



Alex Sandro Monteiro de Moraes

**Ensaio em Gerenciamento de Riscos
Financeiros de Países Emergentes**

Tese de Doutorado

Tese apresentada ao Programa de Pós-graduação em Administração de Empresas da PUC-Rio como requisito parcial para obtenção do título de Doutor em Administração de Empresas.

Orientador: Prof. Antonio Carlos Figueiredo Pinto

Rio de Janeiro

Novembro de 2015



Alex Sandro Monteiro de Moraes

**Ensaio em Gerenciamento de Riscos
Financeiros de Países Emergentes**

Tese apresentada como requisito parcial para obtenção do grau de Doutor pelo Programa de Pós-graduação em Administração de Empresas da PUC-Rio. Aprovada pela Comissão Examinadora abaixo assinada.

Prof. Antonio Carlos Figueiredo Pinto

Orientador
Departamento de Administração – PUC-Rio

Prof. Marcelo Cabus Klotzle

Departamento de Administração - PUC-Rio

Prof. Luiz Felipe Jacques da Motta

Departamento de Administração – PUC-Rio

Prof. Roberto Marcos da Silva Montezano

Faculdades Ibmecc

Prof. Ricardo Bordeaux Rego

UFF

Profa. Mônica Herz

Vice-Decana de Pós-Graduação do CCS

Rio de Janeiro, 10 de novembro de 2015

Todos os direitos reservados. É proibida a reprodução total ou parcial do trabalho sem autorização da universidade, do autor ou do orientador.

Alex Sandro Monteiro de Moraes

Bacharel em Ciências do Mar (Escola Naval) em 1996. Mestre em Administração de Empresas pelo IBMEC *Business School* no Rio de Janeiro em 2003. Professor convidado do FGV Management, do MBA de Finanças da Universidade Federal do Rio de Janeiro e da Escola Naval. Atualmente ocupa o cargo de Chefe do Departamento de Administração Financeira da Diretoria de Finanças da Marinha, cujas atribuições compreendem a execução da administração financeira da Marinha no Brasil e exterior; a gestão da mesa de operações financeiras da Marinha nas áreas de renda fixa e câmbio; e o planejamento de aplicações financeiras nos Estados Unidos e Europa.

Ficha Catalográfica

Moraes, Alex Sandro Monteiro de

Ensaio em gerenciamento de riscos financeiros de países emergentes / Alex Sandro Monteiro de Moraes; orientador: Antonio Carlos Figueiredo Pinto. – 2015.

125 f. : il. (color.) ; 30 cm

Tese (Doutorado) – Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2015.

Inclui bibliografia

1. Administração – Teses. 2. Gerenciamento de Riscos. 3. Administração Pública. 4. Memória Longa. 5. Value-at-Risk. 6. GARCH. I. Pinto, Antonio Carlos Figueiredo. II. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Administração. III. Título.

CDD: 658

Para a minha esposa Priscila e meu filho Leonardo, meus maiores tesouros, pelo amor infinito em compreender o meu longo período de ausência motivado pela dedicação a esta Tese de Doutorado. Essa vitória não é só minha. É de toda a nossa família.

Para os meus pais, Yêda e Carlos, e irmãos, Alessandra e Alan, pela torcida sincera e incondicional que acompanham todas as minhas realizações.

Agradecimentos

A Deus pelas infinitas benções que tem derramado sobre a minha vida.

À Diretoria de Finanças da Marinha, representada pelos Vice-Almirante (IM) Edesio Teixeira Lima Junior, Contra-Almirante (IM) Samy Moustapha e Contra-Almirante (IM) Hugo Cavalcante Nogueira, pelo apoio e confiança em mim depositada.

Ao meu orientador, Prof. Dr. Antonio Carlos Figueiredo Pinto, pela simplicidade, praticidade e precisão com que me orientou para a realização deste trabalho.

Ao Prof. Marcelo pela gentileza em compartilhar comigo seu “arsenal” de livros, artigos e *softwares*, todos relevantes para o bom andamento de minhas pesquisas.

Ao meus amigos da Diretoria de Finanças da Marinha pela torcida e apoio.

Aos meus colegas da PUC-Rio em especial aos amigos Flávio Val e Macelly Moraes pelas longas conversas de desabafo e motivação.

Aos professores que participaram da comissão examinadora pelas contribuições que enriqueceram este trabalho.

A todos os professores do IAG pelos ensinamentos e ajuda.

À Teresa Campos e Fabio Etienne, secretários do IAG, pela gentileza e cordialidade nos atendimentos de minhas demandas ao longo do curso.

A todos os amigos e familiares que, de uma forma ou de outra, me incentivaram ou me ajudaram a concluir este trabalho.

Resumo

Moraes, Alex Sandro Monteiro de; Pinto, Antonio Carlos Figueiredo. **Ensaio em Grenciamento de Riscos Financeiros de Países Emergentes.** Rio de Janeiro, 2015. 125p. Tese de Doutorado – Departamento de Administração, Pontifícia Universidade Católica do Rio de Janeiro.

Nesta tese são desenvolvidos três ensaios que avaliam os riscos relativos a alguns países emergentes. No primeiro ensaio, por meio do uso de modelos da família GARCH, verificou-se que o aumento dos pesos relativos atribuídos às observações mais antigas em função do aumento do horizonte de previsão resulta em melhores estimativas de volatilidade. Por meio da utilização de sete modelos de previsão de volatilidade e séries de retornos de ativos do mercado financeiro brasileiro (ações de Petrobrás e Vale, índice Ibovespa, taxa de câmbio Real/Dólar, taxa de juros de 1 ano e taxa de juros de 3 anos de títulos de dívida do governo brasileiro emitidos em reais) compararam-se as estimativas obtidas na amostra (*in-sample*) com as observações fora da amostra (*out-of-sample*). Com base nesta comparação, constatou-se que as melhores estimativas de previsão de volatilidade foram obtidas, predominantemente, por dois modelos que permitem que seus parâmetros variem em função do horizonte de previsão: o modelo modificado EGARCH e o modelo ARLS. Concluiu-se que a utilização de modelos de previsão de volatilidade tradicionais, os quais mantêm inalterados os pesos relativos atribuídos às observações antigas e recentes, independente do horizonte de previsão, mostrou-se inapropriada. No segundo ensaio comparou-se os desempenhos dos modelos de memória longa (FIGARCH) e curta (GARCH) na previsão de *value-at-risk* (VaR) e *expected shortfall* (ES) para múltiplos períodos à frente para seis índices de ações de mercados emergentes. Utilizou-se, para dados diários de 1999 a 2014, uma adaptação da simulação de Monte Carlo para estimar previsões de VaR e ES para 1, 10 e 20 dias à frente, usando modelos FIGARCH e GARCH para quatro distribuições de erros. Os resultados sugerem que, em geral, os modelos FIGARCH melhoram a precisão das previsões para horizontes mais longos; que a distribuição dos erros pode influenciar a decisão de escolha do melhor modelo; e que apenas para os modelos FIGARCH houve redução do número de subestimações do VaR verdadeiro com o aumento do horizonte de previsão. Com relação ao terceiro ensaio, percebeu-se que a administração de riscos é um assunto que há muito tempo já faz parte do dia-a-

dia das instituições financeiras e não financeiras, todavia não é comum a utilização de métricas de risco na Administração Pública. Considerando a existência dessa lacuna e a importância do tema para uma adequada gestão dos recursos públicos, principalmente para países emergentes, esse terceiro ensaio teve como propósitos estimar, em um único valor, o risco de liquidez de um Órgão Público, a Marinha do Brasil, e identificar as fontes desse risco. Para isso, utilizou-se o *exposure-based Cash-Flow-at-Risk (CFaR) model*, o qual, além de resumir a estimação do risco de liquidez a um único valor, ajuda no gerenciamento desse risco pelo fornecimento de informações adicionais sobre a exposição do fluxo de caixa da organização a diversos fatores de risco. Usando dados trimestrais do período compreendido entre o primeiro trimestre de 1999 ao quarto trimestre de 2013, identificaram-se as taxas de câmbio real/dólar, dólar/libra, a taxa SELIC, a Necessidade de Financiamento do Setor Público e a taxa de inflação dos Estados Unidos como os fatores de risco macroeconômicos e de mercado que impactam o fluxo de caixa da Marinha, bem como se calculou seu CFaR com 95% de nível de confiança para o período de um trimestre à frente.

Palavras-chave

Value-at-Risk; Cash-Flow-at-Risk; Expected Shortfall; GARCH; FIGARCH; Gerenciamento de Riscos; Administração Pública; Memória Longa.

Abstract

Moraes, Alex Sandro Monteiro de; Pinto, Antonio Carlos Figueiredo (Advisor). **Essays in Financial Risk Management of Emerging Countries**. Rio de Janeiro, 2015. 125p. Tese de Doutorado – Departamento de Administração, Pontifícia Universidade Católica do Rio de Janeiro.

In this thesis we develop three essays on risk management in some emerging countries. On the first one, using models of the GARCH family, we verified that the increase in relative weights assigned to the earlier observations due to the increase of the forecast horizon results in better estimates of volatility. Through the use of seven forecasting models of volatility and return series of financial markets assets (shares of Petrobras and Vale, Bovespa index, exchange rate Real/Dollar, 1-year and 3 years interest rates of Brazilian Government bonds issued in Reais) the estimates obtained in the sample (in-sample) were compared with observations outside the sample (out-of-sample). Based on this comparison, it was found that the best estimates of expected volatility were obtained predominantly by two models that allow its parameters to vary depending on the forecast horizon: the modified EGARCH model (exponential generalized autoregressive conditional heteroskedastic) and the ARLS model proposed by Ederington and Guan (2005). We conclude that the use of traditional forecasting models of volatility, which keeps unchanged relative weights assigned to both old and new observations, regardless of the forecast horizon, was inappropriate. On the second essay we compared the performance of long-memory models (FIGARCH) with short-memory models (GARCH) in forecasting value-at-risk (VaR) and expected shortfall (ES) for multiple periods ahead for six emerging markets stock indices. We used daily data from 1999 to 2014 and an adaptation of the Monte Carlo simulation to estimate VaR and ES forecasts for multiple steps ahead (1, 10 and 20 days), using FIGARCH and GARCH models for four errors distributions. The results suggest that, in general, the FIGARCH models improve the accuracy of forecasts for longer horizons; that the error distribution used may influence the decision about the best model; and that only for FIGARCH models the occurrence of underestimation of the true VaR is less frequent with increasing time horizon. Regarding the third essay, we realized that risk management is a subject that has long been part of the day-to-day activities of financial and non-

financial institutions, yet the use of risk metrics is not common among public agencies. Considering this gap, and the importance of the issue for the proper management of public resources, the purpose of this third essay is to estimate, in a single value, the liquidity risk of a public agency, in this case, the Brazilian Navy, and to identify the sources of risk. To do this, the exposure-based Cash-Flow-at-Risk (CFaR) model has been developed, which, in addition to summarizing the liquidity risk estimation in a single value, helps in managing risk by providing additional information about the exposure of the organization's cash flow to various risk factors. Using quarterly data for the period between the first quarter of 1999 and the fourth quarter of 2013, the macroeconomics and market risk factors that impact the Navy's cash flow were identified. Moreover, the CFaR was calculated at a 95% confidence level for a period of one quarter ahead.

Keywords

Value-at-Risk; Cash-Flow-at-Risk; Expected Shortfall; GARCH; FIGARCH; Risk Management; Public Administration; Long Memory.

Sumário

1	Introdução	15
1.1	Situação Problema	15
1.2	Objetivos	18
1.3	Relevância	19
1.4	Contribuições	20
1.5	Descrição dos Capítulos	20
2	Estimativas de Longo Prazo para Volatilidade de Séries Temporais no Mercado Financeiro Brasileiro	22
2.1	Introdução	22
2.2	O Horizonte de Previsão e a Importância Relativa das Observações Passadas nos Modelos da família GARCH.	25
2.2.1	Estimativas de Volatilidade para Horizontes de Tempo Superiores a Um Dia	25
2.3	A Importância Relativa das Observações Passadas nos Modelos da Família GARCH	27
2.3.1	Modelo GARCH	27
2.3.2	Modelo TGARCH	30
2.3.3	Modelo EGARCH	31
2.3.4	Modelo ARLS	32
2.4	Metodologia	33
2.4.1	Dados	33
2.4.2	Modelos	34
2.5	Precisão das Previsões Fora da Amostra	36
2.5.1	Raiz Quadrada da Média dos Quadrados dos Erros (RMSE)	37
2.5.2	Média dos Erros Absolutos (MAE).	38
2.6	Resultados	38
2.6.1	Modelos	38
2.6.2	Precisão das Previsões Fora da Amostra	43
2.7	Conclusão	45
3	Previsão de Value-at-risk e expected-shortfall para mercados emergentes usando modelos fracionalmente integrados para volatilidade condicional	48
3.1	Introdução	48
3.2	Metodologia Empírica	53
3.2.1	Modelo Autorregressivo	53
3.2.2	Modelo GARCH	54
3.2.3	Modelo GARCH Fracionalmente Integrado (FIGARCH)	54
3.2.4	Cálculo do VaR para um passo à frente	55
3.2.5	Cálculo de VaR para múltiplos passos à frente.	56
3.2.6	Avaliação da acurácia das estimativas de VaR	56
3.2.7	A medida ES para um e múltiplos passos à frente	57
3.3	Descrição dos dados	58
3.4	Resultados	60
3.4.1	Testes para detecção de presença de memória longa	60

3.4.2	Estimação (dentro da amostra) dos modelos GARCH e FIGARCH	61
3.4.3	Avaliação das previsões de VaR para um e múltiplos passos à frente para observações fora da amostra	69
3.4.4	Estimativa dos parâmetros utilizando rolagens diárias para a amostra	85
3.5	Discussão	86
3.6	Conclusões	88
4	A Utilização do Cash-Flow-at-Risk no Gerenciamento de Riscos da Marinha do Brasil	90
4.1	Introdução	90
4.2	Referencial Teórico	92
4.2.1	Introdução ao Conceito de Risco	92
4.2.2	Tipos de Risco	92
4.2.3	A Gestão de Risco em Instituições Financeiras	94
4.2.4	A Gestão de Risco em Instituições Não Financeiras	95
4.3	Dados	101
4.3.1	Fluxo de Caixa	101
4.3.2	Potenciais fatores de risco.	102
4.4	Metodologia	104
4.4.1	Exposure-Based Model	104
4.4.2	Simulação do CFaR	105
4.5	Resultados	106
4.5.1	Exposure-based model	106
4.5.2	Resultados Esperados	108
4.5.3	Análise da exposição aos riscos	110
4.5.4	Simulação do Cash-flow-at-risk	112
4.6	Conclusão	113
5	Conclusão	115
6	Referências Bibliográficas	117
7	Apêndice	124

Lista de figuras

Figura 1- Função de Autocorrelação (ACF) para o quadrado dos retornos dos países emergentes.	61
Figura 2- Índice XU100: Estimativas dos Parâmetros ao Longo do Tempo para o Modelo GARCH.	85
Figura 3- Índice XU100: Estimativas dos Parâmetros ao Longo do Tempo para o Modelo FIGARCH	86
Figura 4 – Distribuição Simulada do Fluxo de Caixa da Marinha	113

Lista de tabelas

Tabela 1 - Ativos e Dados	34
Tabela 2 - Estimativas do Modelo GARCH e Horizontes de Previsão	39
Tabela 3 - Estimativas do Modelo TGARCH e Horizontes de Previsão	40
Tabela 4 - Estimativas do Modelo EGARCH e Horizontes de Previsão	41
Tabela 5 - Estimativas do Modelo ARLS e Horizontes de Previsão	42
Tabela 6 - Raiz Quadrada da Média dos Quadrados dos Retornos (RMSE)	43
Tabela 7 - Média dos Erros Absolutos (MAE)	45
Tabela 8 - Estatísticas Descritivas	59
Tabela 9 - Resultados dos Testes de Memória Longa	60
Tabela 10A - IBOV – Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal (n), t de <i>Student</i> (t), GED e t de <i>Student</i> assimétrica (skt).	62
Tabela 10B - JALSH – Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal (n), t de <i>Student</i> (t), GED e t de <i>Student</i> assimétrica (skt)	63
Tabela 10C - MICEX – Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal (n), t de <i>Student</i> (t), GED e t de <i>Student</i> assimétrica (skt)	64
Tabela 10D - SENSEX – Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal (n), t de <i>Student</i> (t), GED e t de <i>Student</i> assimétrica (skt)	65
Tabela 10E - SHCOMP – Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal (n), t de <i>Student</i> (t), GED e t de <i>Student</i> assimétrica (skt)	66
Tabela 10F - XU100 – Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal (n), t de <i>Student</i> (t), GED e t de <i>Student</i> assimétrica (skt)	67
Tabela 11A - Resultados do VaR e ES para 1 passo à frente – distribuição normal (n).	69
Tabela 11B - Resultados do VaR e ES para 1 passo à frente – distribuição t de <i>Student</i> (t).	70
Tabela 11C - Resultados do VaR e ES para 1 passo à frente – distribuição ged.	71
Tabela 11D - Resultados do VaR e ES para 1 passo à frente – distribuição t de <i>Student</i> assimétrica (skt).	72
Tabela 12A - Resultados do VaR e ES para 10 passos à frente – distribuição normal (n).	74
Tabela 12B - Resultados do VaR e ES para 10 passos à frente – distribuição t de <i>Student</i> (t).	75
Tabela 12C - Resultados do VaR e ES para 10 passos à frente – distribuição ged.	76
Tabela 12D - Resultados do VaR e ES para 10 passos à frente – distribuição t de <i>Student</i> assimétrica (skt).	77

Tabela 13A - Resultados do VaR e ES para 20 passos à frente – distribuição normal (n).	78
Tabela 13B - Resultados do VaR e ES para 20 passos à frente – distribuição t de <i>Student</i> (t).	79
Tabela 13C - Resultados do VaR e ES para 20 passos à frente – distribuição ged.	80
Tabela 13D - Resultados do VaR e ES para 20 passos à frente – distribuição t de <i>Student</i> assimétrica (skt).	81
Tabela 14 - Resultados do Teste de Giacomini-White (2006).	84
Tabela 15 - Descrição das Variáveis Independentes e Fontes de Dados	103
Tabela 16 - Estatísticas Descritivas das Variáveis Independentes Utilizadas	107
Tabela 17 - Resultados do <i>Exposed-Based Model</i>	110
Tabela 18 – Correlação das Variáveis Independentes depois de diferenciá-las.	112
Tabela 19 - Estimativas do <i>Exposed-Based CFaR</i> para o 1Tri/2014.	113

1

Introdução

1.1 Situação problema

A recente crise financeira, a volatilidade dos preços do petróleo e demais commodities, a expectativa de subida das taxas de juros nos Estados Unidos e a ocorrência de crises políticas em outros países, tais como o Brasil, mostraram que a busca por medidas de risco é de significativa importância para empresas, governos, investidores e bancos.

Duarte (2003, p. 1) define risco como uma medida da incerteza associada aos retornos esperados de investimentos. Já para Jorion (2003, p. 3), risco pode ser definido “como a volatilidade de resultados inesperados, normalmente relacionados ao valor de ativos ou passivos de interesse”. Desse modo, depreende-se que a ideia de risco está relacionada à incerteza dos resultados de ativos e passivos de interesse do administrador ou investidor.

Roll e Ross (1995) sugerem que um ativo pode ser impactado por riscos sistemáticos e riscos não sistemáticos, também chamados próprios. Risco sistemático é qualquer risco que afeta um grande número de ativos, cada um com maior ou menor intensidade. Exemplos desse tipo de risco são as variações no Produto Interno Bruto, taxas de juros e inflação. Já os riscos não sistemáticos se aplicam a empresas individualmente ou a algum setor específico da indústria, mas não às condições gerais da economia. São também chamados de idiossincráticos para diferenciá-los dos fatores de risco sistemáticos. Dentre os riscos não sistemáticos estão os riscos de falência, riscos de qualidade da administração e os riscos do próprio segmento.

Oxelhein e Wihlborg (1997, p. 20) destacam o método adotado pelo Bank for International Settlements (BIS) para classificação de riscos. Esse método classifica os riscos em risco de mercado, risco de crédito, risco operacional, risco legal, risco de contraparte e risco de liquidez. O risco de mercado está relacionado à incerteza sobre os preços dos ativos transacionados pelo mercado. O risco de crédito refere-se à possibilidade de o tomador de empréstimo não honrar seu

compromisso de pagamento. O risco operacional é aquele oriundo de erros humanos, tecnológicos ou de acidentes, o que inclui fraudes, falhas de gerência e controles inadequados. O risco legal é causado pela incerteza sobre a interpretação dos termos de um contrato. O risco de contraparte refere-se à possibilidade de a contraparte deixar de cumprir os termos de qualquer contrato firmado, ou de outra forma deixar de cumprir o que foi acordado. Por fim, o risco de liquidez ocorre quando uma negociação não pode ser realizada aos preços correntes de mercado, em função da desproporcionalidade entre posição no ativo e seu volume normalmente negociado.

No que concerne aos riscos de mercado, torna-se relevante a elaboração de previsões confiáveis para o Value-at-risk (VaR) e Expected shortfall (ES) para empresas e investidores. O VaR quantifica a máxima perda esperada de uma carteira, em condições normais de mercado, dentro de determinado horizonte de tempo para um nível de confiança especificado. A ES quantifica o valor esperado da perda, dada a ocorrência de violação do VaR.

Na tentativa de se medir adequadamente os riscos de mercado, vários modelos de VaR e ES foram testados. Entretanto, os resultados são conflitantes, já que Angelidis, Benos, e Degiannakis (2004) e Shao *et al* (2009) demonstraram que esses resultados dependem, por exemplo, do mercado para o qual o modelo foi estimado.

Um problema na mensuração dos riscos de mercado é que a maioria dos modelos para previsão de volatilidade, utilizada para cálculo do VaR, produz previsões para 1 dia à frente. Ocorre que, segundo Ederington e Guan (2010), diversos modelos de apreçamento de opções e medidas de VaR geralmente demandam previsões de volatilidade para prazos mais longos. Para atender a essas demandas, a orientação do Comitê de Supervisão Bancária de Basileia (Basel Committee on Banking Supervision –BCBS, 1996) é a utilização da multiplicação do VaR diário pela raiz quadrada do tempo. Todavia, este método foi criticado por Engle (2004) por assumir a inválida suposição de que as volatilidades são constantes ao longo do tempo.

Adicionalmente, há escassez de estudos sobre gestão dos riscos de mercado dedicados aos mercados emergentes. Aloui e Hamida (2014) asseveram que trabalhos relacionados a modelos de risco em mercados de ações de países desenvolvidos vêm sendo frequentemente documentados na literatura empírica. Entretanto, apesar de os mercados emergentes nas últimas duas décadas terem atraído a atenção de investidores internacionais em busca de maior retorno e diversificação para seus investimentos, pouca atenção tem sido dada a previsão de VaR e ES para múltiplos períodos à frente no contexto dos mercados emergentes. Pelo exposto, surgem as seguintes questões de pesquisa:

Como prever a volatilidade de retornos de ativos financeiros de mercados emergentes para horizontes de previsão superiores a um dia?

Como medir os riscos de mercado de ativos financeiros de mercados emergentes para horizontes de previsão superiores a um dia?

A importância da gestão de riscos não é privativa das instituições financeiras, sendo importante também para as instituições não financeiras. Perobelli *et al* (2007) destacam que para as instituições não financeiras a mensuração e gerenciamento de riscos passam a ser fatores de competitividade com potencial para impactar seus fluxos de caixa e, por conseguinte, suas capacidades financeiras e de solvência. Apesar de o VaR ser uma das métricas de risco mais utilizadas para as instituições financeiras, sua aplicação às instituições não financeiras é limitada, pois os ativos destas instituições não apresentam o mesmo grau de liquidez que os das instituições financeiras. Para contornar essa limitação, em 1999, o Riskmetrics Group propôs a mensuração do Cash-Flow-at-Risk (CFAR), cujo propósito principal era o de avaliar os potenciais impactos de mudanças nas taxas de mercado sobre os resultados financeiros da empresa em um determinado intervalo de tempo. La Rocque e Lowenkron (2005) esclarecem que o CFAR representa o valor mínimo de um fluxo de caixa em uma determinada data no futuro, a um determinado nível de confiança avaliado com as informações disponíveis no presente.

Ocorre que apesar de haver, na literatura de finanças, métricas utilizadas no gerenciamento de riscos de instituições financeiras, não é comum a utilização de métricas de risco na esfera governamental. O gerenciamento de riscos é de capital importância para as finanças públicas, porque desequilíbrios entre entradas e saídas de recursos podem resultar em atrasos nos pagamentos de fornecedores, credores e servidores públicos. Assim, torna-se necessário identificar, medir, informar e monitorar os fatores de risco que afetam os fluxos de caixa dos Órgãos Públicos de forma a subsidiar os processos de tomada de decisão para mitigação desses fatores de risco.

A Marinha do Brasil, por fazer parte do Governo Federal, também está inserida nesse contexto. Além disso, recentemente, a Marinha do Brasil firmou contrato de longo prazo com o governo da França para a produção de submarinos, o que além de envolver vultosos recursos financeiros, expõe o orçamento da Marinha aos mais diversos tipos de risco, dentre os quais se destacam os riscos cambiais e os relacionados aos movimentos das taxas de juros nacionais e internacionais. Tal constatação cria a oportunidade de utilização de métricas com potencial para identificar e mensurar os riscos financeiros a que seus fluxos de caixa estão expostos, visando a sua mitigação. Em decorrência, emergem as seguintes questões:

Quais os fatores de risco que influenciam o fluxo de caixa da Marinha?

Em que medida e de que maneira cada fator de risco influencia o fluxo de caixa da Marinha?

Como medir o risco de fluxo de caixa da Marinha do Brasil?

1.2 Objetivos

Para responder as questões de pesquisa supracitadas, definiram-se os seguintes objetivos de pesquisa:

Avaliar se melhores estimativas de volatilidade são obtidas por meio do aumento dos pesos relativos atribuídos às observações mais antigas em função do horizonte de previsão.

Comparar os desempenhos dos modelos de memória longa, Fractionally Integrated Generalized Autorregressive Conditional Heteroscedasticity model (FIGARCH), e memória curta, Generalized Autorregressive Conditional Heteroscedasticity model (GARCH), na previsão de VaR e ES para múltiplos períodos à frente para seis índices de ações de países emergentes.

Identificar os fatores de risco que influenciam o fluxo de caixa da Marinha.

Avaliar em que medida e de que maneira cada fator de risco influencia o fluxo de caixa da Marinha.

Propor um modelo para o gerenciamento de risco de um Órgão governamental: a Marinha do Brasil.

1.3 Relevância

A avaliação de riscos por meio de ferramentas de mensuração adequadas é relevante, principalmente, por dois motivos. Primeiro, a intensificação das transações nos mercados de ações para alguns países emergentes contribui para o aumento da volatilidade nesses mercados. Relatório elaborado pelo Instituto de Finanças Internacionais (IIF Report, 2015) aponta que o fluxo de capitais para mercados emergentes saltou de aproximadamente de US\$ 200 bilhões para US\$ 1,1 trilhão em 2014, mormente para atender aos desejos de investidores por maior rentabilidade e diversificação de riscos. Segundo, os efeitos relevantes da recente crise financeira não foram adequadamente capturados pelos modelos de risco até então utilizados. Rossignolo *et al* (2012) destacam que os níveis de capital sugeridos pelos modelos de VaR adotados foram insuficientes em prover cobertura para eventos adversos inesperados. Daí a importância da adoção da medida ES, a qual mede a perda esperada de uma carteira, dada a violação do VaR.

No que tange ao gerenciamento de riscos em Órgão públicos, o tema é relevante, pois o desequilíbrio das contas públicas que, até recentemente, resultava em insuficiência de caixa para o governo brasileiro tinha como consequência atrasos de pagamentos a fornecedores, servidores públicos e credores (ALBUQUERQUE *et al*, 2006). Esses atrasos faziam com que os fornecedores embutissem seus efeitos nos preços cobrados ao governo, incrementando, portanto, as despesas públicas custeadas por todos os contribuintes. Ademais, uma programação financeira ineficiente realizada pelo governo federal traz resultados

indesejáveis para a sociedade, já que a insuficiência de recursos paralisa a execução de projetos de investimento de interesse comum e aumenta o custo de captação de recursos do Governo em situações de emergência.

1.4 Contribuições

Este trabalho contribui para a discussão sobre os modelos utilizados para previsão de volatilidade e medidas de risco, tais como VaR e ES, para longos horizontes de previsão, uma vez que não há consenso na literatura de finanças sobre qual seria o melhor modelo a ser adotado, já que Christoffersen e Diebold (2000) asseveram que pouco ainda é conhecido acerca da previsibilidade da volatilidade para períodos de longo prazo. Adicionalmente, tendo em vista que Rossignolo *et al* (2012) destacam que há uma tradicional relutância por parte de acadêmicos em estudar os mercados emergentes, este trabalho tem o propósito de contribuir para a redução da carência de estudos sobre o uso de medidas de risco para alguns países emergentes.

Por fim, este trabalho contribui para o preenchimento de lacuna encontrada na bibliografia revisada, ao propor a utilização de uma metodologia, *Cash-Flow-at-Risk*, para identificação e medição dos fatores de risco que impactam os fluxos de caixa de um Órgão Público, a Marinha do Brasil. Após a identificação desses fatores de risco, é possível utilizá-los tanto para analisar quais desses poderão ser mitigados, quanto para mensurar a probabilidade de insuficiência de caixa do Órgão para uma data futura.

1.5 Descrição dos capítulos

O trabalho, além desta parte introdutória, está dividido em três ensaios (Capítulos 2 a 4) e uma conclusão (Capítulo 5). O primeiro ensaio, ao utilizar modelos da família GARCH, examina se o aumento dos pesos relativos, atribuídos às observações mais antigas em função do aumento do horizonte de previsão, resulta em melhores estimativas de volatilidade para os retornos de alguns ativos do mercado financeiro brasileiro. Concluiu-se que a utilização de modelos de previsão de volatilidade tradicionais, os quais mantêm inalterados os pesos relativos atribuídos às diversas observações antigas e recentes, mostrou-se inapropriada.

O segundo ensaio compara os desempenhos dos modelos de memória longa (FIGARCH) e memória curta (GARCH) na previsão de *Value-at-Risk* (VaR) e *Expected Shortfall* (ES) para múltiplos períodos à frente para seis índices de ações de mercados emergentes. Os resultados sugerem que, para a maioria dos índices estudados, os modelos FIGARCH melhoram a precisão das previsões para horizontes mais longos; que a distribuição dos erros pode influenciar a decisão de escolha do melhor modelo; e que apenas para os modelos FIGARCH houve redução do número de subestimações do VaR verdadeiro com o aumento do horizonte de previsão.

O terceiro artigo tem como propósito estimar, em um único valor, o risco de liquidez um Órgão Público de um país emergente, a Marinha do Brasil, e identificar as fontes desse risco. Para isso, lançou mão do *exposure-based Cash-Flow-at-Risk model* (CFaR), o qual além de resumir a estimação do risco de liquidez a um único número, contribui para o gerenciamento desse risco pelo fornecimento de informações adicionais sobre a exposição do fluxo de caixa da Marinha a diversos fatores de risco. Esses fatores de risco, macroeconômicos e de mercado, que impactam o fluxo de caixa da Marinha do Brasil foram identificados e o CFaR foi estimado para um período à frente.

2

Estimativas de longo prazo para volatilidade de séries temporais no mercado financeiro brasileiro

2.1 Introdução

Medidas de Valor em Risco (VaR) para longo prazo bem como modelos de apreçamento de opções demandam estimativas de volatilidade para horizontes de tempo que superam a frequência das observações dos dados. De acordo com Poon e Granger (2003), a volatilidade é frequentemente calculada pela raiz quadrada da variância, a qual, segundo Xekalaki e Degiannakis (2010, p.362) é frequentemente calculada pela soma dos quadrados dos retornos.

Este artigo discute os problemas que surgem quando os modelos de séries temporais do tipo GARCH, tais como GARCH, EGARCH e *threshold* GARCH (TGARCH), propostos por Bollerslev (1986) e Taylor (1986), Nelson (1991) e Zakoian (1994), respectivamente, estimados com dados diários ou de alta frequência são usados para prever volatilidade para horizontes com prazos mais longos, comuns aos modelos de apreçamento de opções e às medidas de longo prazo de Valores em Risco (VaR). Brooks (2014, p. 416) destaca que poucos modelos não-lineares têm se mostrado úteis na modelagem de dados financeiros. Segundo o autor, os modelos do tipo ARCH ou GARCH são os mais utilizados para modelagem e previsão de volatilidade. Moreira e Lemgruber (2004) utilizaram modelos GARCH e EGARCH para cálculo do VaR do IBOVESPA utilizando dados de alta frequência.

Enquanto os modelos tipo GARCH geram previsões de volatilidade para o próximo período ou observação (normalmente para o dia seguinte), os modelos de apreçamento de opções e as medidas de VaR geralmente demandam previsões de volatilidade para prazos mais longos, os quais podem ser semanais, mensais ou mesmo anuais.

Essas previsões de volatilidade, tipicamente, são obtidas por sucessivas substituições futuras, de forma que a previsão de volatilidade para o período $t+1$ é usada juntamente com o modelo de previsão para prever a volatilidade do período $t+2$, esta previsão do período $t+2$ é usada para prever a volatilidade do período $t+3$, e assim sucessivamente. Essas volatilidades são então combinadas para obter a previsão da “volatilidade integrada” para o intervalo compreendido entre o período $t+1$ e o período $t+N$. Muitos modelos de previsão de volatilidade encontrados na literatura de econometria estão focados em prever a volatilidade em $t+1$. Tal fato é observado por Christoffersen e Diebold (2000), os quais asseveram que “muito pouco ainda é conhecido acerca da previsibilidade da volatilidade para períodos de longo prazo”.

Ederington e Guan (2010) esclarecem que o problema dos modelos de previsão de volatilidade de séries temporais para horizontes de tempo maiores que um período é que a previsão de volatilidade para o dia (ou período) $t+1$ é usada para prever a volatilidade para qualquer data futura $t+k$. A importância relativa da volatilidade observada hoje (t) comparada à volatilidade do dia anterior ($t-1$) ou da semana anterior ($t-5$) é forçada a ser a mesma independente de a previsão de volatilidade ser realizada para amanhã, para a próxima semana, ou para o próximo mês.

Uma maneira de evitar esse problema seria adequar a frequência dos dados ao horizonte de previsão. Por exemplo, se o objetivo for prever a volatilidade para o próximo mês, utilizar-se-iam dados mensais para estimar o modelo GARCH e, então, prever a volatilidade para o mês $t+1$.

Todavia, se o horizonte de previsão for longo, o número de observações é significativamente reduzido e, conforme sugerido por Figlewski (1997), a convergência geralmente requer a existência de séries temporais longas.

Ademais, Andersen *et al* (1999) apontam que, ao utilizar-se substituições sucessivas, previsões de volatilidade mais precisas são obtidas com dados de mais alta frequência.

Este trabalho evidencia para dados do mercado financeiro brasileiro, da mesma forma que Ederington e Guan (2010) fizeram para o mercado financeiro norte-americano, que para os modelos GARCH, EGARCH e TGARCH os parâmetros que melhor estimam a volatilidade para o dia seguinte não são os melhores para estimar a volatilidade para períodos de tempo mais longos. Na

verdade, observações mais antigas são relativamente mais importantes em prever volatilidades de mais longo prazo.

Um modelo em que a importância relativa entre observações recentes e antigas varia em função do horizonte de previsão é o modelo dos Mínimos Quadrados Restritos Absolutos (ARLS) proposto por Ederington e Guan (2005). Neste modelo a importância relativa das observações mais antigas aumenta em função do horizonte de previsão.

Neste trabalho comparou-se a capacidade de previsão fora da amostra dos modelos GARCH, EGARCH, TGARCH, modificações de cada um desses três modelos baseadas em regressão - na qual o valor do parâmetro GARCH varia com o horizonte de previsão -, e o modelo ARLS.

Dentre esses sete modelos, o modelo ARLS e o modelo EGARCH modificado obtiveram os melhores resultados em suas previsões de volatilidade para diversos mercados, considerando-se diferentes horizontes de tempo. Na maioria dos casos observados esses modelos apresentaram os menores valores para a raiz quadrada da média dos quadrados dos erros (RMSE), bem como para a média dos erros absolutos (MAE).

Asséries utilizadas foram os retornos diários do IBOVESPA, Petrobrás, Vale, taxa de câmbio Real/Dólar, e os preços unitários (PU) relativos ao valor nominal de R\$ 100.000 descapitalizado pelas taxas de juros de 1 e 3 anos, as quais foram obtidas das curvas de juros dos títulos do governo brasileiro calculadas diariamente pela plataforma *Bloomberg*. As séries correspondem ao período de agosto/1994 a junho/2012. As previsões de volatilidade foram examinadas para os horizontes temporais de 10, 20, 40 e 80 dias úteis.

Este trabalho está organizado da seguinte forma. A próxima Seção discute o fato de como a relação entre os pesos atrelados às observações recentes e antigas, na previsão de volatilidade, depende do horizonte de previsão nos modelos GARCH, TGARCH e EGARCH. Na Seção 3, são apresentados os dados, bem como a metodologia utilizada para a estimação dos parâmetros dos modelos. Além disso, foram apresentadas duas medidas de precisão de modelos de previsão para observações fora da amostra. Na Seção 4, os resultados são evidenciados e analisados. A Seção 5 conclui o artigo.

2.2 O horizonte de previsão e a importância relativa das observações passadas nos modelos da família GARCH.

2.2.1 estimativas de volatilidade para horizontes de tempo superiores a um dia

A literatura mostra alguns modelos que não exigem estimativas de volatilidade para prazos mais longos como, por exemplo, o modelo CAViaR proposto por Engle e Manganelli (2004), em que os autores modelam diretamente a dinâmica temporal de um determinado quantil da distribuição condicional. Mas Figlewski (1997) e Christoffersen e Diebold (2000) apontam que muitas das aplicações para as previsões de volatilidade, tais como apreçamento de opções e modelos de VaR de longo prazo demandam estimativas de volatilidade para um horizonte de tempo maior que a frequência de observação dos dados utilizados para a estimação do modelo. Geralmente, modelos de séries temporais e dados de retornos diários são usados para prever a volatilidade para o dia $t+1$, todavia para o apreçamento de opções, por exemplo, exige-se uma estimativa de volatilidade em conformidade com o prazo de vencimento dessas opções, o que pode ocorrer meses à frente.

Às vezes, assume-se simplesmente que a volatilidade do dia $t+1$ permanecerá constante até o vencimento da opção. Isso ignora a tendência de reversão à média da volatilidade e, como mostram Christoffersen, Diebold e Schuermann (1998), resulta em sérios erros de estimativa.

Normalmente, a previsão de volatilidade para períodos mais longos é realizada por meio de um procedimento recursivo no qual a volatilidade para o dia $t+1$ é usada juntamente com os parâmetros do modelo para prever a volatilidade para o dia $t+2$, a previsão do dia $t+2$ é usada para prever a volatilidade para o dia $t+3$ e assim por diante. Essas previsões diárias são combinadas para se obter a volatilidade do período $t+1$ a $t+N$, uma medida chamada de “volatilidade integrada” por Andersen *et al*(2006).

Como ilustração, considere o modelo:

$$v_{t+1} = \alpha_0 + \alpha_1 r_t^2 + \beta v_t \quad (1)$$

Onde r_t é o choque do retorno logarítmico ($r_t = R_t - E_{t-1}(R_t)$, onde $R_t = \ln(P_t/P_{t-1})$ e P_t é o preço do ativo no tempo t) e v_t é a variância de r_t . No que tange ao vetor de parâmetros $\theta(\alpha_0, \alpha_1, \beta)$, define-se $\alpha_0 > 0, \alpha_1 \geq 0, \beta \geq 0$ para garantir que a variância seja um número não negativo.

Como $E_t(r_{t+1}^2) = v_{t+1}$, onde $E_t(\cdot)$ é o valor esperado no tempo t , sucessivas substituições resultam na expressão da variância esperada no tempo $t+k$ baseada na previsão para $t+1$:

$$\begin{aligned} E_t(v_{t+k}) &= \alpha_0 \sum_{j=0}^{k-1} (\alpha_1 + \beta)^j + (\alpha_1 + \beta)^{k-1} v_{t+1} \\ &= \alpha_0 \sum_{j=0}^{k-1} (\alpha_1 + \beta)^j + (\alpha_1 + \beta)^{k-1} [\alpha_1 r_t^2 + \beta v_t] \end{aligned} \quad (2)$$

Nota-se que v_{t+1} e v_{t+k} são estimativas pontuais da volatilidade. Entretanto, para o apreçamento de opções e mensuração do VaR de longo prazo é preciso usar um intervalo de tempo superior a um dia. O Comitê de Supervisão Bancária de Basileia, por exemplo, recomenda que as instituições financeiras calculem seus VaR para 10 dias à frente (*Basel Committee on Banking Supervision*, 1996). Assim, para se gerar essas previsões, Ederington e Guan (2010) assumem que normalmente os choques dos retornos são independentes. Desse modo, a previsão de variância integrada para o intervalo será obtida pela média das previsões diárias de variância.

Assim, somando-se os valores da equação (2) para $k=1$ até s e dividindo-se o resultado por s , obtém-se a previsão da volatilidade integrada V_{t+s} :

$$E_t(V_{t+s}) = \left(\frac{1}{s}\right) \sum_{k=1}^s v_{t+k} = \alpha_s + \left(\frac{1}{s}\right) [\alpha_1 r_t^2 + \beta v_t] \sum_{k=1}^s (\alpha_1 + \beta)^{k-1} \quad (3)$$

$$\text{Onde } \alpha_s = \left(\frac{\alpha_0}{s}\right) \sum_{k=1}^s \sum_{j=0}^{k-1} (\alpha_1 + \beta)^j$$

2.3 A importância relativa das observações passadas nos modelos da Família GARCH

2.3.1 Modelo GARCH

De acordo com Ederington e Guan (2010), a importância relativa entre as observações recentes e antigas, na previsão da volatilidade, depende do horizonte de previsão. Supõe-se, por exemplo, que, em uma quarta-feira, deseje-se realizar uma previsão de volatilidade para o dia seguinte (quinta-feira), para a semana seguinte e para o mês seguinte. De acordo com a persistência de volatilidade, a volatilidade da quarta-feira seria muito mais importante na previsão da volatilidade do dia seguinte do que a volatilidade de terça-feira, por exemplo. Mas será que a volatilidade de quarta-feira é tão mais importante que a volatilidade do dia anterior (terça-feira) para se fazer previsões de volatilidade para daqui a uma semana ou daqui a um mês?

O procedimento de utilização de sucessivas substituições para a previsão de volatilidade preserva a importância relativa das observações recentes e antigas independentemente do horizonte de previsão. Entretanto, conforme já mencionado, Ederington e Guan (2010) sustentam a hipótese de que a importância relativa entre as observações recentes e antigas deve ser alterada à medida que o horizonte de previsão se amplia.

Considere-se a importância relativa das observações passadas no modelo GARCH. Como $v_t = \alpha_0 + \alpha_1 r_{t-1}^2 + \beta v_{t-1}$, e $v_{t+1} = (\alpha_0 + \beta \alpha_0) + \alpha_1 r_t^2 + \beta \alpha_1 r_{t-1}^2 + \beta^2 v_{t-1}$, sucessivas substituições retroativas no tempo produzem a equação (4), uma forma alternativa de representar o modelo GARCH já mostrado na equação (1):

$$v_{t+1} = \alpha_0' + \alpha_1 \sum_{j=0}^I \beta^j r_{t-j}^2 \quad (4)$$

Onde $\alpha_0' = \alpha_0 \sum_{j=0}^I \beta^j + \beta^{I+1} v_{t-I}$

No que tange ao vetor de parâmetros $\theta(\alpha_0, \alpha_1, \beta)$, define-se $\alpha_0 > 0, \alpha_1 \geq 0, \beta \geq 0$ para garantir que a variância seja um número não negativo.

Ao substituir a equação (4) na equação (2), obtém-se:

$$E_t(v_{t+k}) = \alpha_0 \sum_{j=0}^{k-1} (\alpha_1 + \beta)^j + (\alpha_1 + \beta)^{k-1} \alpha_0' + (\alpha_1 + \beta)^{k-1} \alpha_1 \sum_{j=0}^I \beta^j r_{t-j}^2 \quad (5)$$

A equação (5) deixa claro que, enquanto os pesos absolutos, termos $(\alpha_1 + \beta)$, declinam proporcionalmente ao horizonte k , assumindo-se que $\alpha_1 + \beta < 1$, os pesos relativos dos quadrados dos choques dos retornos passados decaem por uma mesma taxa exponencial independente de a previsão de volatilidade ser realizada para amanhã ou para um futuro mais distante. Como $\partial v_{t+k} / \partial r_{t-j}^2 = \alpha_1 (\alpha_1 + \beta)^j$, a razão das derivadas parciais de duas observações separadas por m períodos é:

$$\frac{\partial E_t(v_{t+k}) / \partial r_{t-j-m}^2}{\partial E_t(v_{t+k}) / \partial r_{t-j}^2} = \beta^m \quad (6)$$

Assim, nas previsões do modelo GARCH, a razão dos pesos relativos associados a observações passadas defasadas em m dias (ou períodos) é de β^m , independente do horizonte de previsão, k , e do quão distante no tempo é o termo j .

Relaciona-se a esse assunto a crítica de que os modelos GARCH apresentam memória curta. Engle e Bollerslev (1986), Ding e Granger (1996), Baillie *et al.* (1996), e Bollerslev e Mikkelsen (1996) evidenciam que o impacto do choque dos retornos decai rapidamente ao longo do tempo. O impacto do quadrado do choque dos retornos, r_{t-j}^2 , na previsão de volatilidade n dias no futuro é:

$$\frac{\partial E_t(v_{t+k+n}) / \partial r_{t-j}^2}{\partial E_t(v_{t+k}) / \partial r_{t-j}^2} = (\alpha_1 + \beta)^n \quad (7)$$

Assim, o impacto do choque na volatilidade em $t+k$ decai exponencialmente a uma taxa $\alpha_1 + \beta$, apesar de haver evidências de que o efeito do impacto tem uma duração maior, segundo Ding *et al.* (1993), Ding e Granger (1996), e Andersen e Bollerslev (1997). Nota-se que os pesos na equação (6) decaem mais rapidamente que na equação (7).

Por exemplo, para as observações diárias dos retornos das ações da VALE no período de 1 de agosto de 1994 até 15 de junho de 2012, os parâmetros α_1 e β do modelo GARCH foram de 0,133 e 0,840, respectivamente. Assim, $(\alpha_1 + \beta)^{10} = 0,7606$, enquanto que $\beta^{10} = 0,1749$, então r_{t-10}^2 (uma observação de 10

dias atrás) recebe um peso que equivale a 17,49% daquele associado ao r_t^2 na previsão de qualquer volatilidade futura.

Segundo Ederington e Guan (2010), existem vários modelos de memória longa utilizados na previsão de volatilidade que estabelecem um fator de decaimento menor que o proporcionado pelo modelo GARCH. Todavia, em todos esses modelos, que lançam mão de funções lineares da volatilidade em $t+1$ para prever volatilidades futuras, o peso relativo dado às observações recentes e futuras são os mesmos independentemente do horizonte de previsão.

Essa relação permanece a mesma nos casos de volatilidade integrada. Somando os valores obtidos na equação (5) para $k=1$ até s , onde $s \geq 2$, e dividindo-se o resultado por s , obtém-se a previsão de volatilidade integrada para o período compreendido entre $t+1$ e $t+s$, V_{t+s} :

$$E_t(V_{t+s}) = (1/s) \sum_{k=1}^s v_{t+k} = \alpha_s + \lambda_s \sum_{j=0}^J \beta^j r_{t-j}^2 \quad (8)$$

Onde,

$$\alpha_s = (1/s) \sum_{k=1}^s \left[\alpha_0 \sum_{j=0}^{k-1} (\alpha_1 + \beta)^j + (\alpha_1 + \beta)^{k-1} \alpha'_0 \right] \quad (9)$$

$$\text{e } \lambda_s = (\alpha_1/s) \sum_{k=1}^s (\alpha_1 + \beta)^{k-1}$$

Nota-se por meio da equação (8) que o impacto relativo de r_{t-j}^2 e r_{t-j-m}^2 na volatilidade integrada de $t+1$ a $t+s$ é a mesma razão β^m , para qualquer valor de s , como pode ser observado a seguir:

$$\frac{\partial E_t(V_{t+s}) / \partial r_{t-j-m}^2}{\partial E_t(V_{t+s}) / \partial r_{t-j}^2} = \beta^m \quad (10)$$

Ainda de acordo com os autores, os parâmetros GARCH, obtidos por máxima verossimilhança, para gerar a volatilidade para o período $t+1$ não são os mesmos para estimar a volatilidade para o período $t+k$, quando k é maior que 1.

Entretanto, Marcellino, Stock e Watson (2006) comparam modelos recursivos e modelos “direct forecast”, nos quais os parâmetros são estimados em função do horizonte de previsão. Após analisarem 170 séries temporais de dados macroeconômicos mensais norte-americanos, apontam que a abordagem recursiva seria mais eficiente se o modelo fosse corretamente especificado. Todavia, esses mesmos autores ressaltam que os modelos “direct forecast” apresentariam resultados mais robustos frente a potenciais erros de especificação no modelo.

Por outro lado Ederington e Guan (2010) esclarecem que melhores estimativas de longo prazo seriam obtidas se a equação (8) fosse alterada de modo a permitir que o parâmetro β varie em função do horizonte de previsão s:

$$E_t(V_{t+s}) = (1/s) \sum_{k=1}^s v_{t+k} = \alpha_s + \lambda_s \sum_{j=0}^J \beta_s^j r_{t-j}^2 \quad (11)$$

Ademais, esses mesmos autores suportam a ideia de que quanto maior o horizonte de previsão, maior deverá ser o termo β_s para que melhores estimativas de volatilidade sejam obtidas.

2.3.2 Modelo TGARCH

O modelo TGARCH acrescenta ao modelo GARCH da equação (1) um termo que captura a assimetria da volatilidade: $\alpha_2 D_t r_t^2$, onde $D_t=1$ se $r_t < 0$, e $D_t=0$ se $r_t \geq 0$:

$$v_{t+1} = \alpha_0 + \alpha_1 r_t^2 + \alpha_2 D_t r_t^2 + \beta v_t \quad (12)$$

Após sucessivas substituições, e utilizando-se $V_t = E_{t-1}(r_t)^2$, chega-se a seguinte expressão para a volatilidade no tempo $t+k$:

$$E_t(v_{t+k}) = \alpha_k + \alpha_1 \delta_k \sum_{j=0}^J \beta^j r_{t-j}^2 + \alpha_2 \delta_k \sum_{j=0}^J \beta^j D_{t-j} r_{t-j}^2 \quad (13)$$

$$\text{Onde } \alpha_k = \sum_{j=0}^{k-1} \beta^j \alpha_0, \quad \delta_k = \prod_{j=0}^{k-1} \zeta_{t+j}, \quad \text{e } \zeta_t = \alpha_1 + \alpha_2 D_t + \beta$$

Ederington e Guan (2010) evidenciam que, se os choques nos tempos $t-j-m$ e $t-j$ apresentarem o mesmo sinal, os pesos relativos das previsões da volatilidade futura ocorrerão na razão β^m para qualquer horizonte de previsão k , do mesmo modo como ocorreu com o modelo GARCH discutido na Seção anterior.

Da equação (13) pode-se chegar a seguinte equação para a volatilidade integrada:

$$E_t(V_{t+s}) = (1/s) \sum_{k=1}^s v_{t+k} = \alpha_s + \lambda_{1s} \sum_{j=0}^1 \beta_s^j r_{t-j}^2 + \lambda_{2s} \sum_{j=0}^1 \beta_s^j D_{t-j} r_{t-j}^2 \quad (14)$$

Onde $\lambda_{1s} = (1/s) \sum_{k=1}^s \alpha_1 \delta_k$ e $\lambda_{2s} = (1/s) \sum_{k=1}^s \alpha_2 \delta_k$

2.3.3 Modelo EGARCH

Considere-se agora o modelo EGARCH, o qual é de particular interesse, uma vez que ele tende a apresentar memória mais longa que o modelo GARCH, isto é, o efeito das observações tende a perdurar por mais tempo. O modelo EGARCH possui a forma:

$$\ln(v_{t+1}) = \alpha_0 + \beta \ln(v_t) + \gamma_1 \left| r_t / \sigma_t \right| + \gamma_2 (r_t^2 / \sigma_t) \quad (15)$$

Ederington e Guan (2010) demonstram que a equação para o cálculo do logaritmo da estimativa da volatilidade pontual no tempo $t+k$, após substituições recursivas para frente, passa a ser:

$$\ln(v_{t+k}) = \left[\alpha + \gamma_1 \sqrt{2/\pi} \right] \sum_{j=0}^{k-2} \beta^j + \beta^{k-1} \ln(v_{t+1}) \quad (16)$$

Ademais, esses autores argumentam que se os choques de observações defasadas em m períodos apresentarem os mesmos sinais, e as volatilidades condicionais dos períodos dessas observações forem iguais; então haverá resultados análogos aos encontrados para os modelos GARCH e TGARCH, nos quais as derivadas parciais das observações defasadas de m períodos são na razão β^m . De onde se conclui que o impacto relativo dos retornos passados na previsão de volatilidade não depende do horizonte de previsão k .

Para o modelo EGARCH, Ederington e Guan (2010) definem a volatilidade integrada, V_{t+s} , como sendo a média geométrica das volatilidades de $t+1$ até $t+s$. Assim, V_{t+s} passa a ser definida pela seguinte expressão:

$$\ln(V_{t+s}) - (1/s) \sum_{k=1}^s \ln(v_{t+k})$$

$$= \lambda_{1s} + \lambda_{2s} \sum_{j=0}^J \beta^j \left| r_{t-j} / \sigma_{t-j} \right| + \lambda_{3s} \sum_{j=0}^J \beta^j \left(r_{t-j} / \sigma_{t-j} \right) \quad (17)$$

$$\text{Onde, } \lambda_{1s} = \left(\frac{1}{s} \right) \sum_{k=1}^s \left[\left(\alpha + \gamma_1 \sqrt{2/\pi} \right) \sum_{j=0}^{k-2} \beta^j + \alpha' \beta^{k-1} \right],$$

$$\lambda_{2s} = \left(\gamma_1 / s \right) \sum_{k=1}^s \beta^{k-1}, \quad \lambda_{3s} = \left(\gamma_2 / s \right) \sum_{k=1}^s \beta^{k-1} \text{ e}$$

α' é a constante da equação

$$\ln(v_{t+1}) = \alpha' + \gamma_1 \sum_{j=0}^J \beta^j \left| r_{t-j} / \sigma_{t-j} \right| + \gamma_2 \sum_{j=0}^J \beta^j \left(r_{t-j} / \sigma_{t-j} \right)$$

2.3.4 Modelo ARLS

O modelo dos Mínimos Quadrados Absolutos (ARLS), sugerido por Ederington e Guan (2005), permite que os pesos relativos entre as observações recentes e antigas variem em função do horizonte de previsão. Assim como ocorre para o modelo GARCH, no modelo ARLS os pesos atribuídos às volatilidades passadas decaem exponencialmente e incorporam reversão à média. Entretanto, o modelo considera o desvio-padrão ao invés da variância e é baseado nos valores absolutos dos choques dos retornos e, não, no quadrado desses choques. Segundo os autores, isso ocorre, pois os modelos baseados nos quadrados dos retornos tendem a prever grandes aumentos de volatilidade após retornos extremos, fato que raramente se confirma com as observações realizadas.

A expressão para o modelo ARLS é a seguinte:

$$ASD(s)_t = \alpha_s + \lambda_s \sum_{j=0}^J \sqrt{\pi/2} \beta_s^j \left| r_{t-j} \right| \quad (18)$$

Onde $ASD(s)_t$ é o desvio-padrão dos retornos do período compreendido entre $t+1$ a $t+s$. Essa expressão é estruturalmente idêntica à do modelo GARCH apresentada na equação (11), exceto pelo seguinte:

- i. O desvio-padrão substitui a variância no lado esquerdo da equação;
- ii. O retorno absoluto $|r_{t-j}|$ substitui r_{t-j}^2 no lado direito da equação;
- iii. Os coeficientes β_s, α_s e γ_s podem variar em função do horizonte de previsão, s ; e
- iv. O termo $\sqrt{\pi/2}$ é adicionado.

Entretanto, Ederington e Guan (2005) esclarecem que o modelo ARLS apresenta a limitação de assumir a distribuição normal para os retornos, enquanto que há ampla documentação na literatura indicando que esses retornos exibem assimetria e excesso de curtose.

2.4 Metodologia

2.4.1 Dados

O conjunto de dados utilizados compõe-se dos retornos logarítmicos diários do índice IBOVESPA; das ações da Vale (VALE5) e Petrobrás (PETR4); dos Preços Unitários (PU) relativos ao valor nominal de R\$ 100.000 descapitalizados pelas das taxas de juros de 1 ano e 3 anos, obtidas das curvas de juros dos títulos do governo brasileiro emitidos em reais calculadas diariamente pela plataforma *Bloomberg*; e da taxa de câmbio Real/Dólar. As séries começam em agosto de 1994 ou na primeira data de dados disponíveis para o ativo e terminam em junho de 2012. A série das taxas de câmbio Real/Dólar começa em fevereiro de 1999, pois se procurou excluir o efeito de quebra estrutural produzida pela mudança de regime cambial no Brasil em janeiro de 1999. A fonte dos dados, períodos de tempo e algumas estatísticas descritivas encontram-se relacionados na Tabela 1. Ademais, em conformidade com o estudo realizado por Ederington e Guan (2010) para o mercado norte-americano, considerou-se os horizontes de previsão de 10, 20, 40 e 80 dias úteis para cálculo da volatilidade.

Tabela 1: Ativos e Dados

Ativos e Dados				
Ativos	Período	Nº observações	Retornos Diários (X 1000)	
			Média	Desv. Padrão
Petrobrás	1/8/94-15/6/12	4421	0,733	28,0719
Vale	1/8/94-15/6/12	4421	0,787	26,7166
Ibovespa	1/8/94-15/6/12	4421	0,588	23,0839
Real/Dólar	1/2/99-15/6/12	3543	0,0001	11,0410
PU 1 ano	28/3/97-29/6/12	1306	0,030	0,8736
PU 3 anos	28/3/97-15/6/12	1300	0,063	3,5700

Fonte: Bloomberg

2.4.2 Modelos

Modelo GARCH

Para testar se as previsões de volatilidade obtidas por meio do modelo GARCH poderiam ser melhoradas variando-se o termo β_s em função do horizonte de previsão, utilizou-se uma regressão não linear de mínimos quadrados (NLMQ) para se obter os parâmetros β_s , α_s e λ_s da equação (11). A variável dependente, $AV(s)_t$, corresponde à variância média observada no período de $t+1$ até $t+s$. Dito de outra forma, $AV(s)_t = (1/s) \sum_{i=1}^s r_{t+i}^2$. Desse modo, os parâmetros β_s , α_s e λ_s foram estimados por meio da aplicação dos mínimos quadrados ao seguinte par de equações:

$$AV(s)_t = \alpha_s + \lambda_s Z_t + \varepsilon_t \quad (19)$$

$$\text{Onde, } Z_t = \sum_{j=0}^J \beta_s^j r_{t-j}^2, \beta < 1$$

Para o cálculo de Z_t estipulou-se $J=200$, pois como $\beta < 1$, β^j é um número muito próximo de zero para valores de $J > 200$.

Para se calcular os termos Z_t fez-se o β variar (em intervalos de 0,01) de 0,50 até 1, resultando, portanto, em 51 coeficientes diferentes e 51 equações de regressão correspondentes a esses coeficientes. Dentre essas equações, foi escolhida aquela que apresentou a menor soma dos quadrados dos erros. Da equação escolhida extraíram-se os parâmetros β_s , α_s e λ_s . A estimação de parâmetros pelo método dos mínimos quadrados, segundo Ederington e Guan (2005) reduz o peso das observações mais recentes. Esse método é uma alternativa ao GARCH padrão, o qual lança mão do método da máxima verossimilhança para a estimação dos parâmetros. De acordo com os autores, os parâmetros estimados por esse método apresentaram menor estabilidade em

comparação àqueles estimados pelo método dos mínimos quadrados, quando diferentes sub-amostras foram utilizadas.

O procedimento utilizado na regressão não linear de mínimos quadrados (NLMQ) mencionada acima visa a obter os parâmetros que resultem na menor raiz quadrada da média dos quadrados dos erros (RMSE) das previsões de variância. Desse modo, pode-se verificar se os parâmetros que minimizam a soma dos quadrados dos erros da variância diferem daqueles obtidos por meio do modelo GARCH e se esses parâmetros variam em função do horizonte de previsão.

Modelo TGARCH

Assim como no modelo GARCH, Ederington e Guan (2010) sustentam a hipótese de que os modelos de previsão de volatilidade com a menor raiz quadrada da média dos quadrados dos erros (RMSE) podem ser obtidos, permitindo-se que o parâmetro β varie em função do horizonte de previsão e que o parâmetro ótimo β_s aumenta com o horizonte de previsão. Para testar essa hipótese os autores sugerem o uso do modelo TGARCH modificado com o uso da regressão (NLMQ) para estimar o modelo:

$$AV(s)_t = \alpha_s + \lambda_{1s}Z_{1t} + \lambda_{2s}Z_{2t} + \varepsilon_t \quad (20)$$

$$\text{Onde, } Z_{1t} = \sum_{j=0}^J \beta_s^j r_{t-j}^2 \text{ e } Z_{2t} = \sum_{j=0}^J \beta_s^j D_{t-j} r_{t-j}^2.$$

Como no modelo GARCH modificado da equação (19), $AV(s)_t$ representa a variância real observada no período $t+1$ a $t+s$.

Utilizando-se os dados dos mesmos ativos do mercado brasileiro discutidos na Seção 3.1, estimou-se os parâmetros β para o modelo TGARCH padrão da equação (12) e os parâmetros β_s do modelo TGARCH modificado.

Modelo EGARCH

Da mesma forma que o realizado para os modelos GARCH e TGARCH, verificou-se se as melhores estimativas de volatilidade são obtidas pela variação do termo β_s em função do horizonte de previsão. Para efetuar esse teste lançou-se mão do modelo EGARCH modificado definido pela expressão a seguir:

$$\ln(AV(s)_t) = \lambda_{1s} + \lambda_{2s}Z_{2t} + \lambda_{3s}Z_{3t} + s_t \quad (21)$$

$$\text{Onde, } Z_{2t} = \sum_{j=0}^J \beta^j \left| \frac{r_{t-j}}{\hat{\sigma}_{t-j}} \right| \text{ e } Z_{3t} = \sum_{j=0}^J \beta^j \left(\frac{r_{t-j}}{\hat{\sigma}_{t-j}} \right)$$

Para a equação acima, $\hat{\sigma}_{t-j}$ corresponde à estimativa da volatilidade para o dia $t-j$.

Utilizando-se os dados dos mesmos ativos do mercado brasileiro discutidos na Seção 3.1, estimou-se os parâmetros β para o modelo EGARCH padrão da equação (15) e os parâmetros β_s do modelo EGARCH modificado.

Modelo ARLS

A equação (18) do modelo ARLS, descrita na Seção 2.2.4, foi estimada por meio de regressão linear, na qual a variável dependente, $ASD(s)_t$, foi obtida pelo desvio-padrão observado no período compreendido entre $t+1$ a $t+s$. Para se gerar as séries de variáveis independentes, lançou-se mão da função $W(\beta) = \sqrt{\pi/2} \sum_{j=0}^{200} \beta^j \left| r_{t-j} \right|$, usando-se valores de β de 0,5 a 1 (em incrementos de 0,01). Desse modo, efetuou-se a regressão de $ASD(s)_t$ em $W(\beta)_t$, utilizando-se o método dos mínimos quadrados, repetiu-se essa regressão para cada valor de β e escolheram-se os valores de β , α e λ para a regressão que apresentasse a menor soma dos quadrados dos resíduos.

2.5 Precisão das previsões fora da amostra

Nesta Seção comparou-se o quão precisos são os modelos de previsão de volatilidade, considerando-se as previsões fora da amostra.

Para os modelos GARCH, TGARCH e EGARCH, estimaram-se seus modelos tradicionais definidos por meio das equações (1), (12) e (15), respectivamente, e as versões modificadas desses modelos definidas pelas equações (19), (20) e (21), respectivamente, as quais permitem que os parâmetros variem em função do horizonte de previsão, utilizando-se uma regressão não linear de mínimos quadrados (NLMQ). Por exemplo, estimou-se separadamente o modelo GARCH da equação (1) e o modelo GARCH modificado da equação (19) e foram usados ambos os modelos para prever a volatilidade futura.

No total compararam-se sete modelos: GARCH, TGARCH, EGARCH, as três versões modificadas destes modelos, e o ARLS.

2.5.1 Raiz Quadrada da Média dos Quadrados dos Erros (RMSE)

Ederington e Guan (2010) sugerem como primeira medida de acurácia do modelo de previsão *out-of-sample* a raiz quadrada da média dos quadrados dos erros (RMSE) definida como:

$$RMSE(s, j, k) = \sqrt{\left(\frac{1}{T}\right) \sum_{t=1}^T FE(s, j, k)_t^2} \quad (22)$$

Onde, $FE(s, j, k)_t$ é o erro de previsão de volatilidade para um horizonte de previsão de s dias para o ativo j no dia t , referente ao modelo k .

Uma questão a ser tratada é qual medida de volatilidade deve ser usada, pois como foi visto até o momento, os modelos GARCH e TGARCH estimam a variância, o modelo ARLS estima o desvio-padrão e o modelo EGARCH estima o logaritmo do desvio-padrão.

Neste artigo foram utilizados como medida de volatilidade os desvios-padrão dos choques dos retornos, pois, como argumentam Poon e Granger (2003) o desvio-padrão é melhor que a variância, já que a variância é mais suscetível a *outliers* e distanciamento da hipótese de normalidade.

Além disso, em Black e Scholes (1973) e na maioria dos modelos de apreçamento de opções, o preço da opção é aproximadamente uma função linear do desvio-padrão para opções *near-the-money*, aquelas cujo preço do exercício apresenta valor próximo ao preço do ativo-objeto. Ademais, as medidas de VaR são funções lineares do desvio padrão.

O erro de previsão do desvio-padrão é calculado como $FE(s, j, k)_t = \text{Fore}(s, j, k)_t - \text{Act}(s, j)_t$, onde $\text{Fore}(s, j, k)_t$ é a previsão para o desvio-padrão anualizada para um horizonte de s dias de $t+1$ até $t+s$ para o ativo j usando o modelo k ; e $\text{Act}(s, j)_t$ é o desvio-padrão real observado, calculado utilizando-se as últimas 252 observações de retornos diários (o que corresponde aproximadamente a um ano de dados diários).

Para a geração das previsões *out-of-sample*, os modelos foram estimados usando 1260 observações diárias dos retornos, o que corresponde a aproximadamente 5 anos de dados diários. Posteriormente, esses modelos foram utilizados para realizar previsões, as quais foram comparadas com as últimas 252 observações diárias dos retornos que foram separadas do resto da amostra.

2.5.2 Média dos Erros Absolutos (MAE).

Além da RMSE, utilizou-se outro critério para avaliar o poder de previsão *out-of-sample* dos sete modelos de previsão mencionados acima, a Média dos Erros Absolutos, MAE (s, j, k), definida como $MAE(s, j, k) = \left[\left(\frac{1}{T} \right) \sum_{t=1}^T |FE(s, j, k)_t| \right]$.

2.6 Resultados

2.6.1 Modelos

Modelo GARCH

As estimativas de β do modelo GARCH da equação (1), a distribuição de erros que proporcionou a menor soma dos quadrados dos resíduos para as distribuições testadas (normal, *t-Student*, *Generalized Error Distribution* (GED), skew normal, skew *t-Student* e skew GED), bem como as estimativas de β_s do modelo GARCH modificado com o uso da regressão (NLMQ) da equação (11) são evidenciados na Tabela 2. Essas estimativas foram obtidas com todas as observações contidas na amostra (*in sample*). Pode-se observar que das 24 estimativas de β no modelo GARCH modificado, 17 apresentaram valor igual ou superior aos valores de β calculados pelo modelo GARCH padrão, representando, portanto 70% dos casos. Esses resultados estão de acordo com a argumentação de Ederington e Guan (2010) de que melhores previsões de volatilidade são obtidas com o incremento do peso relativo das observações mais antigas à medida que o horizonte de previsão se amplia.

Todavia, nota-se que boa parte da exceção a esse comportamento dos parâmetros concentra-se nas previsões de volatilidade para os PU de 3 anos, pois os β_s estimados pelo modelo GARCH modificado foram menores que o β estimado pelo modelo GARCH padrão, indo de encontro, portanto, à hipótese sustentada pelos autores citados no parágrafo anterior.

Tabela 2: Estimativas do Modelo GARCH e Horizontes de Previsão

Estimativas do Modelo GARCH e Horizontes de Previsão						
Ativo	Estimativas de β	Distribuição Resíduos	Valores de β_s que minimizam a soma dos quadrados dos erros do modelo modificado (<i>In Sample</i>)			
	GARCH*		10 dias	20 dias	40 dias	80 dias
Petrobrás	0,88	Skew GED	0,85	0,90	0,95	0,94
Vale	0,85	GED	0,96	0,97	0,97	0,96
IBOV	0,87	Normal	0,88	0,92	0,96	0,95
Real/Dólar	0,86	Skew <i>t-Student</i>	0,80	0,91	0,88	0,85
Taxa 1y	0,74	Normal	0,99	0,98	0,98	1,00
Taxa 3y	0,92	Normal	0,87	0,90	0,87	0,88
Média	0,85		0,89	0,93	0,94	0,93

Fonte: Bloomberg

*p-value < 0,01

As diferenças na importância relativa entre as observações antigas e as recentes são significativas. Considere, por exemplo, o peso atrelado a uma observação de 20 dias úteis atrás, r^2_{t-20} , relativo ao peso atrelado à observação de hoje, r^2_t , na geração de previsão de volatilidade. Para o modelo GARCH o β médio estimado para os seis ativos é de 0,85, o que corresponde a um peso atrelado à observação r^2_{t-20} de 3,88% ($\beta^j = (0,85)^{20}$) do peso atrelado à observação atual, r^2_t . Esses pesos são os mesmos, independente do horizonte de previsão. Por outro lado, ao se usar o modelo GARCH modificado para 20 dias de previsão, por exemplo, percebe-se que o β médio para os 6 ativos passa a ser de 0,93, o que corresponde a um peso atrelado à observação r^2_{t-20} de 23,42% ($\beta^j = (0,92)^{20}$) do peso atrelado à observação atual, r^2_t .

Desse modo, percebe-se que a volatilidade no modelo GARCH modificado de 20 dias úteis atrás tem impacto 6 vezes maior que aquele registrado para a mesma volatilidade no modelo GARCH padrão.

Modelo TGARCH

Os resultados para os parâmetros β para o modelo TGARCH padrão da equação (12), a distribuição de erros que proporcionou a menor soma dos quadrados dos resíduos para as distribuições testadas (normal, *t-Student*, *Generalized Error Distribution* (GED), skew normal, skew *t-Student* e skew GED), e os parâmetros β_s do modelo TGARCH modificado são mostrados na Tabela 3:

Tabela 3: Estimativas do Modelo TGARCH e Horizontes de Previsão

Estimativas do Modelo TGARCH e Horizontes de Previsão						
Ativo	Estimativas de β		Valores de β_s que minimizam a soma dos quadrados dos erros do modelo modificado (In Sample)			
	TGARCH*	Distribuição Resíduos	10 dias	20 dias	40 dias	80 dias
Petrobrás	0,88	Skew GED	0,91	0,93	0,95	0,95
Vale	0,84	Normal	0,95	0,96	0,97	0,96
IBOV	0,87	Normal	0,89	0,91	0,97	0,96
Real/Dólar	0,88	Skew Normal	0,82	0,89	0,85	0,84
Taxa 1y	0,90	Skew t-Student	0,94	0,92	1,00	1,00
Taxa 3y	0,89	Skew Normal	0,87	0,90	0,87	0,87
Médias	0,87		0,90	0,92	0,93	0,93

Fonte: Bloomberg

*p-value < 0,01

Pode-se observar que das 24 estimativas de β no modelo TGARCH modificado, 18 apresentaram valor igual ou superior aos valores de β calculados pelo modelo TGARCH padrão para o respectivo ativo, representando, portanto 75% dos casos. Esses resultados também estão alinhados com a investigação de Ederington e Guan (2010) para dados do mercado financeiro norte-americano.

Assim como o ocorrido para o modelo GARCH, observa-se que o padrão de aumento de β_s em função do horizonte de previsão não se verifica nas previsões de volatilidade para os PU de 3 anos, pois os β_s estimados pelo modelo TGARCH modificado foram menores que o β estimado pelo modelo TGARCH padrão.

Modelo EGARCH

Os resultados dos parâmetros β para o modelo EGARCH padrão da equação (15), a distribuição de erros que proporcionou a menor soma dos quadrados dos resíduos para as distribuições testadas (normal, t-Student, Generalized Error Distribution (GED), skew normal, skew t-Student e skew GED), e os parâmetros β_s do modelo EGARCH modificado são mostrados na Tabela 4:

Tabela 4: Estimativas do Modelo EGARCH e Horizontes de Previsão

Estimativas do Modelo EGARCH e Horizontes de Previsão						
Ativo	Estimativas de β		Valores de β_s que minimizam a soma dos quadrados dos erros do modelo modificado (<i>In Sample</i>)			
	EGARCH*	Distribuição Resíduos	10 dias	20 dias	40 dias	80 dias
Petrobrás	0,97	Skew GED	0,92	0,94	0,95	0,94
Vale	0,97	Normal	0,95	0,96	0,97	0,97
IBOV	0,96	Normal	0,93	0,95	0,96	0,95
Real/Dólar	0,98	Skew t-Student	0,76	0,94	0,81	0,79
Taxa 1y	0,97	Skew t-Student	0,94	0,92	1,00	1,00
Taxa 3y	0,97	Normal	0,96	0,95	0,99	1,00
Médias	0,97		0,91	0,94	0,95	0,94

Fonte: Bloomberg

*p-value < 0,01

Em conformidade com os resultados encontrados por Ederington e Guan (2010) para o mercado norte-americano, observa-se na Tabela 4, que as estimativas de β para o modelo EGARCH são maiores que aquelas realizadas para os modelos GARCH e TGARCH. As médias das estimativas de β dos seis ativos investigados foram de 0,85 para o modelo GARCH contra 0,97 para o modelo EGARCH, resultando em uma memória mais longa e um maior peso dado às observações mais antigas para o modelo EGARCH. Para ilustrar esse ponto, nota-se que a média de 0,85 do modelo GARCH faz com que o peso atribuído ao retorno de 20 dias atrás, r^2_{t-20} , seja de somente 3,88% ($\beta^j = (0,85)^{20}$) daquele atribuído a r^2_t . Todavia, a média de 0,97 faz com que o peso atribuído ao retorno de 20 dias atrás, r^2_{t-20} , seja 54,38% ($\beta^j = (0,97)^{20}$) daquele atribuído a r^2_t .

Ademais, pôde-se verificar que, em 77% dos casos, os β_s estimados pelo modelo EGARCH modificado não apresentaram decréscimo em seus valores com o aumento do horizonte de previsão.

Entretanto, diferentemente do constatado Ederington e Guan (2010) para o mercado norte-americano, verificou-se, para os ativos do mercado brasileiro estudados, que os β_s dos modelos EGARCH modificados não foram, de forma predominante, maiores que os β dos modelos EGARCH padrão, pois, na Tabela 4, observa-se que dos 24 β_s estimados para o modelo EGARCH modificado, apenas 4 (16,6%) apresentaram valores superiores aos respectivos β estimados por meio do modelo EGARCH padrão.

Isso implica que, se o objetivo for apenas a descrição dos dados com observações dentro da amostra, a melhor alternativa é o modelo EGARCH padrão por ser mais parcimonioso que o modelo EGARCH modificado, uma vez que aquele não demanda a estimação de um parâmetro β_s distinto para cada horizonte de previsão.

Modelo ARLS

A Tabela 5 apresenta os resultados para as estimativas de β_s do modelo ARLS:

Tabela 5: Estimativas do Modelo ARLS e Horizontes de Previsão

Estimativas do Modelo ARLS e Horizontes de Previsão				
Ativo	Valores de β que minimizam a soma dos quadrados dos erros do modelo modificado (<i>In Sample</i>)			
	10 dias	20 dias	40 dias	80 dias
Petrobrás	0,90	0,93	0,94	0,93
Vale	0,94	0,95	0,94	0,96
IBOV	0,88	0,91	0,94	0,94
Real/Dólar	0,89	0,91	0,89	0,87
Taxa 1y	0,72	0,84	0,81	0,83
Taxa 3y	0,90	0,89	0,88	0,90
Médias	0,87	0,91	0,90	0,91

Fonte: Bloomberg

Na tabela 5, nota-se que as médias dos β_s obtidas por meio do modelo ARLS para cada horizonte de previsão são maiores que o β médio de 0,85 obtido por meio do modelo GARCH padrão, evidenciando, mais uma vez, o aumento do valor do parâmetro β em função do horizonte de previsão. Isso significa que, quando comparado ao modelo GARCH, o modelo ARLS atribui maior peso para as observações mais antigas devido ao maior horizonte de previsão. Por exemplo, para um horizonte de previsão $s=20$, enquanto no modelo ARLS a observação de 20 dias atrás, $|r_{t-20}|$, recebe um peso de 13,58% ($\beta^j=(0,91)^{20}$) - considerando-se a média de β_{20} para os seis diferentes ativos- daquele atribuído à observação mais recente, $|r_t|$; no modelo GARCH a observação de 20 dias atrás, r_{t-20}^2 , recebe um peso de 3,88% ($\beta^j=(0,85)^{20}$) do peso dado à observação mais recente, r_t^2 .

2.6.2 Precisão das previsões fora da amostra

Raiz Quadrada da Média dos Quadrados dos Erros (RMSE)

Os valores para as raízes quadradas das médias dos quadrados dos erros, RMSE(s, j, k), para as previsões de desvio-padrão dos retornos são apresentados na Tabela 6 para todos os modelos de previsão k, e horizontes de previsão s=10, 20 e 40 dias úteis para os seis ativos, j. Os menores valores para RMSE, para cada linha, encontram-se destacados em negrito, enquanto que o segundo menor valor encontra-se destacado em itálico. O prazo de 80 dias não foi utilizado por lançar mão de muitas observações fora da amostra, o que reduziria significativamente o número de observações disponíveis para a estimação do modelo.

Tabela 6: Raiz Quadrada da Média dos Quadrados dos Erros (RMSE)

Raiz Quadrada da Média dos Quadrados dos Erros (RMSE)							
	ARLS	GARCH		EGARCH		TGARCH	
Ativo		Standard	Modified	Standard	Modified	Standard	Modified
Painel A - 10 dias							
Petrobrás	<i>0,1336</i>	0,1361	0,1358	0,1721	0,1249	0,1422	0,1445
Vale	<i>0,1334</i>	0,1505	0,1435	0,1653	0,1211	0,1512	0,1435
IBOV	<i>0,1035</i>	0,1145	0,1070	0,1362	0,0940	0,1211	0,1105
Real/Dólar	<i>0,0872</i>	0,1329	<i>0,0871</i>	0,1772	0,0778	0,1562	0,0891
Taxa 1y	<i>0,0705</i>	0,0820	0,0724	0,0836	0,0720	0,0830	0,0697
Taxa 3y	0,0174	0,0220	0,0205	0,0320	<i>0,0211</i>	0,0216	0,0530
Painel B - 20 dias							
Petrobrás	<i>0,1180</i>	0,1343	0,1181	0,1917	0,1073	0,1486	0,1221
Vale	<i>0,1168</i>	0,1393	0,1205	0,1758	0,1025	0,1461	0,1219
IBOV	<i>0,0900</i>	0,1124	0,0923	0,1511	0,0828	0,1296	0,0932
Real/Dólar	0,0665	0,0882	<i>0,0663</i>	0,0961	0,0674	0,0913	0,0621
Taxa 1y	0,0061	0,0070	0,0074	0,0069	<i>0,0066</i>	0,0093	0,0211
Taxa 3y	0,0169	0,0180	0,0186	0,0359	0,0203	<i>0,0174</i>	0,0549
Painel C - 40 dias							
Petrobrás	<i>0,0898</i>	0,1568	0,0859	0,2257	0,0761	0,1759	0,0911
Vale	0,0979	0,1522	<i>0,0958</i>	0,2012	0,0823	0,1658	0,1759
IBOV	0,0872	0,1329	<i>0,0871</i>	0,1772	0,0778	0,1562	0,0891
Real/Dólar	0,0591	0,1002	<i>0,0581</i>	0,1072	0,0616	0,1050	0,0580
Taxa 1y	0,0041	0,0084	0,0054	<i>0,0047</i>	0,0058	0,0105	0,0191
Taxa 3y	0,0163	0,0176	0,0191	0,0444	0,0201	<i>0,0165</i>	0,0565

Fonte: Bloomberg

Como mostrado na Tabela 6, nenhum modelo apresenta as melhores previsões para todos os ativos em todos os horizontes de previsão. Todavia percebe-se a predominância dos modelos ARLS e EGARCH modificado. Esses resultados encontram-se alinhados com a pesquisa realizada por Ederington e Guan (2010) para o mercado norte-americano.

Verifica-se na Tabela 6 seis ativos e três horizontes de previsão. Dessas 18 combinações ativo /horizonte de previsão, o modelo EGARCH modificado, o qual permite que o parâmetro β varie em função do horizonte de previsão, apresenta o menor RMSE *out-of-sample* em 10; e o modelo ARLS em 5. Nenhum outro modelo de previsão apresentou menor RMSE em mais que 3 combinações ativo/horizonte de previsão.

A predominância dos modelos EGARCH modificado e ARLS é reforçada ao constatar-se que o modelo EGARCH modificado apresentou o menor ou o segundo menor RMSE em 61% dos casos, enquanto que o modelo ARLS apresentou o menor ou o segundo menor ou RMSE em 72% dos casos.

Média dos Erros Absolutos (MAE)

Os cálculos das MAE (s, j, k) para os diversos mercados e horizontes de previsão encontram-se na Tabela 7.

Os resultados observados na Tabela 7 são basicamente os mesmos obtidos pelo critério RMSE evidenciado na Tabela 6, nos quais se manteve a predominância dos modelos EGARCH modificado e ARLS sobre os demais.

Das 18 combinações ativo/horizonte de previsão, o modelo EGARCH modificado apresentou o menor MAE em 12; e o modelo ARLS em 5 combinações. Assim como observado para o critério RMSE, nenhum outro modelo de previsão apresentou menor MAE em mais que 3 combinações ativo/horizonte de previsão.

Ademais, verificou-se que o modelo EGARCH modificado apresentou o menor ou o segundo menor MAE em 94,4% dos casos, enquanto que o modelo ARLS apresentou o menor ou o segundo menor ou MAE em 88,8%.

Em resumo, pode-se dizer que o modelo EGARCH modificado e o modelo ARLS proposto por Ederington e Guan (2005) apresentaram preponderância em relação aos outros cinco modelos no que diz respeito às previsões de volatilidade *out-of-sample* para horizontes de previsão superiores a um período (dia).

Aqueles modelos apresentam a característica comum de permitir que o parâmetro β_s varie em função do horizonte de previsão, o que não ocorre com os modelos GARCH, TGARCH e EGARCH tradicionais.

Desse modo, percebe-se, para as séries financeiras observadas, que a menor parcimônia dos modelos modificados, já que utilizam parâmetros diferentes para cada horizonte de previsão, é justificada pelos menores RMSE e MAE observados, quando comparados àqueles obtidos pelos modelos padrão.

Tabela 7: Média dos Erros Absolutos (MAE)

Média dos Erros Absolutos (MAE)							
	ARLS	GARCH		EGARCH		TGARCH	
Ativo		Standard	Modified	Standard	Modified	Standard	Modified
S - 10 dias							
Petrobrás	<u>0,0956</u>	0,1038	0,1031	0,1359	0,0858	0,1047	0,1084
Vale	<u>0,0941</u>	0,1222	0,1090	0,1327	0,0842	0,1204	0,1130
IBOV	<u>0,0706</u>	0,0864	0,0726	0,1032	0,0599	0,0870	0,0746
Real/Dólar	<u>0,0500</u>	0,0643	0,0556	0,0654	0,0484	0,0642	0,0531
Taxa 1 ano	0,0046	0,0048	0,0066	0,0055	<u>0,0047</u>	0,0071	0,0165
Taxa 3 anos	0,0140	0,0196	0,0188	0,0287	<u>0,0147</u>	0,0193	0,0526
S - 20 dias							
Petrobrás	<u>0,0893</u>	0,1023	0,0963	0,1340	0,0782	0,1034	0,0999
Vale	<u>0,0804</u>	0,0943	0,0917	0,1176	0,0698	0,0943	0,0922
IBOV	<u>0,0632</u>	0,0805	0,0682	0,1012	0,0520	0,0827	0,0659
Real/Dólar	<u>0,0501</u>	0,0645	0,0522	0,0702	0,0470	0,0650	0,0508
Taxa 1 ano	0,0046	0,0048	0,0066	0,0055	<u>0,0047</u>	0,0071	0,0210
Taxa 3 anos	0,0142	0,0158	0,0164	0,0308	<u>0,0151</u>	0,0154	0,0542
S - 40 dias							
Petrobrás	0,0746	0,1279	<u>0,0712</u>	0,1457	0,0620	0,1309	0,0733
Vale	<u>0,0740</u>	0,1034	0,0798	0,1297	0,0605	0,1087	0,1581
IBOV	<u>0,0673</u>	0,0972	0,0745	0,1130	0,0548	0,1062	0,0746
Real/Dólar	<u>0,0481</u>	0,0738	0,0482	0,0780	0,0461	0,0765	0,0482
Taxa 1 ano	0,0033	0,0071	0,0051	0,0038	<u>0,0035</u>	0,0095	0,0190
Taxa 3 anos	0,0141	<u>0,0131</u>	0,0167	0,0364	0,0156	0,0126	0,0561

Fonte: Bloomberg

2.7 Conclusão

O apreçamento de opções e medidas de Value-at-Risk (VaR) normalmente demandam previsões de volatilidade para períodos, cujos horizontes são superiores à frequência de observação dos dados utilizados para gerar essas previsões.

Os modelos tradicionais da família GARCH para estimar a volatilidade para períodos mais longos lançam mão de substituições recursivas. Estas forçam que a importância relativa entre as observações mais antigas e as mais recentes permaneça a mesma seja qual for o horizonte de previsão da volatilidade, apesar de a importância absoluta de ambas as observações, antigas e recentes, declinarem devido à reversão à média.

Por outro lado, mostrou-se que observações mais antigas são relativamente mais importantes que as mais recentes na previsão de volatilidade para horizontes de previsão mais longos.

Adicionalmente, foram estimadas versões modificadas dos modelos GARCH, TGARCH, EGARCH e o modelo ARLS sugerido por Ederington e Guan (2005), os quais apresentam a característica de permitir que os valores dos parâmetros dos modelos variem em função do horizonte de previsão.

As estimativas de volatilidade fora da amostra para vários ativos e horizontes de previsão foram comparadas entre os sete modelos de previsão. Apesar de nenhum modelo ter apresentado as melhores estimativas para todas as combinações ativo/horizonte de previsão, houve predominância dos modelos EGARCH modificado e ARLS, pois apresentaram os menores valores de RMSE e MAE.

Por todo o exposto, pode-se concluir que gerar estimativas de volatilidade para longos horizontes de previsão por meio dos modelos tradicionais que empregam substituições recursivas mostrou-se inapropriado; e que os métodos de previsão de volatilidade devem permitir que as observações mais antigas sejam relativamente mais importantes que as mais recentes na previsão de volatilidade para horizontes mais longos.

Como limitação, este ensaio apresenta o fato de comparar os modelos modificados GARCH, TGARCH e EGARCH apenas com os respectivos modelos padrão. Uma sugestão de pesquisa futura seria a comparação dos modelos modificados com modelos de memória longa para estimação de volatilidade, uma vez que parte da perda de memória dos modelos da família GARCH poderia ser explicada pela não utilização de modelos que lançam mão de integração fracionada como é o caso dos modelos FIGARCH, FIEGARCH e FIAPARCH.

Outra limitação identificada foi a estimação dos modelos com uma amostra de tamanho fixo de 1260 observações para efeito de análise da precisão das previsões fora da amostra. Angelidis *et al* (2004) explicam que, dependendo do tamanho da amostra utilizado para estimação, pode-se chegar a resultados distintos. Assim, recomenda-se que estudos futuros sobre o assunto adotem tamanhos de amostra distintos para a estimação dos modelos.

3

Previsão de value-at-risk e expected-shortfall para mercados emergentes usando modelos fracionalmente integrados para volatilidade condicional

3.1 Introdução

A recente crise financeira, a volatilidade observada para os preços do petróleo e demais *commodities*, a expectativa de subida das taxas de juros nos Estados Unidos e a ocorrência de crises políticas em outros países, tais como o Brasil, enfatizaram que o uso de medidas de risco para a determinação dos riscos de mercado, implícitos em qualquer investimento ou instrumento financeiro, é de capital importância para empresas, investidores e bancos. Particularmente para os bancos a importância da utilização dessas medidas se dá pela necessidade que estes têm de atender a certos requisitos legais, cujo propósito principal é prevenir a ocorrência de *default*, um evento que seria relevante para os agentes do mercado financeiro de uma forma geral. Nesse contexto, torna-se relevante a elaboração de previsões confiáveis para o *value-at-risk* (VaR) e *expected shortfall* (ES) para empresas e investidores. O VaR quantifica a máxima perda esperada de uma carteira, em condições normais de mercado, dentro de determinado horizonte de tempo para um nível de confiança especificado. A ES quantifica o valor esperado da perda, dada a ocorrência de violação do VaR.

A necessidade da elaboração de uma ferramenta adequada para mensuração de risco é fruto de diversos aspectos. Primeiro, a intensificação das transações nos mercados de ações, principalmente para alguns mercados emergentes, contribui para o aumento da volatilidade nesses mercados (ALLOUI e HAMIDA, 2014). Relatório elaborado pelo Instituto de Finanças Internacionais (IIF report, 2015) revela que o fluxo de capitais para mercados emergentes saltou de aproximadamente US\$ 200 bilhões em 2000 para US\$ 1,1 trilhão em 2014, principalmente para atender aos desejos de investidores por maior rentabilidade e diversificação de riscos.

Segundo, os efeitos relevantes da recente crise financeira não foram adequadamente capturados pelos modelos de risco até então adotados. Rossignolo *et al.* (2012) apontam que os níveis de capital sugeridos pelos modelos de VaR utilizados foram insuficientes em prover cobertura para eventos adversos inesperados. Além disso, a literatura financeira demonstra que o VaR não é uma medida de risco coerente por não atender a propriedade da subaditividade, segundo a qual a medida de risco de uma carteira nunca deve ser maior que a soma das medidas de risco das carteiras que a compõe. Outra limitação do VaR é não fornecer qualquer informação sobre a perda potencial da carteira, quando seu valor é violado. Para superar essas limitações do VaR, Artzer, Delbaen, Eber e Heath (1997) propuseram a medida ES (ES) por representar o valor da perda esperada, dada a ocorrência de violação do VaR.

Como o Comitê de Supervisão Bancária de Basiléia (*Basel Committee on Banking Supervision-BCBS*, 1996) não estabelece em suas recomendações uma metodologia específica para o cálculo do VaR, faz-se necessária a pesquisa de metodologias alternativas para gerenciamento de riscos que possam superar as limitações encontradas no uso do VaR.

Na busca de uma métrica que mensure adequadamente os riscos de mercado, vários modelos de VaR e ES foram testados. Todavia, Angelidis, Benos, e Degiannakis (2004) e Shao *et al* (2009) esclarecem que os resultados são conflitantes, pois dependem do mercado para o qual o modelo foi estimado, o tamanho e a frequência das séries dos dados, e se o VaR se refere a posições compradas ou vendidas.

Além disso, a distribuição adotada para os erros pode influenciar a acurácia da precisão dos modelos, pois o VaR contempla a estimação das caudas da distribuição empírica dos retornos. Há muitos modelos que presumem a distribuição normal para os retornos dos ativos, fato que pode ser justificado, principalmente, nas situações em que os parâmetros desses modelos são estimados pelo método da quase-máxima verossimilhança (QML), pois Bollerslev e Wooldridge (1992) mostraram que a maximização da função logarítmica de verossimilhança com distribuição normal pode prover estimativas consistentes para esses parâmetros, mesmo que distribuição verdadeira dos retornos não seja normal, desde que o valor esperado e variância dos resíduos do modelo sejam 0 e 1, respectivamente. Apesar de Angelidis *et al* (2004) concordarem que muitos

modelos presumem a distribuição normal para os retornos dos ativos, esses autores destacam que há ampla documentação na literatura enfatizando que esses retornos exibem assimetria e excesso de curtose, fato que pode resultar na subestimação ou superestimação do VaR verdadeiro. Rossignolo *et al.* (2012) argumentam que o uso de distribuições de caudas pesadas parecem prover modelos de VaR mais adequados para mercados emergentes, dentre os quais Brasil e Índia. Sitima e Hlatywayo (2015) chegaram a conclusões semelhantes quando modelaram VaR e ES para outros mercados emergentes, que incluíam China e África do Sul. Esses resultados estão de acordo com os encontrados por Aloui e Mabrouk (2010) e Mabrouk e Saadi (2012). Giot e Laurent (2003, 2004) constataram que modelos do tipo APARCH com distribuição *Student-t* assimétrica superaram o desempenho de modelos com outras distribuições nas estimações de VaR dentro da amostra e fora da amostra. Por esses motivos, o presente trabalho lançou mão de quatro diferentes distribuições para os erros. A distribuição normal (n) - mais parcimoniosa; as distribuições leptocúrticas, normal generalizada (ged) e t de *Student*, para capturar o excesso de curtose das distribuições dos retornos e, por fim, a t de *Student* assimétrica (skt) para capturar a assimetria desses retornos.

Todavia, conforme argumentam Aloui e Hamida (2014), a maioria dos modelos para cálculo de VaR produzem previsões para 1 dia à frente. A orientação do BCBS para estimativa de VaR para horizontes de tempo mais longos é a utilização da multiplicação do VaR diário pela raiz quadrada do tempo. Este método foi criticado por Engle (2004) por assumir a inválida suposição de que as volatilidades são constantes ao longo do tempo.

Desse modo, a necessidade de previsões para horizontes mais longos levantou o debate sobre o desempenho do modelo de memória curta, GARCH, na previsão do VaR para horizontes de tempo mais longos, em relação ao modelo de memória longa, FIGARCH, o qual incorpora maior persistência da volatilidade (BAILLIE, BOLLERSLEV, e MIKKENSEN, 1996; BOLLERSLEV e MIKKENSEN, 1996; NAGAYASU, 2008).

A utilização de modelos de memória longa pode contribuir para a melhoria das previsões realizadas pelas ferramentas usadas no gerenciamento de riscos de mercado. Ao estimar o VaR e a ES por meio de dois modelos de memória longa, *Fractional Integrated Power ARCH* (FIAPARCH) e *Hyperbolic GARCH* (HYGARCH) usando várias distribuições para os erros de algumas ações, Hardle e Mungo (2008) concluíram que modelos que consideravam assimetria na especificação de volatilidade apresentaram melhor desempenho na previsão para 5 dias à frente, tanto para posições compradas, quanto para posições vendidas. Kaman, Turgutlu e Ayhan (2009) encontraram fortes evidências de presença de memória longa na volatilidade e nos retornos das ações de mercados de países da Europa Central e do Leste, constatando a superioridade do modelo ARFIMA-FIGARCH na previsão de observações *fora da amostra*.

Adicionalmente, Caporin (2008), Tang e Shieh (2006), e Vilasuso (2002) apresentaram resultados empíricos que sugerem a superioridade do modelo FIGARCH na previsão do VaR. Todavia, esses resultados contrastam com as alegações de Degiannakis *et al.*(2013), os quais concluíram que o modelo FIGARCH não supera o modelo GARCH nas previsões de VaR e ES para múltiplos dias à frente (10 e 20 dias), após investigarem 20 índices de ações de mercados desenvolvidos, assumindo somente a distribuição normal para os retornos. Aloui e Hamida (2014) asseveram que a presença de memória longa em mercados de ações de países desenvolvidos vem sendo frequentemente documentada na literatura empírica. Entretanto, apesar de os mercados emergentes nas últimas duas décadas terem atraído a atenção de investidores internacionais em busca de maior retorno e diversificação para seus investimentos, pouca atenção tem sido dada a previsão de VaR e ES para múltiplos períodos à frente no contexto dos mercados emergentes.

Os mercados emergentes diferem dos mercados de países desenvolvidos. Aloui e Hamida (2014) alegam que, na maioria dos casos, os mercados emergentes são caracterizados por carência de desenvolvimento institucional, baixa proteção legal ao investidor, fraca governança corporativa; e presença de distorções de microestrutura de mercado. Ademais, na maioria desses mercados, os participantes reagem às informações de forma mais lenta devido à falta de cultura de investimento em ações.

Desse modo, este trabalho visa a contribuir com a discussão sobre o desempenho das previsões dos modelos de memória longa em relação aos de memória curta. Para tal, testou-se empiricamente, para seis índices de ações de países emergentes, se o modelo de memória longa, FIGARCH, apresenta melhor desempenho que o modelo de memória curta, GARCH, na previsão de VaR e ES para horizontes mais longos de previsão, em particular, para 10 e 20 dias à frente. O prazo de 10 dias foi selecionado, pois o Comitê de Supervisão Bancária da Basileia recomenda que as instituições financeiras calculem seus VaR para 10 dias à frente (Basel Committee on Banking Supervision, 1996), enquanto que o prazo de 20 dias foi selecionado por já ter sido utilizado em trabalho sobre tema semelhante (DEGIANNAKIS *et al.*, 2013) e pelo fato de que a utilização de horizontes de tempo mais longos reduz significativamente o número de observações *fora da amostra* disponíveis para a análise.

A análise empírica deste estudo faz uso da adaptação da técnica da simulação de Monte Carlo adotada por Degiannakis *et al.* (2013) para a previsão de VaR e ES para múltiplos períodos à frente, a qual foi proposta inicialmente por Christoffersen (2012). Esta técnica permite a comparação de desempenho entre os modelos GARCH e FIGARCH para os horizontes de tempo investigados.

Os resultados deste estudo sugerem que, para a maioria dos índices estudados, os modelos de memória longa, FIGARCH, melhoram a precisão das previsões de VaR e ES quando comparados aos modelos de memória curta, GARCH, para horizontes mais longos de previsão. Ademais, constatou-se que a ocorrência de subestimação do VaR verdadeiro ficou menos frequente com o aumento do horizonte de previsão para os modelos FIGARCH. O mesmo não ocorreu para os modelos GARCH. Adicionalmente, verificou-se que a escolha da distribuição utilizada para os retornos pode influenciar a decisão de escolha do melhor modelo para previsão de VaR e ES. Por fim, constatou-se a presença de instabilidade das estimativas dos parâmetros ao longo do tempo para os modelos GARCH e FIGARCH. Todavia, os modelos FIGARCH sugerem maior variação das estimativas de seus parâmetros ao longo do tempo do que a variação apresentada pelos modelos GARCH.

Este estudo se distingue dos trabalhos acima citados pelo fato de investigar a relevância das propriedades de memória longa na modelagem de volatilidade dos mercados da Turquia e dos países emergentes que representam a sigla BRICS (Brasil, Rússia, Índia, China e África do Sul) para três horizontes de previsão (1, 10 e 20 dias à frente); e por estimar os modelos GARCH e FIGARCH com o uso de quatro diferentes distribuições para as inovações dos retornos.

Esses países foram escolhidos por constituírem, formalmente, desde 2008, uma nova unidade político-diplomática (BRICS). Essa nova entidade tem promovido encontros anuais entre os Chefes de Estado dos países-membros, cujos resultados englobam acordos constitutivos do Novo Banco de Desenvolvimento (NBD) voltado para o financiamento de projetos de infraestrutura e desenvolvimento sustentável em economias emergentes e países em desenvolvimento (Ministério das Relações Exteriores, 2014). Apesar de não fazer parte dos BRICS, a Turquia foi selecionada por ser um país emergente do continente europeu que ocupou lugar de destaque (7º lugar) no *ranking* dos 20 melhores países emergentes, elaborado pela revista *Bloomberg Markets* (BLOOMBERG, 2013).

O restante deste ensaio está organizado da seguinte forma: a Seção 2 apresenta a metodologia empírica utilizada neste trabalho. A Seção 3 descreve os dados. A Seção 4 mostra os resultados. A Seção 5 apresenta a discussão dos resultados e a Seção 6 conclui o artigo.

3.2 Metodologia empírica

3.2.1 Modelo autorregressivo

Para a média condicional dos retornos logarítmicos dos índices de ações, y_t , estabeleceu-se a especificação AR(1) por sua parcimônia e porque Angelidis e Degiannakis (2007) reportaram que a especificação da média condicional não é importante para a previsão da variância condicional. Desse modo os referidos retornos seguem o processo descrito conforme a equação a seguir:

$$\begin{aligned} y_t &= \mu_t + a_t \\ a_t &= \sigma_t z_t \end{aligned} \quad (23)$$

em que $z_t^{i.i.d} \sim f(w; 0,1)$, sendo $f(\cdot)$ a função densidade de z_t e w , um vetor de parâmetros de f a ser estimado para as distribuições normal (n), t de *Student* (t), normal generalizada (ged) e t de *Student* assimétrica (skt), distribuições essas escolhidas em função dos motivos apresentados na seção 1. Os números 0 e 1 representam, respectivamente, os valores da média e variância da distribuição.

3.2.2 Modelo GARCH

Bollerslev (1986) e Taylor (1986) desenvolveram, independentemente, o modelo GARCH. O modelo GARCH permite que a variância condicional, σ_t^2 , seja dependente de seus valores passados de forma que a equação dessa variância condicional em sua forma mais simples, GARCH (1,1), seja:

$$\sigma_t^2 = \alpha_0 + \alpha_1 L \sigma_t^2 + \beta_1 L \sigma_t^2 \quad (24)$$

em que L representa o operador de defasagem. A especificação GARCH (1,1) foi selecionada, pois alguns autores, Angelidis e Degiannakis (2007) e Hansen e Lunde (2005), relataram que uma ordem 1 de defasagem tanto para o quadrado dos resíduos, quanto para a variância condicional seria suficiente para modelar a volatilidade condicional.

3.2.3 Modelo GARCH Fracionalmente Integrado (FIGARCH)

Baillie, Bollerslev, and Mikkelsen (1996) ampliaram o modelo GARCH tradicional ao incluir a operação de integração fracionária. Com isso propuseram o modelo FIGARCH, o qual é capaz de distinguir processos de memória curta dos processos de memória longa para o comportamento da variância condicional. O desempenho do modelo de especificação GARCH (1,1) foi comparado com o modelo GARCH fracionalmente integrado, FIGARCH (p,d,q), o qual incorpora um decaimento mais lento da volatilidade condicional dos retornos, esse processo de memória longa faz com que o efeito da volatilidade persista por mais tempo. (BAILLIE *et al.*, 1996). O processo FIGARCH (p,d,q) é definido por:

$$\sigma_t^2 = \alpha_0 + (1 - D(L) - \Phi(L)(1 - L)^d) \varepsilon_t^2 + D(L) \sigma_t^2 \quad (25)$$

em que $\Phi(L) \equiv (1 - A(L) - B(L))(1 - L)^{-1}$, sendo $A(L)$ e $B(L)$ os polinômios operadores de defasagem de ordens q e p , respectivamente (HARRIS e SOLLIS, 2003). O operador de diferenciação fracionária $(1 - L)^d$ é definido como $(1 - L)^d = \sum_{j=0}^{\infty} \pi_j L^j$. Em que $\pi_j = \frac{d\Gamma(j-d)}{\Gamma(1-d)\Gamma(j+1)}$ e $\Gamma(v) = \int_0^{\infty} e^{-x} x^{v-1} dx$.

Os modelos IGARCH (p,q) e GARCH (p,q) são casos particulares do modelo FIGARCH (p,d,q), para $d=1$ e $d=0$, respectivamente. Pelos mesmos motivos já explicados para a escolha do GARCH (1,1), assumiu-se a especificação FIGARCH (1,d,1) para o modelo de memória longa. Todavia, Chung (1999) critica o modelo FIGARCH proposto por Baillie *et al.* (1996), alegando que o operador de diferenciação fracionária não se aplica ao termo constante da equação da variância do mesmo jeito que se aplica ao termo constante da equação da média (modelos ARFIMA). Assim, considerando as alegações de Chung (1999), Xekalaki e Degiannakis (2010) apresentam a seguinte equação para o modelo FIGARCH (1,d,1), a qual foi utilizada neste artigo:

$$\sigma_t^2 = (a_1 - b_1) L s_t^2 + \sum_{j=1}^{\infty} \left(\pi_j L^j (s_t^2 - a_1 L s_t^2) \right) + b_1 L \sigma_t^2 \quad (26)$$

3.2.4 Cálculo do VaR para um passo à frente

O VaR, com 95% de nível de confiança, para um passo à frente é calculado da seguinte forma:

$$VaR_{t+1|t}^{(1-\alpha)} = \mu_{t+1|t} + f_{\alpha}(z_t; w) \sigma_{t+1|t} \quad (27)$$

em que $1 - \alpha = 95\%$, $\mu_{t+1|t}$ e $\sigma_{t+1|t}$ são, respectivamente, a previsão da média condicional e o desvio-padrão em $t + 1$, dada a informação disponível no tempo t . Ademais, $f_{\alpha}(z_t; w)$ é o α -percentil da distribuição z_t definida por $z_t^{i.i.d} \sim f(w; 0,1)$, sendo $f(\cdot)$ a função densidade de z_t e w , um vetor de parâmetros de f a ser estimado para as distribuições normal (n), t de Student (t), normal generalizada (ged) e t de Student assimétrica (skt).

3.2.5 Cálculo de VaR para múltiplos passos à frente.

Para computar as previsões de VaR para múltiplos passos à frente, utilizou-se o algoritmo de simulação de Monte Carlo apresentado por Degiannakis *et al.* (2013), proposto inicialmente por Christoffersen (2012), cujo detalhamento encontra-se no Apêndice A. O método consiste em dividir o período fora da amostra em intervalos não sobrepostos para evitar autocorrelação na previsão dos erros. Para cada intervalo não sobreposto, produziu-se a distribuição dos retornos τ passos à frente (neste estudo usou-se $\tau = 1, 10$ e 20) dias utilizada para estimar o conjunto de VaR, com nível de confiança 95%, para τ passos à frente, conforme a equação a seguir:

$$VaR_{t+\tau|t}^{(95\%)} = f_{95\%} \left(\{y_{t+\tau}\}_{t-1}^{5000} \right) \quad (28)$$

3.2.6 Avaliação da acurácia das estimativas de VaR

Danielson (2011, p. 143) esclarece que não há uma simples resposta sobre como escolher o melhor modelo para previsão de risco. Segundo o autor, apesar de ser possível avaliar modelos individualmente por meio de testes de significância de parâmetros e análise de resíduos, esses métodos não abordam de maneira adequada as propriedades dos modelos de previsão de risco. Por isso, sugere a utilização de procedimentos de *backtesting*, como, por exemplo, o teste de Kupiec. Esses procedimentos ajudam a evitar a superestimação e subestimação do VaR.

Primeiramente, a acurácia das previsões do VaR foi avaliada pelo teste de Kupiec (1995). A ideia do referido teste é verificar se a esperada taxa de violação do modelo é igual à taxa de violação realmente obtida com o uso desse modelo. Para isso a estatística incondicional de cobertura de Kupiec testa a hipótese nula de que a taxa de violação real do VaR $(N/\bar{T} = \pi_0)$ é estatisticamente igual a taxa esperada de violação $(\alpha = 5\%)$, em que N é o número de dias em que houve violação do VaR durante o período de estimação, \bar{T} , o qual corresponde também ao número de observações fora da amostra para as previsões de VaR um passo à frente. A estatística da razão de verossimilhança usada no teste é dada por:

$$LR_{UC} = 2 \log((1 - \pi_0)^{T-N} \pi_0^N) - 2 \log((1 - \alpha)^{T-N} \alpha^N) \sim \chi_1^2 \quad (29)$$

Assim, o modelo preferido seria aquele em que a hipótese nula de igualdade entre as taxas observadas e taxas esperadas de violação não fosse rejeitada.

Adicionalmente, utilizou-se a estatística condicional de cobertura de Christoffersen para examinar a hipótese nula de que as violações do VaR ocorrem de forma independente e estão espalhadas ao longo do período de estimação; contra a hipótese alternativa de que as violações do VaR não ocorrem de forma independente. O teste é realizado por meio da estatística da razão de verossimilhança:

$$LR_{IN} = 2 \log \left(\frac{(1 - \pi_{01})^{n_{00}} \pi_{01}^{n_{01}} (1 - \pi_{11})^{n_{10}} \pi_{11}^{n_{11}}}{(1 - \pi_0)^{n_{00} + n_{10}} \pi_0^{n_{01} + n_{11}}} \right) \sim \chi_1^2 \quad (30)$$

Com relação às variáveis, n_{ij} é o número de observações com valor i seguido pelo valor j , para $i, j = 0, 1$ e $\pi_{ij} = \frac{n_{ij}}{\sum_j n_{ij}}$ representa as probabilidades

correspondentes. Uma violação do VaR ocorre quando $i = 1$ e/ou $j = 1$, não ocorrendo violação, portanto, quando $i = 0$ ou $j = 0$. A variável π_{ij} indica a probabilidade de j ocorrer no tempo t , dado que i ocorreu no tempo $t - 1$. A hipótese nula é de que as violações do VaR ocorrem de forma independente.

3.2.7 A medida ES para um e múltiplos passos à frente

O conceito de ES foi proposto por Artzner, Delbaen, Eber, e Heath (1997) para contornar algumas desvantagens apresentadas pelo VaR tais como a falta de informação do volume da perda potencial, caso o VaR seja violado; e o fato de o VaR não ser uma medida de risco coerente, pois não satisfaz a propriedade da subaditividade. A ES representa o valor da perda esperada, dada a ocorrência de violação do VaR. Para o cálculo da ES, Acerbi e Tasche (2002) propõem dividir a cauda de distribuição de probabilidade dos retornos em 5000 partes de igual massa de probabilidade. Em seguida calcular-se-iam os VaR relativos a cada uma das 5000 partes. A ES seria obtida pela média desses VaR.

$$ES_{t+\tau|t}^{(1-\alpha)} = E \left(Y_{t+\tau} | (Y_{t+\tau} \leq VaR_{t+\tau|t}^{(1-\alpha)}) \right) \quad (31)$$

em que τ representa o número de passos à frente (neste estudo usou-se $\tau = 1, 10$ e 20).

De acordo com Angelidis e Degiannakis (2007) é possível medir a função quadrática de perda usando ES, já que, conforme dito anteriormente, o VaR não provê informação sobre a perda esperada da carteira nos casos em que o VaR é violado, isto é, nas situações em que o retorno observado é menor que o VaR. Esses autores sugerem que a função quadrática de perda, Ψ_{t+1} , assuma o valor do quadrado da diferença entre o retorno observado e a ES, nos casos de violação do VaR; e 0 (zero), nos demais casos. Assim o melhor modelo seria aquele que apresentasse o menor erro médio quadrático, (*mean squared error*)(MSE):

$$MSE = \sum_{t=0}^{T-1} \Psi_{t+1} / T \quad (32)$$

3.3 Descrição dos dados

Com o propósito de examinar a robustez e o desempenho dos modelos de volatilidade selecionados, este estudo utilizou os retornos diários dos índices de ações dos BRICS (Brasil, Rússia, Índia, China e África do Sul) e da Turquia. Os índices são IBOV (Brasil), MICEX (Rússia), SENSEX (Índia), SHCOMP (China), JALSH (África do Sul) e XU100 (Turquia). Os dados foram obtidos da plataforma de informações *Bloomberg* durante o período compreendido entre 01/01/1999 a 26/12/2014. Escolheu-se esse intervalo de tempo porque Angelidis *et al* (2004) utilizaram período de extensão semelhante em seu trabalho com alguns índices de ações de países desenvolvidos e porque a partir de janeiro de 1999 o mercado cambial brasileiro passou a operar sob regime de livre flutuação da taxa de câmbio, abandonando o sistema de bandas. Foram removidos os dias em que não houve negociações. Assim, o número total de retornos logarítmicos, \hat{T} , variou de 3863 para o índice chinês até 3998 para o índice turco. Baseando-se na rolagem diária de amostras (*rolling sample*) de tamanho $T=2000$ observações, cada modelo gerou um total de $\tilde{T} = \hat{T} - T$ observações fora da amostra. Os parâmetros de cada modelo foram reestimados a cada novo dia de negociação para essas observações fora da amostra. Para a estimação dos modelos e testes estatísticos realizados neste artigo lançou-se mão dos seguintes softwares: *Oxmetrics* 6.2, *Eviews* 7 e R versão 3.1.2.

A Tabela 8 apresenta as estatísticas descritivas dos retornos logarítmicos diários para os índices selecionados. Como as distribuições dos retornos de todos os índices apresentaram curtose acima de 3 e a maioria delas apresentou assimetria negativa, reforçou-se a ideia da utilização das distribuições *t* de *Student*, GED e *t* de *Student* assimétrica, além da distribuição normal por ser mais parcimoniosa. Os resultados do teste de Jarque-Bera indicam que nenhuma série de retornos logarítmicos segue uma distribuição Gaussiana. O teste estatístico de Box-Pierce, $Q^2(20)$, de ordem 20 para o quadrado dos retornos indica que esses são autocorrelacionados para todos os países emergentes analisados, já que a hipótese nula de não autocorrelação é significativamente rejeitada para todos os índices. O teste LM-ARCH de ordem 10 confirma essa ocorrência ao rejeitar a hipótese nula de ausência de efeito ARCH para os retornos dos índices analisados. O teste expandido de Dickey-Fuller (ADF) tem como hipótese nula a existência de raiz unitária. Essa hipótese foi rejeitada para todos os índices estudados.

Tabela 8: Estatísticas Descritivas

Índice	IBOV	JALSH	MICEX	SENSEX	SHCOMP	XU100
Observações	3958	3993	3958	3984	3862	3997
Média	0,000502	0,000574	0,000868	0,000549	0,000267	0,000864
Mediana	0,000813	0,000786	0,001324	0,001104	0,000516	0,000960
Desvio Padrão	0,019397	0,012357	0,023553	0,015978	0,015885	0,023770
Assimetria	0,716640	-0,169195	-0,045302	-0,138447	-0,061932	0,155791
Curtose	18,274	6,6139	14,071	9,3316	7,2123	9,8033
Jarque-Bera	38815,8 [0,000]**	2192,0 [0,000]**	20218,1 [0,000]**	6667,6 [0,000]**	2857,7 [0,000]**	7724,7 [0,000]**
LM-ARCH (10)	59,966 [0,000]**	91,299 [0,000]**	65,084 [0,000]**	50,569 [0,000]**	33,136 [0,000]**	35,005 [0,000]**
$Q^2(20)$	583,244 [0,000]**	3450,95 [0,000]**	2781,07 [0,000]**	1482,10 [0,000]**	969,346 [0,000]**	394,447 [0,000]**
ADF	-37,93 [0,000]**	-37,64 [0,000]**	-37,60 [0,000]**	-36,60 [0,000]**	-34,5 [0,000]**	-36,35 [0,000]**

Fonte: Própria

LM-ARCH (10) representa o teste LM de ordem 10 proposto por Engle para detectar a presença de efeito ARCH. $Q^2(20)$ representa o teste de Box-Pierce de ordem 20 para o quadrado dos retornos. Números entre colchetes representam os p-valores. ADF representa o teste expandido de Dickey-Fuller.

3.4 Resultados

3.4.1 Testes para detecção de presença de memória longa

A volatilidade diária foi calculada pelo quadrado dos retornos logarítmicos dos índices de ações dos países emergentes. Para testar a existência de um processo de memória longa para a volatilidade foram utilizados o teste de Lo (1991) e o teste GPH de Gewek e Porter-Hudak (1983). A Tabela 9 apresenta os resultados desses testes. Pode-se observar que ambos indicam a rejeição da hipótese nula de ausência de memória longa, sugerindo que, para os mercados analisados, há persistência da volatilidade ao longo do tempo. Esse resultado alinha-se ao padrão encontrado para as funções de autocorrelação dos quadrados dos retornos dos índices (Figura 1), as quais exibem decaimento lento, sugerindo um decaimento hiperbólico, típico de processos de memória longa.

Tabela 9: Resultados dos Testes de Memória Longa

	IBOV	JALSH	MICEX	SENSEX	SHCOMP	XU100
Parâmetro de memória longa, d, do teste GPH (1983) $m=T/2$	0,1531	0,1381	0,1206	0,1500	0,0959	0,2173
	[0,000]**	[0,000]**	[0,000]**	[0,000]**	[0,000]**	[0,000]**
Estatística do Teste de Lo (1991)	1,8882*	3,7123**	3,8990**	3,2031**	4,5411**	4,5407**

Fonte: Própria

Notas: O parâmetro m representa a largura de banda (*bandwith*) do teste proposto por Geweke e Porter-Hudak's (1983) e T representa o número de observações. O parâmetro q indica o número de autocorrelações do teste proposto por Lo (1991).

(*) Significância a 5%

(**) Significância a 1%

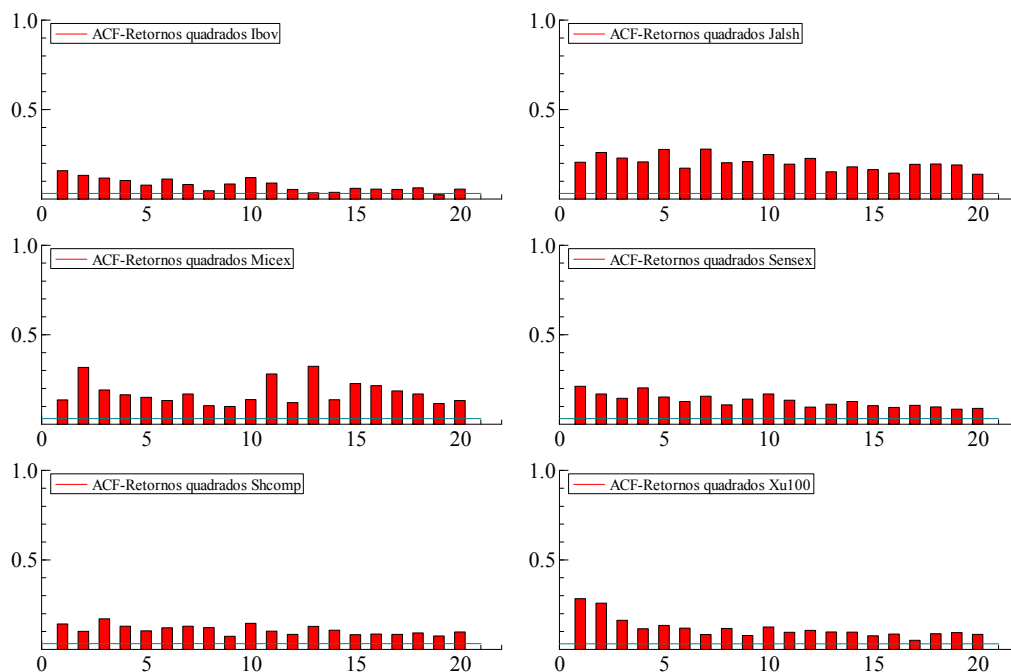


Figura 1 - Função de Autocorrelação (ACF) para o quadrado dos retornos dos países emergentes.

Fonte: Elaboração própria

3.4.2 Estimação (dentro da amostra) dos modelos GARCH e FIGARCH

Com o propósito de se verificar quais modelos proporcionam a melhor descrição dos dados, foram estimados, uma única vez e utilizando todas as observações disponíveis (\widehat{T}), os modelos (*dentro da amostra*) FIGARCH(1,d,1) e GARCH(1,1) para os retornos dos índices dos países emergentes, considerando-se quatro distribuições distintas para os erros: normal, t de *Student*, GED e t de *Student* assimétrica. Os resultados são apresentados nas Tabelas 10A-10F.

Tabela 10A: IBOV– Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal(n), t de *Student* (t), GED e t de *Student* assimétrica (skt).

IBOV								
Painel A – Parâmetros Estimados	FIGARCH(1,d,1)				GARCH(1,1)			
Distribuição	n	t	ged	skt	n	t	ged	skt
C média	0,0007 [0,0039] **	0,0007 [0,0015] **	0,0007 [0,0016] **	0,0006 [0,0147] *	0,0007 [0,0043] **	0,0007 [0,0023] **	0,007 [0,0020] **	0,006 [0,0156] *
AR(1)	0,005 0,7419	0,0078 0,5981	0,0038 0,7977	0,00078 0,9581	0,0016 0,9244	0,0055 0,7221	0,00057 0,9713	-0,0014 0,9244
C Variância	0,000 [0,2244]	0,000 [0,1231]	0,000 [0,1813]	0,000 [0,1197]	0,000 [0,0015] **	0,000 [0,0005] **	0,000 [0,0007] **	0,000 [0,0006] **
ARCH	0,0663 [0,4509]	0,0639 [0,2498]	0,0591 [0,3924]	0,0682 [0,2065]	0,0868 [0,0000] **	0,0716 [0,0000] **	0,0796 [0,0000] **	0,0706 [0,0000] **
GARCH	0,4791 [0,004]*	0,5193 [0,000]**	0,4952 [0,000]**	0,5249 [0,000]**	0,8898 [0,000]**	0,9091 [0,000]**	0,8986 [0,000]**	0,9111 [0,000]**
d- FIGARCH	0,4671 [0,000]*	0,4828 [0,000]**	0,4759 [0,000]**	0,4849 [0,000]**				
<i>Student</i> -df		10,0565 [0,000]**	1,5790 [0,000]**	10,4263 [0,000]**		10,9241 [0,000]**	1,5861 [0,000]**	11,3019 [0,000]**
Assimetria				-0,0743 [0,0023] **				-0,0724 [0,0019] **
Painel B Testes Diagnóstico								
AIC	-5,287717	-5,305562	-5,300934	-5,307450	-5,283931	-5,302292	-5,297801	-5,304252
SBC	-5,278192	-5,294450	-5,289822	-5,294749	-5,275993	-5,292767	-5,288276	-5,293139
Q ² (10)	7,5526 [0,4783]	11,1720 [0,1921]	15,5190 [0,6261]	11,1255 [0,1947]	14,4439 [0,0709]	24,3545 [0,0019] **	27,1957 [0,0753]	24,7586 [0,0017] **
LM- ARCH (10)	1,1277 [0,3367]	1,1632 [0,3108]	1,0886 [0,3668]	1,1569 [0,3153]	1,3696 [0,1878]	1,5924 [0,1023]	1,4184 [0,1652]	1,5977 [0,1008]
SBT	1,11566 [0,2646]	1,4178 [0,1562]	1,2843 [0,1990]	1,41766 [0,1562]	1,22172 [0,2218]	1,55327 [0,1203]	1,34817 [0,1776]	1,56311 [0,1180]

Fonte: Própria

LM-ARCH(10) representa o teste LM de ordem 10 proposto por Engle para detectar a presença de efeito ARCH. Q²(10) representa o teste de Box-Pierce de ordem 10 para o quadrado dos retornos. Números entre colchetes representam os *p-valores*. SBT representa o *Sign Bias Test* proposto por Engle e Ng (1993) para detectar a presença do efeito de alavancagem nos retornos.

Tabela 10B: JALSH– Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal(n), t de *Student* (t), GED e t de *Student* assimétrica (skt).

JALSH								
Painel A – Parâmetros Estimados	FIGARCH(1,d,1)				GARCH(1,1)			
Distribuição	n	t	ged	skt	n	t	ged	skt
C média	0,0008 [0,000]*	0,0008 [0,000]*	0,0009 [0,000]*	0,0007 [0,000]**	0,0009 [0,000]**	0,0008 [0,000]**	0,0009 [0,000]**	0,0008 [0,000]**
AR(1)	0,0530 [0,0011]**	0,0481 [0,0026]**	0,0472 [0,0040]**	0,0409 [0,0103]*	0,0517 [0,0015]**	0,0476 [0,0029]*	0,0462 [0,0049]*	0,0411 [0,0103]*
C Variância	0,0003 [0,0304]	0,0002 [0,0267]	0,0003 [0,0275]	0,0003 [0,0310]*	0,0000 [0,0001]**	0,0000 [0,0001]*	0,0000 [0,0001]*	0,0000 [0,0001]*
ARCH	0,1272 [0,0101]*	0,1358 [0,0014]**	0,1322 [0,0044]**	0,1348 [0,0011]*	0,0970 [0,0000]**	0,0916 [0,0000]*	0,0942 [0,0000]*	0,0898 [0,0000]*
GARCH	0,6058 [0,0007]**	0,6127 [0,0000]**	0,6069 [0,0000]**	0,6255 [0,0000]*	0,0116 [0,0000]**	0,8950 [0,0000]*	0,8919 [0,0000]*	0,8972 [0,0000]*
d- FIGARCH	0,5422 [0,0000]**	0,5322 [0,0000]**	0,5355 [0,0000]**	0,5457 [0,0000]*				
<i>Student</i> -df		12,0529 [0,0000]**	1,6640 [0,0000]**	12,4363 [0,0000]*		12,4198 [0,0000]*	1,6678 [0,0000]*	12,8299 [0,0000]*
Assimetria				-0,0802 [0,0013]*				-0,0765 [0,0017]*
Painel B – Testes Diagnósticos								
AIC	-6,211298	-6,222938	-6,219385	-6,225228	-6,210960	-6,221784	-6,218873	-6,223913
SBC	-6,201843	-6,211908	-6,208354	-6,212621	-6,203081	-6,212329	-6,209418	-6,212883
Q ² (10)	9,24672 [0,9537]	9,4963 [0,9471]	9,28085 [0,9528]	9,5355 [0,9460]	9,17303 [0,9555]	9,6087 [0,9434]	9,3287 [0,9516]	9,8335 [0,9372]
LM- ARCH (10)	0,5667 [0,8423]	0,6206 [0,7975]	0,5783 [0,8330]	0,6208 [0,7974]	0,6107 [0,8061]	0,6584 [0,7639]	0,6260 [0,7928]	0,6689 [0,7543]
SBT	0,2473 [0,8047]	0,0987 [0,9214]	0,2109 [0,8330]	0,0927 [0,9252]	0,0658 [0,9475]	0,0722 [0,9425]	0,0580 [0,9537]	0,2090 [0,8345]

Fonte: Própria

LM-ARCH(10) representa o teste LM de ordem 10 proposto por Engle para detectar a presença de efeito ARCH. Q²(10) representa o teste de Box-Pierce de ordem 10 para o quadrado dos retornos. Números entre colchetes representam os *p-valores*. SBT representa o *Sign Bias Test* proposto por Engle e Ng (1993) para detectar a presença do efeito de alavancagem nos retornos.

Tabela 10C: MICEX– Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal(n), t de *Student* (t), GED e t de *Student* assimétrica (skt).

MICEX								
Painel A – Parâmetros Estimados	FIGARCH(1,d,1)				GARCH(1,1)			
Distribuição	n	t	ged	skt	n	t	ged	skt
C média	0,0012 [0,0000] **	0,0012 [0,0000] **	0,0012 [0,0000] **	0,0009 [0,0000] **	0,0012 [0,0000] **	0,0012 [0,0000] **	0,0012 [0,0000] **	0,0009 [0,0000] **
AR(1)	0,0295 [0,0849]	0,0289 [0,0641]	0,0194 [0,0976]	0,0235 [0,1338]	0,0305 [0,0814]	0,0282 [0,0764]	0,0188 [0,2652]	0,0233 [0,1471]
C Variância	0,0017 [0,0617]	0,0027 [0,1180]	0,0021 [0,1148]	0,0026 [0,1407]	0,0001 [0,0150] *	0,0005 [0,0007] **	0,0006 [0,0015] **	0,0000 [0,0010] **
ARCH	-0,1675 [0,5128]	0,0703 [0,2239]	0,0159 [0,8656]	0,0730 [0,2374]	0,1118 [0,0000] **	0,1016 [0,0000] **	0,1027 [0,0000] **	0,0982 [0,0000] **
GARCH	0,2538 [0,4174]	0,5948 [0,0000] **	0,5041 [0,0010] **	0,5886 [0,0000] **	0,8698 [0,0000] **	0,8924 [0,0000] **	0,8863 [0,0000] **	0,8957 [0,0000] **
d- FIGARCH	0,4921 [0,0000] **	0,5968 [0,0000] **	0,5550 [0,0000] **	0,5897 [0,0000] **				
<i>Student</i> -df		5,9838 [0,0000] **	1,3300 [0,0000] **	6,0466 [0,0000] **		6,2311 [0,0000] **	1,3298 [0,0000] **	6,3308 [0,0000] **
Assimetria				-0,0732 [0,0016] **				-0,0693 [0,0018] **
Painel B – Testes Diagnóstic os								
AIC	-5,081627	-5,143016	-5,132305	-5,145059	-5,072101	-5,137511	-5,127032	-5,134433
SBC	-5,072101	-5,131903	-5,121193	-5,132359	-5,064163	-5,127986	-5,117507	-5,128321
Q ² (10)	3,4585 [0,9999]	3,3025 [0,9999]	2,8569 [0,9999]	3,2070 [0,9999]	6,8261 [0,9915]	7,3725 [0,9865]	7,4461 [0,9857]	7,2527 [0,9878]
LM-ARCH (10)	0,1506 [0,9989]	0,2079 [0,9957]	0,1528 [0,9988]	0,2030 [0,9961]	0,4048 [0,9450]	0,3998 [0,9473]	0,4195 [0,9380]	0,3988 [0,9478]
SBT	1,3086 [0,1907]	1,3320 [0,1829]	1,3734 [0,1696]	1,3146 [0,1886]	0,9068 [0,3645]	1,2133 [0,2250]	1,0598 [0,2893]	1,2318 [0,2180]

Fonte: Própria

LM-ARCH(10) representa o teste LM de ordem 10 proposto por Engle para detectar a presença de efeito ARCH. Q²(10) representa o teste de Box-Pierce de ordem 10 para o quadrado dos retornos. Números entre colchetes representam os *p-valores*. SBT representa o *Sign Bias Test* proposto por Engle e Ng (1993) para detectar a presença do efeito de alavancagem nos retornos.

Tabela 10D: SENSEX– Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal(n), t de *Student* (t), GED e t de *Student* assimétrica (skt).

SENSEX								
Painel A – Parâmetros Estimados	FIGARCH(1,d,1)				GARCH(1,1)			
Distribuição	n	t	ged	skt	n	t	ged	skt
C média	0,0011 [0,0000] **	0,0011 [0,0000] **	0,0011 [0,0000] **	0,0009 [0,0000] **	0,0010 [0,0000] **	0,0011 [0,0000] **	0,0011 [0,0000] **	0,0009 [0,0000] **
AR(1)	0,0811 [0,0000] **	0,0792 [0,0000] **	0,0802 [0,0000] **	0,0723 [0,0000] **	0,0782 [0,0000] **	0,0785 [0,0000] **	0,0791 [0,0000] **	0,0709 [0,0000] **
C Variância	0,0008 [0,0000] **	0,0008 [0,0155] *	0,0008 [0,0264] *	0,0008 [0,0183] *	0,0000 [0,0035] **	0,0000 [0,0000] **	0,0000 [0,0000] **	0,0000 [0,0000] **
ARCH	0,1217 [0,0425] *	0,1008 [0,0443] *	0,1087 [0,0413] *	0,1087 [0,0297] *	0,1131 [0,0000] **	0,1117 [0,0000] **	0,1112 [0,0000] **	0,1093 [0,0000] **
GARCH	0,5551 [0,0000] **	0,5744 [0,0000] **	0,5699 [0,0000] **	0,5831 [0,0000] **	0,8734 [0,0000] **	0,8745 [0,0000] **	0,8750 [0,0000] **	0,8766 [0,0000] **
d- FIGARCH	0,5498 [0,0000] **	0,5669 [0,0000] **	0,5644 [0,0000] **	0,5697 [0,0000] **				
<i>Student</i> -df		7,5991 [0,0000] **	1,4563 [0,0000] **	7,6930 [0,0000] **		7,7625 [0,0000] **	1,4488 [0,0000] **	7,8988 [0,0000] **
Assimetria				-0,0606 [0,0095] **				-0,0628 [0,0062] **
Painel B – Testes Diagnóstic os								
AIC	-5,771336	-5,802476	-5,747820	-5,803700	-5,764035	-5,799349	-5,793697	-5,800774
SBC	-5,761863	-5,791424	-5,786768	-5,791069	-5,756141	-5,789876	-5,784224	-5,789722
Q ² (10)	15,2544 [0,6444]	16,7186 [0,5425]	15,9315 [0,5973]	16,9275 [0,5280]	18,9347 [0,3958]	19,1785 [0,3809]	19,3355 [0,3714]	19,6588 [0,3523]
LM-ARCH (10)	0,5950 [0,8193]	0,7281 [0,6986]	0,6543 [0,7677]	0,7437 [0,6836]	0,9363 [0,4982]	0,9604 [0,4760]	0,9706 [0,4669]	0,9977 [0,4427]
SBT	0,4560 [0,6484]	0,3994 [0,6896]	0,4153 [0,6779]	0,5053 [0,6134]	0,6073 [0,5436]	0,5703 [0,5685]	0,5722 [0,5672]	0,6714 [0,5019]

Fonte: Própria

LM-ARCH(10) representa o teste LM de ordem 10 proposto por Engle para detectar a presença de efeito ARCH. Q²(10) representa o teste de Box-Pierce de ordem 10 para o quadrado dos retornos. Números entre colchetes representam os *p-valores*. SBT representa o *Sign Bias Test* proposto por Engle e Ng (1993) para detectar a presença do efeito de alavancagem nos retornos.

Tabela 10E: SHCOMP– Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal(n), t de *Student* (t), GED e t de *Student* assimétrica (skt).

SHCOMP								
Painel A Parâmetros Estimados	FIGARCH(1,d,1)				GARCH(1,1)			
Distribuição	n	t	ged	skt	n	t	ged	skt
C média	0,0002 [0,1981]	0,0003 [0,0743]	0,0004 [0,0157]	0,0002 [0,4105]	0,0002 [0,2745]	0,0003 [0,1003]	0,0004 [0,0245]	0,00011 [0,6036]
AR(1)	0,0179 [0,3186]	0,0172 [0,2630]	0,0067 [0,6045]	0,0158 [0,2993]	0,0181 [0,3054]	0,0194 [0,1903]	0,0078 [0,4550]	0,0173 [0,2393]
C Variância	0,0002 [0,0081]*	0,0003 [0,0024]*	0,0002 [0,0042]*	0,0002 [0,0025]*	0,0000 [0,0022]*	0,0000 [0,0008]*	0,0000 [0,0007]*	0,0000 [0,0006]*
ARCH	0,1938 [0,0290]*	0,1781 [0,0077]*	0,1740 [0,0105]*	0,1849 [0,0072]*	0,0823 [0,0000]*	0,0740 [0,0000]*	0,0754 [0,0000]*	0,0752 [0,0000]*
GARCH	0,5617 [0,0000]*	0,5692 [0,0000]*	0,5677 [0,0000]*	0,5714 [0,0000]*	0,9059 [0,0000]*	0,9169 [0,0000]*	0,9130 [0,0000]*	0,9158 [0,0000]*
d- FIGARCH	0,4293 [0,0000]*	0,4262 [0,0000]*	0,4338 [0,0000]*	0,4257 [0,0000]*				
<i>Student</i> - df		5,2595 [0,0000]*	1,2186 [0,0000]*	5,2579 [0,0000]*		4,9716 [0,0000]*	1,2141 [0,0000]*	4,9658 [0,0000]*
Assimetria				-0,040 [0,0341]*				-0,0472 [0,0140]*
Painel B Testes Diagnóstico								
AIC	- 5,670590	- 5,737568	- 5,742188	- 5,738068	- 5,669957	- 5,736760	- 5,741094	- 5,737581
SBC	- 5,660866	- 5,726224	- 5,730843	- 5,725103	- 5,661854	- 5,727036	- 5,731370	- 5,726237
Q ² (10)	2,7548 [0,9487]	3,0352 [0,9321]	2,78201 [0,9472]	2,8862 [0,9413]	1,8682 [0,9848]	1,9822 [0,9816]	1,8236 [0,9859]	1,8518 [0,9852]
LM- ARCH (10)	0,2707 [0,9875]	0,2980 [0,9818]	0,2721 [0,9872]	0,2832 [0,9851]	0,1824 [0,9975]	0,1949 [0,9967]	0,1390 [0,9977]	0,1820 [0,9975]
SBT	1,2203 [0,2224]	1,0001 [0,3173]	1,1454 [0,2520]	0,9344 [0,3500]	1,0105 [0,3122]	0,9304 [0,3521]	0,8478 [0,3965]	0,8125 [0,4165]

Fonte: Própria

LM-ARCH(10) representa o teste LM de ordem 10 proposto por Engle para detectar a presença de efeito ARCH. Q²(10) representa o teste de Box-Pierce de ordem 10 para o quadrado dos retornos. Números entre colchetes representam os *p-valores*. SBT representa o *Sign Bias Test* proposto por Engle e Ng (1993) para detectar a presença do efeito de alavancagem nos retornos.

Tabela 10F: XU100– Estimação dos modelos FIGARCH(1,d,1) e GARCH(1,1) para as quatro distribuições: normal(n), t de *Student* (t), GED e t de *Student* assimétrica (skt).

XU100								
Painel A Parâmetros Estimados	FIGARCH(1,d,1)				GARCH(1,1)			
Distribuição	n	t	ged	skt	n	t	ged	skt
C média	0,0013 [0,0000] **	0,0013 [0,0000] **	0,0013 [0,0000] **	0,0012 [0,0000] **	0,0012 [0,0000] **	0,0012 [0,0000] **	0,0012 [0,0000] **	0,0011 [0,0000] **
AR(1)	0,0245 [0,1324]	[0,0159]* 0,3038	[0,0133]* 0,4152	[0,0136]* 0,3877	[0,0243]* 0,1595	[0,0152]* 0,3431	[0,0127]* 0,4434	[0,0126]* 0,4380
C Variância	0,0018 [0,1564]	0,0011 [0,1530]	0,0013 [0,1497]	0,0011 [0,1571]	0,0000 [0,0353]*	0,0000 [0,0043]*	0,0000 [0,0107]*	0,0000 [0,0039]*
ARCH	0,1439 [0,0587]	0,1451 [0,1051]	0,1438 [0,0634]	0,1514 [0,0858]	0,0903 [0,0000]*	0,0885 [0,0000]*	0,0897 [0,0000]*	0,0882 [0,0000]*
GARCH	0,5413 [0,0000]*	0,4964 [0,0000]*	0,5175 [0,0000]*	0,5031 [0,0000]*	0,9041 [0,0000]*	0,9030 [0,0000]*	0,9026 [0,0000]*	0,9031 [0,0000]*
d- FIGARCH	0,5199 [0,0000]*	0,4652 [0,0000]*	0,4916 [0,0000]*	0,4663 [0,0000]*				
<i>Student</i> -df		6,3470 [0,0000]*	0,5175 [0,0000]*	6,3864 [0,0000]*		6,5032 [0,0000]*	1,3755 [0,0000]*	6,5489 [0,0000]*
Assimetria				-0,0267 [0,2540]				-0,0285 [0,2063]
Painel B – Testes Diagnóstic os								
AIC	- 4,983586	- 5,029359	- 5,021659	- 5,029187	- 4,969274	- 5,022130	- 5,013369	- 5,022033
SBC	- 4,974139	- 5,018337	- 5,010638	- 5,016591	- 4,961401	- 5,012683	- 5,003922	- 5,011001 1
$Q^2(10)$	14,4629 [0,0704]	13,9955 [0,0819]	14,2409 [0,0756]	13,5715 [0,0936]	10,6319 [0,2234]	11,1826 [0,1915]	10,7035 [0,2190]	11,0390 [0,1995]
LM- ARCH (10)	1,4049 [0,1712]	1,3779 [0,1838]	1,3906 [0,1778]	1,3363 [0,2046]	1,0745 [0,3780]	1,1312 [0,3341]	1,0830 [0,3712]	1,1167 [0,3450]
SBT	1,4327 [0,1520]	1,4168 [0,1565]	1,4357 [0,1511]	1,5354 [0,1247]	1,4888 [0,1365]	1,3275 [0,1843]	1,3270 [0,1845]	1,1994 [0,2304]

Fonte: Própria

LM-ARCH(10) representa o teste LM de ordem 10 proposto por Engle para detectar a presença de efeito ARCH. $Q^2(10)$ representa o teste de Box-Pierce de ordem 10 para o quadrado dos retornos. Números entre colchetes representam os *p-valores*. SBT representa o *Sign Bias Test* proposto por Engle e Ng (1993) para detectar a presença do efeito de alavancagem nos retornos.

O painel A apresenta os parâmetros estimados para cada modelo. Verifica-se que o parâmetro d-FIGARCH, o qual captura a informação de memória longa, é significativa para todos os modelos FIGARCH estimados e para todas as distribuições de erros utilizadas.

O painel B apresenta os testes diagnósticos dos modelos estimados (*dentro da amostra*). Para detectar a presença de autocorrelação dos quadrados dos resíduos dos modelos estimados foram utilizados os testes de Box-Pierce ($Q^2(10)$) e LM-ARCH de ordem 10. A hipótese nula de não autocorrelação dos quadrados dos resíduos não foi rejeitada para nenhum modelo FIGARCH para nenhum dos dois testes utilizados. Todavia, na Tabela 3A, ao utilizar-se o teste Box-Pierce ($Q^2(10)$) para o modelo GARCH com distribuições *t* de *Student* e *t* de *Student* assimétrica, rejeitou-se a hipótese nula de não autocorrelação dos quadrados dos resíduos para os retornos do índice IBOV.

Além disso, o painel B mostra os resultados do teste *Sign Bias Test* (SBT) proposto por Engle e Ng (1993) para detectar a presença do efeito de alavancagem nos retornos, isto é, a estatística SBT testa se os impactos na volatilidade causados por retornos negativos são maiores que os impactos causados por retornos positivos. A hipótese nula do teste é de que não há diferença entre os impactos causados por retornos positivos e negativos. Nota-se que essa hipótese nula não é rejeitada para nenhum modelo, indicando que não há a presença do efeito de alavancagem e, portanto, não seria necessária a utilização de modelos que procuram capturar tal efeito, como é o caso, por exemplo, dos modelos FIEGARCH e EGARCH.

Ademais, foram utilizados os critérios de informação de Akaike (AIC) e Schwartz (SBC) para avaliar o melhor modelo usando as observações de retornos *dentro da amostra*. Os menores valores para os critérios de informação AIC e SBC para cada índice encontram-se em negrito. Nota-se que para o critério AIC o modelo de memória longa, FIGARCH, superou o modelo de memória curta, GARCH, para todos os índices estudados. Já pelo critério SBC, o modelo com especificação FIGARCH superou o modelo GARCH em 4 dos 6 índices analisados, as exceções para esse padrão ocorreram para os índices JALSH e SHCOMP.

Esses resultados sugerem a supremacia dos modelos de memória longa em relação aos de memória curta quando esses modelos são estimados com observações *dentro da amostra*.

3.4.3 Avaliação das previsões de VaR para um e múltiplos passos à frente para observações fora da amostra

Avaliação pelo critério dos testes de Kupiec e Christoffersen

As Tabelas 11A a 11D mostram as previsões do VaR para um passo à frente para os modelos FIGARCH(1,d,1) e GARCH(1,1), relativas aos seis índices analisados, considerando-se quatro distribuições estatísticas diferentes para os erros: normal (n), t de *Student* (t), distribuição normal generalizada (ged) e t de *Student* assimétrica (skt). No geral, a utilização dos modelos de memória longa (FIGARCH) para as volatilidades condicionais não melhora a precisão das previsões de VaR dos índices para o horizonte de tempo de 1 passo à frente, já que pelo teste de Kupiec (1995), dos 24 modelos FIGARCH e 24 modelos GARCH, 14 e 13 não foram rejeitados para as especificações FIGARCH e GARCH, respectivamente. Ademais, os resultados parecem corroborar com o contido na literatura sobre o assunto de que os modelos VaR não são robustos para os diferentes mercados, de forma que o modelo ótimo varia de um índice para outro (DEGIANNAKIS *et al.*, 2013; ANGELIDIS *et al.*, 2004; MCMILLAN e KAMBOUROUDIS, 2009).

Tabela 11A: Resultados das previsões de VaR e ES para 1 passo à frente – distribuição normal (n)

Índice	Nº de previsões de VaR 1 passo à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-valor)	Christoffersen (p-value)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-n (1,d,1)							
IBOV	1958	-2,7306	5,6691	0,183129	0,571556	-3,4486	0,007741
JALSH	1993	-1,8494	6,2218	0,006904**	0,399730	-2,3411	0,003597
MICEX	1958	-3,0354	5,1583	0,749074	0,280071	-3,8421	0,042512
SENSEX	1984	-2,2461	5,5948	0,232567	0,594816	-2,8470	0,007647
SHCOMP	1862	-2,5977	5,6391	0,214569	0,973732	-3,2652	0,012339
XU100	1997	-2,7113	5,1077	0,825866	0,229228	-3,4347	0,015399
Part B. ARMA(1,0) – GARCH-n (1,1)							
IBOV	1958	-2,7201	4,6476	0,469258	0,509563	-3,4364	0,004706
JALSH	1993	-1,8553	6,4727	0,003837**	0,553206	-2,3493	0,003743
MICEX	1958	-3,0117	4,8519	0,762551	0,414707	-3,8142	0,041593
SENSEX	1984	-2,2406	5,2923	0,553798	0,212809	-2,8401	0,008687
SHCOMP	1862	-2,6265	5,1557	0,768946	0,629745	-3,3005	0,012573
XU100	1997	-2,7850	4,6069	0,414300	0,195216	-3,5259	0,014479

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Tabela 11B: Resultados das previsões de VaR e ES para 1 passo à frente – distribuição t de *Student(t)*

Índice	Nº de previsões de VaR 1 passo à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-value)	Christoffersen (p-valor)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-t (1,d,1)							
IBOV	1958	-2,9790	4,3412	0,171583	0,868479	-3,9821	0,006529
JALSH	1993	-1,9628	5,6197	0,212880	0,280206	-2,5786	0,003252
MICEX	1958	-3,5767	3,3708	0,000454**	0,353763	-5,0497	0,026267
SENSEX	1984	-2,5370	4,1331	0,068118	0,821596	-3,4800	0,004903
SHCOMP	1862	-3,0868	3,7057	0,007345**	0,779732	-4,3563	0,006546
XU100	1997	-3,1318	3,5553	0,001827*	0,014867*	-4,3084	0,011162
Part B. ARMA(1,0) – GARCH-t (1,1)							
IBOV	1958	-2,9728	2,7068	0,0000**	0,646588	-3,9656	0,003801
JALSH	1993	-1,9676	5,4190	0,396870	0,949811	-2,5874	0,002745
MICEX	1958	-3,5542	3,1665	0,0000**	0,447513	-5,0137	0,023844
SENSEX	1984	-2,5464	4,1331	0,068118	0,396166	-3,4957	0,006028
SHCOMP	1862	-3,2011	3,5983	0,003552**	0,704533	-4,5852	0,007915
XU100	1997	-3,1850	3,1547	0,0000**	0,016231*	-4,3698	0,010948

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Tabela 11C: Resultados das previsões de VaR e ES para 1 passo à frente – distribuição ged

Índice	Nº de previsões de VaR 1 passo à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p- valor)	Christoffersen (p-value)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-ged (1,d,1)							
IBOV	1958	-2,7231	5,8223	0,103342	0,481664	-3,5854	0,008358
JALSH	1993	-1,8480	6,3723	0,006904**	0,298100	-2,3908	0,003571
MICEX	1958	-3,0198	5,2094	0,672750	0,545583	-4,1181	0,040374
SENSEX	1984	-2,2412	5,4940	0,320037	0,660007	-2,9991	0,006906
SHCOMP	1862	-2,5741	5,7465	0,148401	0,947944	-3,5332	0,010772
XU100	1997	-2,7297	4,9074	0,848911	0,322754	-3,6448	0,014240
Part B. ARMA(1,0) – GARCH-ged (1,1)							
IBOV	1958	-2,7194	4,5965	0,406550	0,538807	-3,5796	0,004957
JALSH	1993	-1,8514	6,4727	0,003837**	0,553206	-2,3980	0,003705
MICEX	1958	-2,9902	4,8519	0,762551	0,414707	-4,0811	0,036773
SENSEX	1984	-2,2356	5,3427	0,488245	0,437367	-2,9947	0,007909
SHCOMP	1862	-2,5867	5,4243	0,407018	0,817288	-3,5585	0,100828
XU100	1997	-2,7937	4,5568	0,356586	0,177954	-3,7334	0,013605

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Tabela 11D: Resultados das previsões de VaR e ES para 1 passo à frente – distribuição t de *Student* assimétrica (skt)

Índice	Nº de previsões de VaR 1 passo à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-valor)	Christoffersen (p-value)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-skt (1,d,1)							
IBOV	1958	-3,1271	3,7794	0,009732**	0,602501	0,0443	0,152321
JALSH	1993	-2,0571	4,6663	0,489638	0,215345	0,0508	0,072490
MICEX	1958	-3,8056	2,7579	0,0000**	0,661490	0,0458	0,229629
SENSEX	1984	-2,6717	3,5786	0,002258**	0,771710	0,0690	0,101527
SHCOMP	1862	-3,2314	3,4374	0,001070**	0,595820	-0,0875	0,130866
XU100	1997	-3,1910	3,4552	0,000818**	0,010733*	0,0528	0,145081
Part B. ARMA(1,0) – GARCH-skt (1,1)							
IBOV	1958	-3,1079	2,4515	0,000**	0,477870	0,0388	0,127970
JALSH	1993	-2,0602	4,7165	0,557861	0,449499	0,0565	0,074808
MICEX	1958	-3,7235	2,9622	0,0000**	0,555699	0,0600	0,247496
SENSEX	1984	-2,6657	3,5786	0,002258**	0,256328	0,0584	0,105983
SHCOMP	1862	-3,3781	3,1686	0,000106**	0,922916	-0,1108	0,119948
XU100	1997	-3,2445	3,1047	0,0000**	0,013806*	0,0439	0,139908

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

De acordo com o teste de Kupiec (1995), a taxa de violação observada não é estatisticamente diferente da taxa de violação esperada (5%) para as previsões de VaR para 1 passo à frente para ambos os modelos FIGARCH e GARCH relativos aos seguintes índices: IBOV (normal e ged), JALSH (t e skt), MICEX (normal e ged), SENSEX (normal, t e ged), SHCOMP (normal e ged) e XU100 (normal e ged). O mesmo ocorre para o índice IBOV (t) somente para o modelo FIGARCH.

As Tabelas 10A a 10D apresentam os resultados de 48 modelos. Para 28 desses modelos (58%) houve superestimação do VaR verdadeiro, já que a taxa observada de violação do VaR foi menor que a taxa esperada de violação (5%), ocorrendo o maior número de exceções a esse padrão nos modelos FIGARCH (normal e ged) e GARCH (normal e ged). Esses resultados são conflitantes com os obtidos por Kuester *et al.*(2006), os quais reportaram que a maioria dos modelos de VaR sofrem de violação excessiva por subestimarem sistematicamente o VaR verdadeiro. Degiannakis *et al.*(2013) chegaram a mesma conclusão ao utilizar somente a distribuição normal para os erros. Portanto, os resultados deste artigo estão de acordo com o encontrado por Degiannakis *et al.*(2013) apenas para as distribuições normal e ged, já que há uma predominância de superestimação do VaR para as demais distribuições (t e skt).

Pelo teste de Christoffersen (1998), as violações do VaR são independentemente distribuídas em relação à maioria dos índices de ações para os modelos FIGARCH e GARCH, com exceção do índice XU100 para os modelos FIGARCH e GARCH com distribuições t e skt . Todavia, apesar da limitada evidência de não independência das violações de VaR, Degiannakis *et al.* (2013) apontam que os resultados do teste de Christoffersen apresentam menor prioridade que resultados do teste de Kupiec, os quais, para efeitos deste estudo, sugerem uma superestimação do VaR para a maioria dos modelos.

As Tabelas 12A a 12D apresentam os resultados para as previsões de VaR para 10 passos à frente. Para este horizonte de previsão, os resultados do teste de Kupiec sugerem que o modelo de memória longa, FIGARCH, apresenta melhor desempenho que o modelo GARCH. De acordo com o referido teste, os modelos com especificação FIGARCH produziram uma taxa observada de violação estatisticamente não diferente da taxa esperada de violação de 5% para 18 dos 24 modelos FIGARCH, o que corresponde a 75% dos modelos. Já para os modelos com especificação GARCH, o mesmo ocorre para 16 dos 24 modelos, o que corresponde a 66,7% dos modelos. Todavia, destaca-se que ao remover os modelos da Tabela 5B com distribuição t (FIGARCH- t e GARCH- t), os quais foram reprovados no teste de Kupiec para todos os índices, a adequabilidade dos modelos passaria a 100% e a 88,9% para os modelos FIGARCH e GARCH, respectivamente. Ademais, percebe-se que a escolha da distribuição a ser utilizada para os erros afeta a decisão de escolha do modelo. Por exemplo, se a distribuição normal ou skt fosse utilizada para o índice SHCOMP, os modelos GARCH seriam rejeitados pelo teste de Kupiec, fato que não ocorreria com os modelos FIGARCH. Todavia, se as distribuições ged ou t fossem utilizadas, nenhum modelo FIGARCH seria escolhido em detrimento do GARCH. Os resultados do teste de Christoffersen sugerem que as violações do VaR não são independentemente distribuídas para 3 modelos FIGARCH. O mesmo ocorre para 9 dos modelos de memória curta, GARCH.

Tabela 12A: Resultados das previsões de VaR e ES para 10 passos à frente – distribuição normal (n)

Índice	Nº de previsões de VaR 10 passos à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-valor)	Christoffersen (p-value)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-n (1,d,1)							
IBOV	194	-3,4105	3,0928	0,191064	0,606035	-4,4774	0,002306
JALSH	198	-2,0499	5,0505	0,974029	0,514627	-2,7193	0,000626
MICEX	194	-4,2073	2,5773	0,089022	0,606035	-5,7164	0,006370
SENSEX	197	-2,8803	4,0609	0,532431	0,030028*	-3,9020	0,000603
SHCOMP	185	-2,6687	3,2432	0,242610	0,525738	-3,4664	0,000746
XU100	198	-4,1064	2,5253	0,078505	0,609814	-5,5087	0,000203
Part B. ARMA(1,0) – GARCH-n (1,1)							
IBOV	194	-3,0503	6,1856	0,464278	0,015496*	-3,9493	0,005941
JALSH	198	-1,9927	6,5657	0,333786	0,005005**	-2,6245	0,000905
MICEX	194	-3,8482	2,5773	0,089022	0,606035	-5,0983	0,006964
SENSEX	197	-2,7010	5,5838	0,711881	0,014792*	-3,6144	0,001224
SHCOMP	185	-30781	2,1622	0,046909*	0,673277	-4,0431	0,000352
XU100	198	-4,0369	2,5253	0,078505	0,609814	-5,2784	0,000222

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Tabela 12B: Resultados das previsões de VaR e ES para 10 passos à frente – distribuição t de Student (t)

Índice	Nº de previsões de VaR 10 passos à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-valor)	Christoffersen (p-value)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-t (1,d,1)							
IBOV	194	-10,5267	9,7938	0,006431**	0,0000*	-13,9230	0,001501
JALSH	198	-4,2846	0,0000	0,0000**	1,0000	-5,8971	0,000000
MICEX	194	-20,4399	0,0000	0,0000**	1,0000	-30,6424	0,000000
SENSEX	197	-10,5298	0,0000	0,0000**	1,0000	-15,4395	0,000000
SHCOMP	185	-20,5474	0,0000	0,0000**	1,0000	-30,8264	0,000000
XU100	198	-17,1620	0,0000	0,0000**	1,0000	-25,2143	0,000000
Part B. ARMA(1,0) – GARCH-t (1,1)							
IBOV	194	-4,7047	2,0619	0,034137*	0,721924	-6,4933	0,001936
JALSH	198	-3,1888	1,5152	0,008685**	0,760663	-4,4517	0,000180
MICEX	194	-15,4053	0,5155	0,000271**	0,918707	-23,7081	0,002806
SENSEX	197	-7,2974	0,0000	0,0000**	1,0000	-11,1261	0,000000
SHCOMP	185	-23,1886	0,0000	0,0000**	1,0000	-37,4530	0,000000
XU100	198	-13,6197	0,0000	0,0000**	1,0000	-20,4793	0,000000

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Tabela 12C: Resultados das previsões de VaR e ES para 10 passos à frente – distribuição ged

Índice	Nº de previsões de VaR 10 passos à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-valor)	Christoffersen (p-value)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-ged (1,d,1)							
IBOV	194	-3,4004	3,0928	0,191064	0,101465	-4,6599	0,001887
JALSH	198	-2,0163	5,5556	0,724335	0,125361	-2,7456	0,000663
MICEX	194	-4,0914	2,5773	0,089022	0,606035	-5,9581	0,005908
SENSEX	197	-2,8326	4,0609	0,532431	0,030028*	-4,0723	0,000690
SHCOMP	185	-2,5759	3,2432	0,242610	0,524738	-3,6791	0,000641
XU100	198	-3,9418	2,5253	0,078505	0,609814	-5,6029	0,000356
Part B. ARMA(1,0) – GARCH-ged (1,1)							
IBOV	194	-3,0103	6,7010	0,300302	0,002581**	-4,0497	0,005519
JALSH	198	-1,9642	6,5657	0,333786	0,005005**	-2,6579	0,000890
MICEX	194	-3,7649	2,5773	0,089022	0,606035	-5,3916	0,005779
SENSEX	197	-2,6338	5,5838	0,711881	0,014792*	-3,7524	0,001044
SHCOMP	185	-2,8623	3,2432	0,242610	0,524738	-4,1373	0,000870
XU100	198	-3,9133	2,5253	0,078505	0,609814	-5,4940	0,000398

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Tabela 12D: Resultados das previsões de VaR e ES para 10 passos à frente – distribuição *Student t* assimétrica (skt)

Índice	Nº de previsões de VaR 10 passos à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-valor)	Christoffersen (p-value)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-skt (1,d,1)							
IBOV	194	-3,4121	3,0928	0,191064	0,101465	-4,8001	0,001721
JALSH	198	-2,0260	5,5556	0,724335	0,125361	-2,8173	0,000668
MICEX	194	-4,1930	2,5773	0,089022	0,606035	-6,3986	0,005818
SENSEX	197	-2,8463	3,5533	0,326854	0,228708	-4,2310	0,000554
SHCOMP	185	-2,5045	4,3243	0,666303	0,393687	-3,7259	0,000742
XU100	198	-3,8384	2,5253	0,078505	0,609814	-5,6310	0,000290
Part B. ARMA(1,0) – GARCH-skt(1,1)							
IBOV	194	-3,0327	6,7010	0,300302	0,002581**	-4,1611	0,005186
JALSH	198	-1,9586	6,5657	0,333786	0,005005**	-2,7034	0,000853
MICEX	194	-3,8557	2,5773	0,089022	0,606035	-5,7618	0,005447
SENSEX	197	-2,6224	6,0914	0,496114	0,026554*	-3,8591	0,001173
SHCOMP	185	-3,0135	2,1622	0,046909*	0,673277	-4,6945	0,000283
XU100	198	-3,8115	2,5253	0,078505	0,609814	-5,5460	0,000405

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Os resultados acima - para o teste de Kupiec e, de maneira mais marcante, para o teste de Christoffersen - mostram melhor desempenho do modelo de memória longa, FIGARCH, em relação ao modelo com especificação GARCH, quando o horizonte de previsão aumenta de 1 dia para 10 dias à frente.

As Tabelas 13A a 13D mostram os resultados para as previsões de VaR para 20 passos à frente. Para esse horizonte de tempo mais longo, percebe-se uma pequena piora, em relação ao horizonte de 10 passos à frente, no desempenho dos modelos FIGARCH, já que o teste de Kupiec sugere que a taxa de violação observada do VaR não é estatisticamente diferente da taxa esperada de 5% para somente 16 modelos. Para os modelos GARCH isso ocorre para 19 modelos, indicando que mais modelos GARCH foram considerados adequados pelo teste de Kupiec dos que os modelos FIGARCH para esse horizonte de previsão. O teste de Christoffersen indica a não independência de violações de VaR para 3 modelos GARCH: JALSH (normal, ged e skt), o mesmo não ocorreu para os modelos FIGARCH, pois a hipótese independência de violações de VaR não foi rejeitada para nenhum modelo. Entretanto, como este estudo lançou mão de observações não sobrepostas para as previsões de 20 dias à frente, para se evitar autocorrelação entre os retornos, o número de observações disponíveis passou a ser vinte vezes menor do que as utilizadas para a análise das previsões de 1 dia à frente. Esse

número menor de observações aumenta a sensibilidade dos testes de Kupiec e Christoffersen ao número de violações do VaR, o que pode influenciar na avaliação da adequabilidade do modelo. Além disso, Crouhy, Galai e Mark (2000) ressaltam que o poder do teste de Kupiec fica reduzido para pequenas amostras.

Tabela 13A: Resultados das previsões de VaR e ES para 20 passos à frente – distribuição normal (n)

Índice	Nº de previsões de VaR 20 passos à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-value)	Christoffersen (p-valor)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-n (1,d,1)							
IBOV	96	-3,8226	4,1667	0,700045	0,129569	-5,0209	0,000116
JALSH	98	-2,2131	4,0816	0,666988	0,557419	-2,9501	0,000337
MICEX	96	-4,9968	2,0833	0,139522	0,769289	-6,8258	0,000357
SENSEX	98	-3,2972	3,0612	0,344186	0,661653	-4,4901	0,000119
SHCOMP	92	-2,7227	4,3478	0,769307	0,544126	-3,5370	0,000356
XU100	98	-5,0107	1,0204	0,028748*	0,885233	-6,7261	0,000192
Part B. ARMA(1,0) – GARCH-n (1,1)							
IBOV	96	-3,0788	6,2500	0,587934	0,357739	-3,9836	0,000702
JALSH	98	-2,0076	8,1633	0,186168	0,013105	-2,6487	0,000663
MICEX	96	-3,9870	3,1250	0,366566	0,658225	-5,3165	0,001293
SENSEX	98	-2,8041	6,1224	0,622805	0,373562	-3,7564	0,000406
SHCOMP	92	-3,2188	2,1739	0,163132	0,764310	-4,2428	0,000139
XU100	98	-4,5797	1,0204	0,028748*	0,885233	-6,0425	0,000228

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Tabela 13B: Resultados das previsões de VaR e ES para 20 passos à frente – distribuição t de *Student* (t)

Índice	Nº de previsões de VaR 20 passos à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-valor)	Christoffersen (p-value)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-t (1,d,1)							
IBOV	96	-22,0518	0,0000	0,001700**	1,0000	-31,3357	0,0000
JALSH	98	-8,8277	0,0000	0,001521**	1,0000	-12,3140	0,0000
MICEX	96	-120,1046	0,0000	0,001700**	1,0000	-185,9935	0,0000
SENSEX	98	-42,4227	0,0000	0,001521**	1,0000	-63,0386	0,0000
SHCOMP	92	-163,3085	0,0000	0,002125**	1,0000	-251,0064	0,0000
XU100	98	-87,3881	0,0000	0,001521**	1,0000	-130,3582	0,0000
Part B. ARMA(1,0) – GARCH-t (1,1)							
IBOV	96	-5,5035	3,1250	0,366566	0,658225	-7,7026	0,000210
JALSH	98	-3,9806	3,0612	0,344186	0,661653	-5,7019	0,000389
MICEX	96	-59,7528	0,0000	0,001700**	1,0000	-99,7188	0,0000
SENSEX	98	-16,5261	0,0000	0,001521**	1,0000	-27,0191	0,0000
SHCOMP	92	-185,0303	0,0000	0,002125**	1,0000	-325,2382	0,0000
XU100	98	-45,8382	0,0000	0,001521**	1,0000	-73,4673	0,0000

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Tabela 13C: Resultados das previsões de VaR e ES para 20 passos à frente – distribuição ged

Índice	Nº de previsões de VaR 20 passos à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p- valor)	Christoffersen (p-value)	Média ES	MSE para ES
Part C. ARMA(1,0) – FIGARCH-ged (1,d,1)							
IBOV	96	-3,8250	4,1667	0,700045	0,129569	-5,2446	0,000155
JALSH	98	-2,1439	5,1020	0,963150	0,223937	-2,9165	0,000429
MICEX	96	-4,8527	2,0833	0,139522	0,769289	-7,0949	0,000222
SENSEX	98	-3,2319	3,0612	0,344186	0,661653	-4,6483	0,000206
SHCOMP	92	-2,5860	4,3478	0,769307	0,544126	-3,6947	0,000339
XU100	98	-4,7263	1,0204	0,028748*	0,885233	-6,6911	0,000338
Part G. ARMA(1,0) – GARCH-ged (1,1)							
IBOV	96	-3,0388	6,2500	0,587934	0,357739	-4,1049	0,000752
JALSH	98	-1,9795	8,1633	0,186168	0,013105	-2,6873	0,000683
MICEX	96	-3,9579	3,1250	0,366566	0,658225	-5,7238	0,000974
SENSEX	98	-2,7139	6,1224	0,621805	0,373562	-3,8741	0,000351
SHCOMP	92	-2,9322	2,1739	0,163132	0,764310	-4,2608	0,000291
XU100	98	-4,2653	2,0408	0,128954	0,771662	-6,0277	0,000300

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Tabela 13D: Resultados das previsões de VaR e ES para 20 passos à frente – distribuição t de *Student* assimétrica (skt)

Índice	Nº de previsões de VaR 20 passos à frente	Média VaR	Taxa observada de violação de VaR	Kupiec (p-value)	Christoffersen (p-valor)	Média ES	MSE para ES
Part A. ARMA(1,0) – FIGARCH-skt (1,d,1)							
IBOV	96	-3,7899	4,1667	0,700095	0,129569	-5,3482	0,000110
JALSH	98	-2,1412	5,1020	0,963150	0,223937	-2,9741	0,000605
MICEX	96	-4,9491	2,0833	0,139522	0,769289	-7,5698	0,000357
SENSEX	98	-3,2503	3,0612	0,344186	0,661653	-4,8234	0,000465
SHCOMP	92	-2,5044	4,3478	0,769307	0,544126	-3,7440	0,000344
XU100	98	-4,5306	3,0612	0,344186	0,661653	-6,6223	0,000714
Part B. ARMA(1,0) – GARCH-skt(1,1)							
IBOV	96	-3,0534	6,2500	0,587934	0,357739	-4,2012	0,000683
JALSH	98	-1,9756	8,1633	0,186168	0,013105*	-2,7394	0,000663
MICEX	96	-4,0869	3,1250	0,366566	0,658225	-6,1715	0,000836
SENSEX	98	-2,7008	7,1429	0,359060	0,296474	-3,9960	0,000598
SHCOMP	92	-3,1972	2,1739	0,163132	0,764310	-5,0198	0,0000001
XU100	98	-4,1288	3,0612	0,344186	0,661653	-6,0576	0,000587

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Outro padrão que emerge ao se analisar os resultados é que para os modelos FIGARCH quanto maior o horizonte de previsão, menor é o número de vezes que o VaR é subestimado. O mesmo não ocorre para os modelos GARCH. Para o horizonte temporal de 1 dia à frente, as taxas percentuais observadas de violação do VaR foram maiores que 5% em 12 casos para os modelos FIGARCH e em 7 casos para os modelos GARCH. Para 10 passos à frente, as taxas percentuais de violação do VaR foram maiores que 5% em 4 casos para os modelos FIGARCH e em 9 casos para os modelos GARCH. Por fim, para 20 passos à frente, as taxas percentuais de violação do VaR foram maiores que 5% em apenas 2 casos para os modelos FIGARCH e em 9 casos para os modelos GARCH.

Avaliação pelo critério do erro quadrático médio (MSE)

A medida ES (ES) reporta ao gestor de riscos a perda esperada de seu investimento se um evento extremo ocorrer, em outras palavras, a exigência de capital sob a condição de teste de estresse.

No que tange às estimativas do erro quadrático médio (MSE para ES) definido pela equação (32), os modelos FIGARCH produziram os menores valores (em relação aos modelos GARCH) de MSE para ES em 13 casos dos 24 possíveis, para o horizonte de 1 dia. Todavia, para o horizonte de 10 dias, os

modelos FIGARCH produziram os menores valores de MSE para ES em 20 casos dos 24 possíveis, representando, portanto, desempenho melhor que os modelos GARCH para esse horizonte de tempo. Esses resultados estão alinhados com aqueles obtidos pelo teste de Kupiec para este horizonte de previsão. Para 20 dias à frente, os modelos FIGARCH produziram os menores valores de MSE para ES em 15 casos dos 24 possíveis, representando uma piora em relação ao prazo de 10 dias, mas, ao mesmo tempo, mantendo pequena supremacia dos modelos FIGARCH em relação aos modelos GARCH, o que conflita com os resultados obtidos pelo teste de Kupiec para o horizonte de 20 dias à frente, os quais sugeriam pequena supremacia dos modelos GARCH.

Avaliação pelo critério do teste de Giacomini e White (GW)

A Tabela 14 apresenta os resultados do teste de Giacomini e White (2006) utilizado para comparar o desempenho, na previsão de ES, dos modelos de memória longa (FIGARCH) e de memória curta (GARCH) que foram considerados adequados tanto pelo teste de Kupiec, quanto pelo teste de Christoffersen. O teste de Giacomini e White (2006) é aplicado para verificar se a diferença entre as funções de perda (MSE para ES) dos modelos GARCH e FIGARCH são estatisticamente significantes. A hipótese nula é de que não há diferença na precisão de previsão entre os modelos GARCH e FIGARCH. Valores positivos da estatística de teste indicam que o modelo GARCH é superior ao modelo FIGARCH com mesma distribuição para os erros. Por outro lado, valores negativos indicam superioridade do modelo FIGARCH.

Tabela 14: Resultados do teste de Giacomini-White (2006)

Modelo	Passos à frente	IBOV		JALSH		MICEX	
		Estatística	p-valor	Estatística	p-valor	Estatística	p-valor
FIGARCHC(1,1)-n - GARCH(1,1)-n	1	2,3720	0,0088**			0,6824	0,2475
FIGARCHC(1,1)-t - GARCH(1,1)-t	1			1,9687	0,0244**		
FIGARCHC(1,1)-ged - GARCH(1,1)-ged	1	2,7586	0,0029**			1,4480	0,0738
FIGARCHC(1,1)-skt - GARCH(1,1)-skt	1			-0,8149	0,2076		
FIGARCHC(1,1)-n - GARCH(1,1)-n	10					-0,9407	0,1734
FIGARCHC(1,1)-t - GARCH(1,1)-t	10						
FIGARCHC(1,1)-ged - GARCH(1,1)-ged	10					0,6372	0,2620
FIGARCHC(1,1)-skt - GARCH(1,1)-skt	10					0,8502	0,1976
FIGARCHC(1,1)-n - GARCH(1,1)-n	20	-1,2901	0,0985			-1,6829	0,0461*
FIGARCHC(1,1)-t - GARCH(1,1)-t	20						
FIGARCHC(1,1)-ged - GARCH(1,1)-ged	20	-1,2583	0,10413			-1,6186	0,0527
FIGARCHC(1,1)-skt - GARCH(1,1)-skt	20	-1,6155	0,0531*			-1,5075	0,0658

Modelo	Passos à frente	SENSEX		SHCOMP		XU100	
		Estatística	p-valor	Estatística	p-valor	Estatística	p-valor
FIGARCHC(1,1)-n - GARCH(1,1)-n	1	-0,2949	0,3840	2,0617	0,0196*	1,1485	0,1254
FIGARCHC(1,1)-t - GARCH(1,1)-t	1	-1,0379	0,1496				
FIGARCHC(1,1)-ged - GARCH(1,1)-ged	1	-0,5790	0,2812	1,4710	0,0706	0,3703	0,3555
FIGARCHC(1,1)-skt - GARCH(1,1)-skt	1						
FIGARCHC(1,1)-n - GARCH(1,1)-n	10					-2,0246	0,0214*
FIGARCHC(1,1)-t - GARCH(1,1)-t	10						
FIGARCHC(1,1)-ged - GARCH(1,1)-ged	10			-0,6519	0,2572	-0,2841	0,3881
FIGARCHC(1,1)-skt - GARCH(1,1)-skt	10					-0,7483	0,2271
FIGARCHC(1,1)-n - GARCH(1,1)-n	20	-1,6682	0,0476*	1,1989	0,1153		
FIGARCHC(1,1)-t - GARCH(1,1)-t	20						
FIGARCHC(1,1)-ged - GARCH(1,1)-ged	20	-0,9002	0,1840	0,4104	0,3408	0,0711	0,5283
FIGARCHC(1,1)-skt - GARCH(1,1)-skt	20	-1,6651	0,0479*	1,7272	0,0420*		

Fonte: Própria

(*) Significância a 5%

(**) Significância a 1%

Para 1 dia à frente, dos 13 pares de modelos (FIGARCH-GARCH) que atenderam aos requisitos de escolha (não serem rejeitados pelos testes de Kupiec e Christoffersen), o modelo GARCH superou o modelo FIGARCH, para 10% de significância, em 6 ocasiões (GARCH(1,1)-n: IBOV e SHCOMP; GARCH(1,1)-t: JALSH; e GARCH(1,1)-ged: IBOV, MICEX e SHCOMP), o que representa 46,15% das vezes. Para os 7 modelos remanescentes não houve diferença estatística entre o desempenho dos modelos GARCH e FIGARCH.

Para 10 dias à frente, a supremacia do modelo GARCH sobre o FIGARCH desaparece, pois para os 7 pares de modelos que atenderam aos requisitos de escolha, o modelo FIGARCH mostrou-se superior ao modelo GARCH em 1 ocasião (FIGARCH(1,1)-n: XU100), sendo que para os 6 modelos remanescentes não houve diferença estatística entre o desempenho dos modelos GARCH e FIGARCH. Ademais, para ilustrar a superioridade do modelo FIGARCH em relação ao modelo GARCH, quando se alonga o horizonte de previsão para 10 dias à frente, destaca-se que dos 24 modelos estimados para o processo FIGARCH, 16 (66,67%) passaram por ambos os critérios de Kupiec e Christoffersen, enquanto que para os 24 modelos GARCH estimados, somente 7 (29,17%) passaram por ambos os testes.

Para 20 dias à frente, a supremacia do modelo FIGARCH se intensifica ainda mais, uma vez que para os 13 pares de modelos que passaram pelos critérios de escolha, o modelo de memória longa superou o modelo de memória curta em 8 ocasiões (61,54%), enquanto que o modelo GARCH superou o modelo FIGARCH em apenas uma única ocasião (7,7%), GARCH(1,1)-skt: SHCOMP. Em 4 ocasiões os modelos foram considerados indiferentes estatisticamente.

Degiannakis *et al.*(2013) realizaram comparação semelhante entre modelos que passaram pelo mesmo filtro, testes de Kupiec e Christoffersen, todavia, ao invés de utilizarem o teste de Giacomini White, lançaram mão do teste de Diebold e Mariano (1995) para comparar os desempenho dos modelos. Ocorre que Clark e McCracken (2001) mostraram evidências de que a normalidade da distribuição assintótica da estatística de Diebold e Mariano (1995) não é válida se os modelos competidores forem aninhados, como é o caso dos modelos FIGARCH (1,d,1) e GARCH(1,1), já que este último é um caso particular daquele quando $d=0$. Por este motivo, o teste de Diebold e Mariano não foi utilizado neste estudo.

3.4.4 Estimativa dos parâmetros utilizando rolagens diárias para a amostra

Outro propósito deste trabalho foi estudar o comportamento dos parâmetros estimados pela rolagem da amostra ao longo do tempo. Como as informações obtidas de notícias de mercado surgem todos os dias de maneira imprevisível, os parâmetros estimados devem ser revistos diariamente (DEGIANNAKIS *et al.*, 2008; ENGLE, ITO e LIN, 1990). As Figuras 2e3ilustram a plotagem dos parâmetros estimados pela rolagem da amostra ao longo do tempo para alguns modelos FIGARCH e GARCH com distribuição normal. Nas figuras apresentadas observa-se considerável mudança nos parâmetros estimados ao longo do tempo para ambos os modelos referentes ao índice XU100. Após a utilização do teste de Nyblom (1989) rejeitou-se a hipótese de estabilidade dos parâmetros para 36 (75%), dos 48 modelos testados, não havendo diferenças significativas entre os resultados obtidos para os modelos FIGARCH e GARCH.




Figura 2 - Índice XU100: estimativas dos parâmetros ao longo do tempo para o modelo GARCH
Fonte: Própria




Figura 3 - Índice XU100: estimativas dos parâmetros ao longo do tempo para o modelo FIGARCH
Fonte: Própria

Entretanto, as Figuras 2 e 3 ilustram o fato de os parâmetros estimados pelo modelo FIGARCH parecerem variar mais, isto é, serem mais instáveis, ao longo do tempo dos que os do modelo GARCH. Esse padrão se repetiu para todos os índices de mercados emergentes e distribuições investigados neste trabalho.

3.5 Discussão

A presença de processos de volatilidade de memória longa nos retornos dos índices de ações de países emergentes foi comprovada pelos testes de memória longa realizados. Esses resultados vão ao encontro dos obtidos por Aloui e Hamida (2014) para os países do Conselho de Cooperação do Golfo. Degiannakis et al.(2013) chegaram a mesma conclusão para índices de países desenvolvidos, mas não efetuaram testes de presença de memória longa.

Para os modelos estimados com o propósito de descrever os dados (*dentro da amostra*) verificou-se que com a utilização de processos de memória longa são obtidos modelos com melhor desempenho que os de memória curta quando se utiliza, para avaliação, os critérios de informação AIC e SBC. Além disso, identificou-se que o parâmetro de memória longa “d-FIGARCH”, foi estatisticamente significativo para todos os modelos FIGARCH estimados. Esses

resultados vão ao encontro dos obtidos por Aloui e Hamida (2014) para os retornos dos índices de ações de países do Golfo Pérsico.

Além disso, no que tange as previsões de VaR e ES para observações fora da amostra, verificou-se que, com o aumento do horizonte de previsão, os modelos de memória longa tendem a superar os de memória curta. Esses resultados diferem dos encontrados por Degiannakis *et al*(2013), cuja conclusão foi a de que os modelos FIGARCH não superavam os modelos GARCH com o aumento do horizonte de previsão para a modelagem dos retornos dos mercados dos países desenvolvidos.

Entretanto, nossos resultados vão ao encontro daqueles obtidos por Aloui e Hamida (2014), pois segundo esses autores, os modelos de memória longa superam os de memória curta para previsões de VaR e ES fora da amostra.

Ademais, conforme verificado nos testes de Kupiec para 10 dias à frente, percebeu-se que a escolha da distribuição a ser utilizada para os erros influencia a decisão de escolha do modelo. Essa constatação diminui a generalização da conclusão de Degiannakis *et al*(2013) sobre a irrelevância dos modelos de memória longa para horizontes de previsão mais longos, pois esses autores limitaram sua investigação a utilização da distribuição normal para os erros.

Além disso, cabe ilustrar alguns pontos sobre as distribuições utilizadas. A distribuição t de *Student* não apresentou desempenho relevante para qualquer modelo ou horizonte de previsão. O mesmo ocorreu para a distribuição t de *Student* assimétrica para o horizonte de 1 dia à frente, todavia esta distribuição apresentou um desempenho muito bom para 10 e 20 dias à frente.

Para os modelos GARCH, a distribuição normal apresentou desempenho semelhante ao das distribuições ged e t de *Student* assimétrica, motivo pelo qual a distribuição normal, por ser mais parcimoniosa, pode ser considerada a melhor escolha nesse caso. Com relação aos modelos FIGARCH, destaca-se que os modelos FIGARCH-n e FIGARCH-ged apresentaram desempenho semelhante aos modelos GARCH-n e GARCH-ged para o horizonte de 1 dia à frente, mas para os horizontes de 10 e 20 dias à frente, esses modelos GARCH mostraram desempenho inferior, pois foram considerados inadequados mais vezes que os FIGARCH, pelo critério do teste de Christoffersen.

Adicionalmente, os resultados deste estudo apontam que a ocorrência de subestimação do VaR verdadeiro fica menos frequente com o aumento de horizonte de previsão para os modelos FIGARCH e que o mesmo não ocorre para os modelos GARCH. Essa constatação difere dos resultados obtidos por Degiannakis *et al.*(2013) para índices de ações de mercados desenvolvidos, uma vez que esses autores concluíram que o número de subestimações do VaR diminuía com o horizonte de tempo para ambos os modelos GARCH e FIGARCH.

Com relação à estabilidade dos parâmetros ao longo do tempo, verificou-se que, para os índices de países emergentes estudados, os parâmetros dos modelos FIGARCH variaram mais que aqueles dos modelos GARCH. Resultados similares foram encontrados por Degiannakis *et al.*(2013) para índices de ações de mercados desenvolvidos. Além disso, a maior instabilidade encontrada para os parâmetros dos modelos FIGARCH não é totalmente explicada pelo processo de chegada de informações, pois ambos os modelos, FIGARCH e GARCH, foram estimados com base nas mesmas amostras. Assim, conforme sugerido por Degiannakis *et al.*(2013) uma parte dessa instabilidade pode ser devida ao próprio processo de modelagem do FIGARCH.

3.6 Conclusões

A recente crise financeira internacional enfatizou a importância da utilização de métricas de risco que possam auxiliar de maneira adequada o processo de decisão de todos os agentes expostos aos riscos de mercado. Uma das métricas mais utilizadas pelo mercado financeiro, o VaR, não foi capaz de quantificar adequadamente as perdas sofridas pelas diversas instituições durante a crise financeira mencionada. Além disso, a aplicação de métricas de risco podem apresentar desempenhos diferentes em mercados financeiros distintos.

Este trabalho investigou se a utilização dos modelos de memória longa (FIGARCH) melhora a previsão para observações *fora da amostra* de VaR e ES para múltiplos períodos à frente para retornos de índices de ações de alguns países emergentes (Brasil, África do Sul, Rússia, Índia, China e Turquia).

Constatou-se que os modelos de memória longa apresentaram melhor desempenho que os modelos de memória curta com o aumento do horizonte de previsão.

Adicionalmente, verificou-se que, para as observações *dentro da amostra*, em geral, os modelos FIGARCH superaram os modelos GARCH na descrição dos retornos dos índices de ações investigados.

Todavia, constatou-se que os parâmetros dos modelos GARCH apresentaram maior estabilidade ao longo do tempo quando comparados aos parâmetros dos modelos FIGARCH.

Esses resultados têm como público-alvo acadêmicos e investidores interessados em conhecer a dinâmica dos riscos atinentes a mercados emergentes, principalmente, quando se alonga o horizonte de previsão.

Entretanto, este trabalho apresenta algumas limitações. Primeiro, utilizou-se apenas uma janela de rolagem diária de amostras no valor de $T=2000$. Angelidis *et al* (2004) asseveram que, dependendo do valor dessa janela de rolagem diária, pode-se chegar a resultados distintos. Assim, recomenda-se que estudos futuros sobre o assunto lancem mão de diferentes tamanhos para os valores de T .

Segundo, as especificações GARCH(1,1) e FIGARCH(1,1) mostraram-se adequadas somente para os horizontes de previsão estudados. Assim, sugere-se que sejam realizados estudos futuros tanto para outras especificações do modelos GARCH e FIGARCH, quanto para horizontes de previsão mais longos. Por fim, os modelos de VaR e ES foram calculados com nível de confiança de 95%, pesquisas futuras poderão testar a robustez dos resultados deste trabalho por meio da utilização de maiores níveis de confiança.

4.1 Introdução

A administração de riscos é um tema que há muito tempo assumiu papel relevante e permanente nas instituições financeiras. Todavia, recentemente, tal tema também vem sendo debatido no ambiente de instituições não financeiras. Para as instituições não financeiras a mensuração e gerenciamento de riscos passam a ser fatores de competitividade com potencial para impactar seus fluxos de caixa e, por conseguinte, suas capacidades financeiras e de solvência (PEROBELLI *et al*, 2007).

No que tange às instituições financeiras, uma das métricas de risco mais utilizadas é o Value-at-Risk (VaR). O VaR representa a máxima perda esperada de um ativo financeiro ou de uma carteira em um certo período de tempo com um nível de confiança especificado. Todavia, o conceito de VaR não apresenta o mesmo desempenho quando utilizado em instituições não financeiras, pois os ativos destas não possuem o mesmo grau de liquidez que os das instituições bancárias.

Assim, com o fito de contornar o problema causado pela falta dessa informação, em 1999, o Riskmetrics Group propôs a mensuração do Cash-Flow-at-Risk (CFaR), cujo propósito principal era o de avaliar os potenciais impactos de mudanças nas taxas de mercado sobre os resultados financeiros da empresa em um determinado intervalo de tempo. (PEROBELLI *et al*, 2007). O CFaR representa o valor mínimo de um fluxo de caixa em uma determinada data no futuro, a um determinado nível de confiança avaliado com as informações disponíveis no presente (LA ROCQUE e LOWENKRON, 2005).

Há na literatura de Finanças diversas métricas adotadas no gerenciamento de riscos de instituições financeiras e não financeiras, todavia não é comum a utilização de métricas de risco na esfera governamental. O gerenciamento de riscos é importante para as finanças públicas, pois desequilíbrios entre entradas e saídas de recursos podem resultar em atrasos nos pagamentos de fornecedores, credores e servidores públicos.

Esse ensaio procurou mensurar o risco de liquidez de um Órgão Público, a Marinha do Brasil, por meio do cálculo do CFaR, o qual representa uma extensão do VaR.

A primeira contribuição deste trabalho é destacar a diferença entre VaR e CFaR. O VaR é utilizado como medida de risco em boa parte das instituições financeiras, e o CFaR, como medida de risco de instituições não financeiras, isto se deve ao fato de que nas instituições financeiras o VaR seria igual ao CFaR, pois as carteiras dos bancos seriam marcadas a mercado (Shimko, 1998). Entretanto, o VaR, ao contrário do CFaR, captura somente uma pequena parte da exposição total de uma empresa, pois não leva em consideração os riscos embutidos em seus fluxos de caixa (YAN, HALL e TURNER, 2014).

A segunda contribuição deste trabalho é verificar a adequabilidade do modelo *exposure-based* CFaR para a administração dos fluxos de caixa da Marinha, o que envolve a estimação de um conjunto de coeficientes de exposição, os quais fornecem informação sobre a expectativa de como algumas variáveis macroeconômicas e de mercado afetam o fluxo de caixa daquela Força Armada. Além disso, essa estimação leva em consideração as correlações entre os efeitos daqueles coeficientes.

O trabalho encontra-se estruturado em cinco seções. A primeira trata da introdução. A segunda discute o referencial teórico. A terceira descreve a metodologia da pesquisa. A quarta expõe os resultados e análise. A quinta apresenta as conclusões.

4.2 Referencial teórico

4.2.1 Introdução ao conceito de risco

As corporações têm como objetivo estratégico a obtenção de retorno sobre seu capital de modo a atender o desejo dos *stakeholders*, baseando-se em princípios éticos e boas práticas de governança corporativa em conformidade com as principais diretrizes que norteiam os problemas gerenciais relacionados com a área de finanças.

O processo decisório das corporações referente aos aspectos estratégicos envolve decisões de governança, administração financeira e gestão de riscos, tomadas em cenários de incerteza, isto é, lastreadas em expectativas e projeções que podem não ocorrer. Várias consequências podem advir devido a não obtenção dos resultados positivos esperados, desde a diminuição da rentabilidade da organização e queda de suas ações, até prováveis desastres financeiros, como, por exemplo, processos de falência.

O risco faz parte do dia-a-dia das corporações, as quais são obrigadas, constantemente, a tomar decisões, cujo grau de complexidade requer a escolha, dentre as alternativas existentes, daquela considerada a mais adequada para o momento e a menos arriscada. Desse modo, o processo permanente de tomada de decisão exige que as empresas realizem previsões, lançando mão da elaboração de cenários que possibilitem a avaliação de resultados passados e a verificação da possibilidade destes ocorrerem novamente.

4.2.2 Tipos de risco

As empresas estão sujeitas a riscos de diferentes fontes: mudanças na preferência dos consumidores e na demanda por seus produtos, variações no custo das matérias-primas, rotatividade dos funcionários, entrada de novos concorrentes e outras incertezas. Gestores, de uma forma geral, assumem esses riscos voluntariamente em busca de retornos elevados e os aceitam como parte do custo de fazer negócios.

Os órgãos de governo, dentre os quais se inclui a Marinha do Brasil, também estão sujeitos a riscos, na medida em que as flutuações nas variáveis macroeconômicas podem ter impactos negativos em seus orçamentos, comprometendo, por conseguinte, a aplicação de recursos em projetos de investimento de interesse da sociedade. Portanto, tal como ocorre com as empresas privadas, órgãos governamentais devem gerenciar seus riscos com o propósito de minimizar os efeitos negativos destes sobre suas finanças. Assim, antes de se propor um modelo que contribua para a gestão de riscos de órgãos de governo, é necessário discutir seus conceitos e de que forma podem afetar os valores esperados de variáveis de interesse.

Duarte (2003, p.1) define risco como uma medida da incerteza associada aos retornos esperados de investimentos. Já para Jorion (2003, p. 3), risco pode ser definido “como a volatilidade de resultados inesperados, normalmente relacionados ao valor de ativos ou passivos de interesse”. Desse modo, depreende-se que a ideia de risco está relacionada à incerteza dos resultados de ativos e passivos de interesse do administrador ou investidor.

Ross (1995) sugere que um ativo pode ser impactado por riscos sistemáticos e riscos não sistemáticos, também chamados próprios. Risco sistemático é qualquer risco que afeta um grande número de ativos, cada um com maior ou menor intensidade. As incertezas acerca de condições econômicas gerais, tais como Produto Interno Bruto, taxas de juros ou inflação seriam exemplos de risco sistemático, já que todas as empresas estariam suscetíveis às forças dessa natureza.

Por outro lado, alguns ativos também são afetados por riscos não sistemáticos. Esses riscos se aplicam a empresas individualmente ou a algum setor específico da indústria, mas não às condições gerais da economia. São também chamados de idiossincráticos para diferenciá-los dos fatores de risco sistemáticos, os quais explicam a maioria dos movimentos observados nos retornos dos mercados. (ROSS, 1995). Risco financeiro ou de falências, risco de qualidade da administração e o risco do próprio segmento são exemplos de fontes de riscos não sistemáticos.

La Rocque e Lowenkron (2005) esclarecem que o conceito de risco - genericamente definido como a possibilidade de ocorrência de resultados inesperados - é muito amplo e por isso deve ser classificado de forma mais precisa a fim de melhor explicitar os riscos corporativos. Para esses autores as corporações podem se defrontar com: riscos de negócios (demanda, custos de insumos, marketing e tecnológicos), riscos de evento (legal, de reputação e regulamentação) ou riscos financeiros. Esses últimos, por seu turno, ainda podem ser divididos em riscos operacionais, de liquidez, de crédito e de mercado.

Jorion (2003, p. 4) conceitua os riscos financeiros como aqueles ligados a possíveis perdas nos mercados financeiros, podendo a exposição a esses riscos, em algumas ocasiões, ser mitigada pela utilização de instrumentos de *hedge*, de forma que as empresas possam se concentrar na administração de seus riscos estratégicos. Na literatura de finanças, o termo *hedge*, normalmente, está relacionado a operações que têm como propósito mitigar ou eliminar os diferentes tipos de riscos a que as empresas estão sujeitas.

4.2.3 A gestão de risco em instituições financeiras

O estabelecimento de estruturas adequadas para o gerenciamento de riscos tem sido alvo de preocupações crescentes recentemente, tanto das instituições financeiras quanto das autoridades reguladoras.

Duarte (2003, p. 13) esclarece que, especificamente a partir do início da década de 1980, verifica-se o aumento das atividades internacionais das instituições financeiras, inovação de práticas e instrumentos derivativos e *swaps*, além de vários tipos de operações especulativas relacionadas, por exemplo, à volatilidade das taxas de câmbio. Por conseguinte, a existência de ferramentas para gerenciamento de ativos e passivos passou a ter relevância significativa na sobrevivência das instituições financeiras e na solidez dos sistemas financeiros nacionais e internacionais.

O desenvolvimento dos instrumentos de regulação e supervisão de instituições financeiras é consequência natural do desenvolvimento dos mercados, operações e atividades dessas instituições. Dessa forma, na medida em que a intensificação da internacionalização das instituições financeiras resultou na necessidade de padronização da supervisão bancária mundial, houve também o

estabelecimento de regras prudenciais condizentes com a sofisticação das atividades bancárias (DUARTE, 2003, p.14).

Stulz (2008) relata que uma das métricas de risco mais utilizadas pelas instituições financeiras é o *Value-at-Risk* (VaR). O VaR representa a máxima perda esperada de um ativo financeiro ou de uma carteira em um certo período de tempo com um nível de confiança especificado. Embora as instituições financeiras geralmente divulguem o VaR de suas carteiras diariamente, VaRs também podem ser estimados para períodos mais longos de tempo.

Ademais, é importante destacar que uma das grandes vantagens de utilização do VaR é o fato de resumir em um único número a perda máxima esperada dentro de certo prazo e com certo grau de confiança estatística. Além disso, pode ser frequentemente recalculado, o que o faz uma ferramenta útil de controle de risco (JORION, 2007).

Todavia, Artzner *et al* (1997) esclarecem que o VaR não é uma medida de risco coerente por não atender a propriedade da subaditividade, segundo a qual a medida de risco de uma carteira nunca deve ser maior que a soma das medidas de risco das carteiras que a compõe.

4.2.4 A gestão de risco em instituições não financeiras

A prática da gestão de riscos financeiros ainda é bastante recente nas instituições não financeiras, uma vez que há dificuldade por parte dessas instituições em adaptar os conceitos oriundos do mercado financeiro para o dia-a-dia das corporações, conforme relatam La Rocque e Lowenkron (2005). Segundo esses autores, o Value-at-Risk (VaR) ainda é a métrica de risco mais difundida, sendo bastante utilizada para administração dos riscos de mercado relacionados a fundos de investimento e mesa de operações financeiras de bancos

Todavia, Yan, Maximilian e Turner (2014) destacam que o VaR não fornece qualquer tipo de informação sobre a disponibilidade de caixa dos bancos para fazer face a seus riscos de liquidez. Ademais, o conceito de VaR deixa de ser suficiente quando aplicado a outras entidades, demandando que outras métricas de risco o complementem para que aquelas entidades consigam gerir seus riscos de mercado de forma mais eficaz. La Rocque e Lowenkron (2005) reforçam essa ideia ao destacar que críticas à adoção do conceito de VaR para a administração

dos riscos de mercado de instituições não financeiras começaram a aparecer no final da década de 90.

Bancos e corporações diferem primordialmente pelo fato daqueles manterem suas posições em ativos muito líquidos, o que não é o caso das corporações. Além disso, a liquidez dos ativos bancários faz com que o foco em valor dado pelo VaR faça mais sentido para as instituições financeiras.

Entretanto, como asseveram La Rocque e Lowenkron (2005), medir tudo em termos de valor nas corporações não é tarefa das mais simples. Um complicador seria descobrir qual taxa de desconto utilizar para descapitalizar os fluxos de caixa operacionais da empresa com o fito de se determinar seu valor presente.

Adicionalmente, Stulz (1996) propõe que o objetivo de uma política de gestão de riscos é impedir um cenário de “*financial distress*”, no qual há ausência de recursos para financiar os projetos de investimento da instituição. Contudo, o VaR não fornece informação acerca da probabilidade de ocorrência desse tipo de cenário.

Como resultado das críticas anteriormente mencionadas, métricas de risco de mercado mais apropriadas para as instituições não financeiras foram propostas posteriormente.

Turner (1997) sugere que as ferramentas estatísticas trazidas pela metodologia VaR sejam utilizadas na busca de um número que faça mais sentido para as instituições não financeiras. Nessa situação a ideia de VaR seria utilizada não como perda de patrimônio, mas, sim, como perda de fluxo de caixa em relação a seu alvo: o *Cash-Flow-at-Risk* (CFaR). Logo, a atenção se afasta do risco de valor de patrimônio (valor presente) e passa a ser direcionada para os riscos dos fluxos de caixa das empresas.

Perobelli *et al* (2007) relatam que tentativas rudimentares de verificação dos impactos de oscilações nos preços de mercado sobre o fluxo de caixa são creditadas a Vermeulen (1994), Shapiro e Titman (1999) e Bauman *et al* (1999). Contudo, esses autores não chegaram a propor um modelo completo, uma vez que trataram o assunto de forma mais geral.

Presume-se que um dos primeiros trabalhos acerca do cálculo do fluxo de caixa em risco foi desenvolvido por Hayt e Songs (1995). O trabalho sugerira uma medida de sensibilidade para o fluxo de caixa em risco. Essa medida tinha como propósito relacionar a probabilidade de a empresa alcançar certo patamar de fluxo de caixa que a impossibilitasse de honrar seus compromissos e planejamento de investimento, com mudanças em preços financeiros em determinados períodos (PEROBELLI *et al*, 2007).

Hayt e Songs (1995), ao analisarem o risco no fluxo de caixa pela probabilidade da obtenção da meta estabelecida, oferecem a possibilidade de investigação de alternativas que reduzam o risco resultante de cenários em que haja baixa probabilidade de obtenção da meta.

Stulz e Willianson (1996), posteriormente, propõem a possibilidade de utilização de simulação para o cálculo da distribuição esperada dos fluxos de caixa futuros. O trabalho desses autores tem o propósito de sugerir alternativas para a identificação e mensuração das exposições no fluxo de caixa, com potencial para gerar redução no valor da empresa, em virtude de possíveis perdas de oportunidades de investimentos, fruto de reduções inesperadas de fluxo de caixa. Os riscos com potencial para afetar o fluxo de caixa podem ser classificados em dois tipos.

O primeiro tipo refere-se aos riscos únicos da empresa, os quais apesar de mensuráveis não ensejam a possibilidade de proteção pela inexistência de produtos financeiros que possam atuar como *hedge*. O segundo tipo refere-se aos riscos de mercado, os quais, além de afetar um conjunto de empresas, admitem a possibilidade de serem mitigados pela utilização de instrumentos financeiros. Assim, as empresas não financeiras passariam a ter condições de administrar os riscos de mercado pela possibilidade de se quantificar a influência de cada fator de risco em seu fluxo de caixa.

Stulz e Willianson (1996) sugerem que a quantificação de cada fator de risco pode ser obtida por meio de três metodologias diferentes: pró-forma, dados históricos e simulação. A metodologia pró-forma lança mão da demonstração de fluxo de caixa para avaliar o comportamento desse fluxo em função da variação dos fatores de risco. A metodologia por dados históricos faz uso de dados passados para medir a exposição do fluxo de caixa aos fatores de risco por meio de análises de regressões lineares. Por fim, a metodologia de simulação, partindo

do conhecimento da distribuição dos fatores de risco, promove a simulação desses fatores para realizar inferências sobre o comportamento dos fluxos de caixa futuros.

Os trabalhos de Hayt e Songs (1995) e Stulz e Williamson (1996) materializaram as primeiras tentativas de cálculo do risco de fluxo de caixa (PEROBELLI *et al*, 2007). Além disso, estabeleceram as bases para o desenvolvimento de metodologias mais robustas.

Alinhado ao movimento de evolução das metodologias de cálculo do risco de fluxo de caixa, o *Riskmetrics Group* produziu, em 1999, o *CorporateMetrics Technical Document*. O principal objetivo desse documento residia em avaliar os potenciais impactos de mudanças nas taxas de mercado sobre os resultados financeiros da empresa em um determinado intervalo de tempo. Dentre as medidas analisadas e propostas estava o *Cash-Flow-at-Risk* (CFaR) (PEROBELLI *et al*, 2007).

O CFaR representa o valor mínimo de fluxo de caixa em uma determinada data no futuro, a um determinado nível de confiança avaliado com as informações disponíveis no presente. A metodologia utilizada lançava mão das ferramentas estatísticas usadas no conceito do VaR, adaptando-as ao dia-a-dia corporativo. Adicionalmente, expandia a convencional técnica de análise de sensibilidade de alguns poucos cenários para um amplo conjunto de cenários simulados. O método ainda propunha a necessidade de estimação de relações econométricas entre os fatores de risco e a variável de interesse: o fluxo de caixa. (LA ROCQUE e LOWENKRON, 2005).

Perobelli *et al* (2007) reportam que o modelo deveria ser capaz de explicitar o mais corretamente possível a evolução dos fatores de risco, bem como de manter consistência com teorias econômicas relevantes.

Apesar de o CFaR ter suas origens nas ideias básicas do VaR, La Rocque e Lowenkron (2005) apontam duas significativas diferenças entre o VaR e o CFaR. A primeira diz respeito ao fato de que o VaR foca a variabilidade em valor, ao passo que o CFaR tem sua preocupação voltada para a variabilidade de fluxo. A segunda diz respeito à metodologia de cálculo, pois o VaR, além do uso de simulação, pode lançar mão de fórmulas analíticas, ao passo que o CFaR faz uso intensivo de simulação.

Em que pese o fato de o *CorporateMetrics* apresentar metodologia de cálculo mais elaborada para o cálculo do CFaR, algumas críticas surgiram em relação a ela. Essas críticas devem-se, principalmente, à maneira como as exposições do fluxo de caixa aos fatores de risco são calculadas. O modelo proposto no *CorporateMetrics* utiliza a abordagem *bottom-up*, na qual procura-se identificar os fatores de risco que influenciam cada conta utilizada para cálculo do fluxo de caixa da empresa, como, por exemplo, receitas e custo de matéria-prima.

Stein, Usher, La Gattuta e Youngen (2001) alegam que a abordagem *bottom-up* é adequada para instituições financeiras, haja vista que os riscos atinentes a ativos financeiros (mais líquidos) tendem a ser mais identificáveis. Contudo, pelo fato de os ativos das empresas não financeiras não possuírem alto grau de liquidez, a identificação da totalidade dos fatores de risco com potencial de impactar seus fluxos de caixa fica comprometida. Para contornar o problema, esses autores sugerem a abordagem *top-down* como alternativa à *bottom-up* para o cálculo do CFaR. Por meio da abordagem *top-down* o foco passa para a observação agregada dos fluxos de caixa de um conjunto de empresas com o propósito de se obter a distribuição dos fluxos de caixa de empresas com perfis semelhantes.

Nota-se que tal abordagem tem a vantagem de oferecer uma distribuição de fluxo de caixa mais robusta, pois lança mão de um grande conjunto de empresas similares, agregando, portanto, todos os fatores de risco intrínsecos a essas empresas. Por outro lado, a abordagem *top-down* apresenta como desvantagem a necessidade de utilização de grande quantidade de dados empresas, o que nem sempre é possível de se obter. Além disso, essa metodologia não provê nenhuma estimação do CFaR condicionada a riscos de mercado, bem como não sugere nenhum tipo de adaptação que a capacite a fazê-lo. Em outras palavras, não se estabelece nenhuma correlação entre fatores de risco macroeconômicos ou de mercado e os valores de fluxos de caixa.

Com o propósito de superar essa limitação, Andrén, Jankensgar e Oxelheim (2005) propõem uma metodologia alternativa para o cálculo do CFaR denominada *Exposure-based Cash-Flow-at-Risk model*. Os autores esclarecem que a metodologia proposta é mais informativa que a abordagem *top-down* porque é capaz de obter tanto a distribuição do fluxo de caixa total da empresa, quanto a

identificação e quantificação das exposições a que o fluxo de caixa está sujeito, em relação a cada fator de risco. Para isso a metodologia faz uso de duas etapas:

A primeira lança mão de uma regressão múltipla que utiliza o fluxo de caixa como variável dependente, e os fatores de risco macroeconômicos e de mercado com potencial para influenciar o comportamento do fluxo de caixa como variáveis explicativas. Nessa etapa são identificados quais os fatores de risco que impactam o fluxo de caixa da empresa, de que maneira e em que medida se dá esse impacto.

A segunda etapa consiste no uso de simulação para o cálculo dos diversos valores possíveis para os fatores de risco, os quais, posteriormente, são inseridos no modelo de cálculo de fluxo de caixa para a obtenção da distribuição estatística deste último.

Com tudo que foi discutido até o momento, percebe-se a importância da gestão de riscos tanto para as instituições financeiras, quanto para as não financeiras. Entretanto, não se identificou na literatura sobre o assunto nenhuma metodologia que tratasse do gerenciamento de riscos de fluxo de caixa no setor público.

Desse modo, com o propósito de contribuir para o preenchimento dessa lacuna, este artigo propõe a utilização da metodologia do *Exposed-Based Model* sugerida por Andrén, Jankensgar e Oxelheim (2005) na identificação e mensuração dos fatores de risco com potencial de impactar o fluxo de caixa de um dos órgãos do Governo Federal: a Marinha do Brasil.

Apesar da carência de literatura sobre os fatores de risco no setor público brasileiro, o Anexo V da Lei 13.080/2015 discrimina alguns fatores de risco macroeconômicos com potencial para afetar tanto a arrecadação quanto o nível de endividamento do governo federal brasileiro. Esses fatores de risco serão tratados na seção 4.3.2.

Um dos benefícios da utilização do modelo *exposure-based CFaRé* a decomposição das estimativas de fluxo de caixa em exposições individuais a cada fator de risco, o que promove maior percepção tanto da dinâmica do fluxo de caixa da organização, quanto dos principais fatores de risco.

Todavia, cabe destacar que essa metodologia apresenta como limitação o uso de matriz de covariâncias constante ao longo do tempo.

4.3 Dados

4.3.1 Fluxo de caixa

O Sistema de Administração Financeira do Governo Federal brasileiro (SIAFI), com o objetivo de oferecer suporte ao processo de tomada de decisão relativo à gestão financeira dos órgãos públicos, produz algumas demonstrações contábeis, dentre as quais o Balanço Financeiro. O Balanço Financeiro tem por propósito evidenciar os ingressos e saídas de recursos em determinado exercício financeiro. (Manual de Contabilidade Aplicada ao Setor Público, 2013).

Desse modo, a partir do item “Disponível do Exercício Anterior” (saldo inicial), adicionam-se as entradas de recursos previstas no orçamento público (receitas orçamentárias), as transferências financeiras recebidas de outros órgãos e os ingressos de recursos não previstos no orçamento (recebimentos extraorçamentários) e subtraem-se as despesas previstas no orçamento (despesas orçamentárias), as transferências financeiras concedidas e pagamentos extraorçamentários, obtendo-se o valor do “Disponível para o Exercício Seguinte” (saldo final).

Assim, o Balanço Financeiro permite que se apure o fluxo de caixa do ente público em determinado período. De acordo com o Manual de Contabilidade Aplicada ao Setor Público, o cálculo desse fluxo de caixa pode ser realizado de duas formas:

- a) Subtraindo-se do “Disponível para o Exercício Seguinte” (saldo final) o “Disponível do Exercício Anterior” (saldo inicial).
- b) Somando-se as receitas orçamentárias, transferências financeiras recebidas e os recebimentos extraordinários, subtraindo-se, posteriormente, a despesa orçamentária, as transferências financeiras concedidas e os pagamentos orçamentários.

Para fins desta pesquisa, foram coletados os saldos iniciais e finais em Reais (R\$) do Balanço Financeiro da Marinha do Brasil, relativo às fontes de recursos do Tesouro Nacional, no período compreendido entre o primeiro trimestre de 1999 e o quarto trimestre de 2013. Por meio da subtração mencionada na alínea “a”, entre os saldos finais e iniciais de cada trimestre, obteve-se a variável de interesse para cada trimestre: o fluxo de caixa da Marinha do Brasil.

4.3.2 Potenciais fatores de risco.

Em seus estudos sobre o CFaR dos maiores bancos do Reino Unido, Yan *et al* (2014) identificaram os seguintes fatores de risco referentes ao mercado financeiro do Reino Unido: a taxa de juros de três meses do mercado interbancário, a taxa de juros dos títulos de 10 anos do governo, taxa de inflação e de crescimento real do PIB, e as taxas de câmbio dólar/libra (USD/GBP) e euro/libra (EUR/GBP).

Já na modelagem do CFaR para a empresa norueguesa Norsh Hydro, Andrén *et al* (2005) identificaram como fatores de risco as taxas de câmbio da coroa norueguesa contra o euro e contra os dólares americanos e canadenses; as taxas de inflação na Noruega, União Europeia, Estados Unidos e Canadá; e as taxas de juros de longo prazo na Noruega, União Europeia e Estados Unidos.

Os fluxos de caixa dos órgãos públicos também estão sujeitos a riscos macroeconômicos, relacionados especificamente às atividades do governo federal. O Anexo V da Lei Complementar nº. 101/2000 prevê alguns fatores de risco macroeconômicos que podem afetar a arrecadação e a consequente execução orçamentária do governo Federal.

O referido diploma legal cita como possíveis fontes de risco a taxa de crescimento real do Produto Interno Bruto (g) - pois afeta vários tributos como, por exemplo, o imposto de renda das pessoas físicas e jurídicas; a taxa de inflação – medida pelo Índice de Estimativa da Receita (IRE), o qual é composto por uma média ponderada que atribui 55% à taxa média do Índice Nacional de Preços ao Consumidor Amplo (IPCA) e 45% à taxa média Índice Geral de Preços, Disponibilidade Interna (IGP-DI); taxa de juros básica da economia (SELIC) e a taxa de câmbio real/dólar (BRL/USD).

No caso específico da Marinha do Brasil, que importa equipamentos de defesa principalmente dos Estados Unidos, Inglaterra e alguns outros países da Europa, há a possibilidade de que o fluxo de caixa dessa Força Armada seja impactado pelas variações da taxa de câmbio real/dólar (BRL/USD) e também pelas variações das taxas de câmbio real/libra (BRL/GBP) e real/euro (BRL/EUR). Como as cotações dessas duas últimas taxas de câmbio não apresentam tanta liquidez quando comparadas às cotações dólar/euro (USD/EUR) e dólar/libra (USD/GBP), essas últimas cotações foram escolhidas para capturar a

exposição do fluxo de caixa da Marinha às oscilações da libra e do euro, uma vez que a taxa de câmbio BRL/GBP é igual ao produto de BRL/USD e USD/GBP; e a taxa de câmbio BRL/EUR é igual ao produto de BRL/USD e USD/EUR. Adicionalmente, ao se escolher as cotações USD/EUR e USD/GBP evita-se um eventual problema de multicolinearidade, pois as BRL/GBP e BRL/EUR incorporariam informação já contida na cotação BRL/USD.

A inflação dos Estados Unidos medida pelo *Consumer Price Index* (CPI) também foi considerada como potencial fator de risco pelo fato de influenciar o câmbio real de compra de equipamentos naquele país

Por fim, foram incluídos na lista de fatores de risco a taxa de juros de longo prazo (TJLP), como *proxy* do custo do crédito no longo prazo no Brasil (Perobelli, 2011), e a Necessidade de Financiamento do Setor Público (NFSP) medida em percentual do PIB.

Em resumo, nove potenciais fatores de risco foram testados dentro do contexto do *exposure-based cash-flow-at-risk model*: g, IRE, SELIC, TJLP, BRL/USD, USD/EUR, USD/GBP, CPI e NFSP. A Tabela 15 descreve esses fatores de risco em periodicidade trimestral, bem como as respectivas fontes desses dados.

Tabela 15: Descrição das variáveis independentes utilizadas e fonte dos dados

Variável	Definição	Fonte
g	Variação real do PIB (% a.t) – medido em relação ao trimestre anterior deflacionado pelo IGPDI a valores de fev/1999.	IBGE
IRE	Índice de Estimativa de Receita – média ponderada entre IPCA (55%) e IGP-DI (45%) – média trimestral.	
IPCA	Índice Nacional de Preços ao Consumidor Amplo (%a.m) - média trimestral.	IPEA
IGP-DI	Índice Geral de Preços, Disponibilidade Interna (% a.m) - média trimestral.	IPEA
SELIC	Taxa de juros básica da economia (% a.m)	Banco Central
TJLP	Taxa de Juros de Longo Prazo (% a.a)	Banco Central
BRL/USD	Taxa de câmbio nominal real/dólar comercial - média trimestral.	Banco Central
USD/EUR	Taxa de câmbio nominal dólar/euro - média trimestral.	Bloomberg
USD/GBP	Taxa de câmbio nominal dólar/libra - média trimestral.	Bloomberg
CPI	Taxa de inflação dos Estados Unidos (% a.a).	Bloomberg
NFSP	Necessidade de Financiamento do Setor Público (%PIB).	Banco Central

Fonte: Própria

4.4 Metodologia

A metodologia utilizada neste trabalho segue Andr  n, Jankensgard e Oxelheim (2005), que utilizaramo *Exposed-Based Model* e t  cnicas de simula  o, como base para o c  lculo do fluxo de caixa em risco - CFaR.

4.4.1 Exposure-based model

O *Exposure-Based Model* consiste em uma regress  o linear m  ltipla, na qual a vari  vel dependente    o fluxo de caixa da institui  o e as vari  veis explicativas (vari  veis independentes) s  o os fatores de risco macroecon  micos e de mercado com potencial para afetar a vari  vel dependente. Esse modelo pode ser representado pela equa  o (33):

$$CF_t - E(CF_t|I_{t-1}) = \beta_0 + \sum_{i=1}^n \beta_i (X_{it} - E(X_{it}|I_{t-1})) + \varepsilon_t \quad (33)$$

Onde CF_t representa o fluxo de caixa no per  odo t ; $X_t = [g, IRE, SELIC, TJLP, BRL/USD, USD/EUR, USD/GBP, CPI \text{ e } NFSP]$; e $E(X_{it}|I_{t-1})$ representa o valor esperado da vari  vel X_i no tempo t , dadas as informa  es em $t-1$.

Como os riscos derivam dos desvios em rela  o aos valores esperados de cada vari  vel, a regress  o acima evidencia que o risco do fluxo de caixa $[CF_t - E(CF_t|I_{t-1})]$    dependente dos riscos associados   s vari  veis independentes $[X_{it} - E(X_{it}|I_{t-1})]$

Yan *et al* (2014) argumentam que os coeficientes produzidos pela regress  o m  ltipla medem o grau de exposi  o do fluxo de caixa a cada fator de risco - o que poderia determinar a quantidade de contratos a serem adquiridos no mercado de derivativos para reduzir o efeito dessas exposi  es; servem para ajustar os fluxos de caixa hist  ricos por meio da filtra  em dos impactos dos riscos macroecon  micos e de mercado; e proveem a base para o c  lculo do CFaR.

Dados os fluxos de caixa trimestrais da Marinha, assumiu-se que a distribui  o das vari  veis seguiria um passeio aleat  rio, o que significa que todas as varia  es s  o inesperadas. O princ  pio das expectativas racionais implica que toda a informa  o necess  ria em $t-1$ para a previs  o do pre  o em t est   contida no pre  o em $t-1$, desse modo tem-se que:

$$E(CF_t|I_{t-1}) = CF_{t-1} \text{ e } E(X_t|I_{t-1}) = X_{t-1} \quad (34)$$

Assim, a equação (33) poderia ser representada segundo a forma reduzida representada na equação (35), qual inclui séries dos fatores de risco defasadas no tempo:

$$\Delta CF_t = \beta_0 + \sum_{i=1}^n \sum_{k=0}^p \beta_{it-k} \Delta X_{it-k} + \varepsilon_t \quad (35)$$

4.4.2 Simulação do CFaR

Para calcular a distribuição condicional dos fluxos de caixa, o modelo de regressão múltipla foi utilizado em conjunto com a matriz de covariâncias das variáveis independentes estatisticamente significativas (macroeconômicas e de mercado) identificadas no *exposure model*.

Posteriormente, simulações foram realizadas para as variáveis independentes, de forma que a matriz de covariâncias entre essas variáveis independentes permanecesse constante. Em cada interação, os valores das variáveis independentes são gerados randomicamente e inseridos no modelo de regressão para gerar a simulação dos fluxos de caixa condicionados às variáveis macroeconômicas e de mercado. Como 10.000 cenários para as variáveis independentes foram simulados, obteve-se 10.000 valores de fluxos de caixa simulados.

Para se estimar o fluxo de caixa total, faz-se necessário complementar a distribuição do fluxo de caixa condicional com a distribuição do termo de erro (ε). Assume-se que o erro não tem correlação com as variáveis explicativas, podendo sua distribuição ser obtida por meio de uma distribuição normal ($\varepsilon \sim N(0, \sigma^2)$). Desse modo, soma-se o valor ε ao valor obtido para o fluxo de caixa condicionado para que se possa obter a distribuição do fluxo de caixa total.

Em resumo, o cálculo do *Exposure-Based CFaR*, proposto por Andrén *et al*(2005), foi efetuado por meio da realização de seis passos.

Primeiro, com o conjunto trimestral de dados (CF_t , X_{it}) do primeiro trimestre de 1999 ao quarto trimestre de 2013, estimou-se os coeficientes ($\hat{\beta}_i$). Segundo, calculou-se a média e a matriz de covariâncias das primeiras diferenças das variáveis independentes (ΔX_{it}). Terceiro, foram gerados 10.000 novos valores para $\Delta X_{i,1T2014}$ dados a média e a matriz de covariâncias:

$$\Delta X_{i,1T2014} \sim N(\mu, \Omega) \quad (36)$$

Onde o vetor média é igual a $\mu = E(\Delta X_{1,T2014}, \Delta X_{2,T2014} \dots \Delta X_{n,T2014})$ e a matriz de covariância igual a $\Omega = COV(\Delta X_{i,T2014}, \Delta X_{j,T2014})_{i,j=1,2,\dots,n}$.

Quarto, foram simulados 10.000 termos de erro (ε_{1T2014}) para o primeiro trimestre de 2014:

$$\varepsilon_{1T2014} \sim N(0, \sigma^2) \quad (37)$$

Quinto, previu-se a volatilidade dos fluxos de caixa da Marinha para o primeiro trimestre de 2014 como sendo a soma da constante, dos valores simulados para as variáveis independentes multiplicados pelos coeficientes de exposição e dos termos de erro, de acordo com a equação (38).

$$\Delta CF_{1T2014} = \beta_0 + \sum_{i=1}^n \beta_i \Delta X_{i,T2014} + \varepsilon_{1T2014} \quad (38)$$

Por fim, a distribuição do fluxo de caixa da Marinha para o primeiro trimestre de 2014 foi obtida de acordo com a equação (39).

$$\begin{aligned} CF_{1T2014} &= E(CF_{1T2014} | I_{4T2013}) + \Delta CF_{1T2014} \\ &= CF_{4T2013} + \Delta CF_{1T2014} \end{aligned} \quad (39)$$

Ressalta-se que antes de analisar os resultados, é fundamental que se verifique se os efeitos dos diferentes fatores de risco no fluxo de caixa da Marinha estão em conformidade com a teoria econômica, já que, segundo Andrén *et al* (2005), especificar um modelo de exposição a riscos é uma combinação de ciência e arte.

4.5 Resultados

4.5.1 Exposure-based model

Inicialmente, usou-se uma regressão múltipla para se verificar a significância estatística dos potenciais fatores de risco escolhidos, conforme os motivos descritos na seção 4.3.2, e de variáveis *dummy* trimestrais para detectar a presença de efeitos sazonais. Os fatores de risco escolhidos e algumas de suas estatísticas descritivas encontram-se detalhados na Tabela 16.

Tabela 16: Estatísticas Descritivas das Variáveis Independentes Utilizadas

Variável	Definição	Nº Obs	Média	Desvio-Padrão
g	Variação real do PIB (% a.t)	59	0,93	3,10
IRE	Índice de Estimativa de Receita – média ponderada entre IPCA (55%) e IGP-DI (45%)	59	0,60	0,48
IPCA	Índice Nacional de Preços ao Consumidor Amplo (%a.m)	59	0,53	0,33
IGP-DI	Índice Geral de Preços, Disponibilidade Interna (% a.m)	59	0,69	0,73
SELIC	Taxa de juros básica da economia (% a.m)	59	1,14	0,36
TJLP	Taxa de Juros de Longo Prazo (% a.a)	59	8,17	2,44
BRL/US	Taxa de câmbio real/dólar comercial	59	2,20	0,49
D				
USD/EU	Taxa de câmbio dólar/euro	59	1,22	0,19
R				
USD/GB	Taxa de câmbio dólar/libra	59	1,67	0,18
P				
CPI	Taxa de inflação dos Estados Unidos (% a.a)	59	2,43	1,22
NFSP	Necessidade de Financiamento do Setor Público (%PIB)	59	2,32	1,72

Fonte: Própria

Entretanto, constatou-se a presença de autocorrelação dos resíduos, por meio do teste de Breusch-Godfrey, bem como a presença de heterocedasticidade na aplicação do teste White (1980). Para resolver o problema foi utilizada a regressão robusta proposta por Newey-West (1987), na qual a estimação dos parâmetros é robusta mesmo na presença de autocorrelação e heterocedasticidade. Essa regressão revelou que os fatores de risco g, IRE, TJLP e a taxa de câmbio USD/EUR não apresentaram coeficientes estatisticamente significativos, motivo pelo qual foram excluídos do modelo.

Após a exclusão dos fatores de risco mencionados acima, uma nova regressão robusta foi calculada usando-se cinco fatores de risco: SELIC, BRL/USD, USD/GBP, CPI e NFSP. Para contornar o problema de autocorrelação dos resíduos detectado pelo teste de Breusch-Godfrey, Ruppert (2010, p. 369) sugere substituir a hipótese de independência dos erros pela hipótese mais relaxada de que os erros seguem um processo estacionário, mas, possivelmente, correlacionado. Desse modo, adicionou-se à regressão múltipla um termo de

média móvel de primeira ordem, MA(1), após o critério de informação de Akaike (1974) revelar que os erros seguiam um processo ARMA(0,1).

Além disso, foram adicionadas duas variáveis *dummy* ao modelo. Uma para o quarto trimestre de 2010 (Dum10q4) e outra para o quarto trimestre de 2011 (Dum11q4). Essas variáveis foram incluídas com o propósito de capturar o efeito do início do Programa de Submarinos da Marinha, cujos vultosos valores envolvidos para a sua implantação distorceram a série histórica de seus fluxos de caixa para esses trimestres.

4.5.2 Resultados esperados

Andrén *et al.* (2005) sugerem que o melhor modelo de exposição deve incluir variáveis alinhadas com a teoria econômica e suportadas por evidências empíricas. Em outras palavras, para ser aceito como ferramenta adequada de gestão, um modelo de estimação de risco não deve apenas ter suporte estatístico, com elevados níveis de significância dos coeficientes, elevado (R^2) e sem problemas de autocorrelação; mas, apresentar coeficientes que representem uma relação entre as variáveis que faça sentido teórico à luz do comportamento do fluxo de caixa da Marinha.

Representando o custo do crédito no curto prazo, a taxa SELIC deve afetar negativamente o fluxo de caixa da Marinha, pois um aumento dessa taxa representaria maior desembolso de recursos do governo federal para o pagamento dos juros de sua dívida, reduzindo, portanto, os recursos a serem distribuídos para os demais Órgãos Públicos, dentre os quais a Marinha. Adicionalmente, faz-se necessário testar o efeito dessa variável defasada no tempo.

Com relação à taxa de câmbio BRL/USD, não é possível vislumbrar seu resultado líquido no fluxo de caixa da Marinha, haja vista que a variação dessa taxa de câmbio pode apresentar efeitos de sinais e magnitude distintos. Um dos efeitos, por exemplo, estaria relacionado ao fato de a Marinha ser importadora de equipamentos dos Estados Unidos, o que implicaria em relação negativa entre a taxa de câmbio mencionada e o fluxo de caixa. Por outro lado, Martner (1992) esclarece que, com relação aos impostos do comércio exterior, a desvalorização aumenta arrecadação nominal pela elevação, em moeda nacional, das importações e das exportações, se tais impostos forem *ad valorem*, isto é, baseados em um percentual sobre o valor do bem. Para esse caso, por aumentar a arrecadação

nominal, a taxa de câmbio apresentaria relação positiva com o fluxo de caixa da Marinha.

Já quanto à exposição da Marinha ao movimento da libra, medido pela taxa de câmbio USD/GBP - já que a cotação BRL/GBP pode ser calculada pelo produto entre as cotações BRL/USD e USD/GBP - espera-se uma relação negativa, já que a Marinha importa muitos equipamentos da Inglaterra, possuindo inclusive um escritório nesse país para facilitar a importação desses equipamentos. Assim, para os casos de não variação da cotação BRL/USD, uma depreciação do dólar em relação à libra corresponderia à desvalorização do real em relação à libra, indicando que os bens importados ficariam mais caros em reais, o que reduziria o fluxo de caixa da Marinha.

Para a inflação dos Estados Unidos (CPI), esperam-se dois efeitos possíveis. O primeiro efeito seria de que um aumento na taxa de inflação americana implicaria aumento nos custos da Marinha, pois esta como importadora passaria a pagar mais caro – em dólares – pelos equipamentos, o que reduziria seu fluxo de caixa. Por outro lado, quando há aumento na taxa de inflação americana, o preço, em dólares, dos bens importados por todas as empresas do país aumenta e, como consequência, impostos como o Imposto sobre Importação (II) e o Imposto sobre Produtos Industrializados Vinculado à Importação (IPI-Vinculado) também aumentam, o que representaria um aumento da arrecadação do governo federal e, consequentemente, maior disponibilidade de caixa para distribuir para os demais órgãos públicos, dentre eles a Marinha.

No que tange à Necessidade de Financiamento do Setor Público (NFSP), espera-se uma relação positiva com o fluxo de caixa da Marinha, pois o aumento nessa variável corresponderia a um aumento dos recursos aplicados no orçamento do Governo Federal, o que contribuiria para o aumento do fluxo de caixa Marinha, apesar de poder contribuir para o aumento da taxa de juros. A Tabela 17 apresenta os resultados do *exposure-based model* do fluxo de caixa da Marinha do Brasil, os quais serão analisados na seção seguinte.

Tabela 17: Resultados do *exposure-based model*

Variável	Coefficiente	p-valor
C	34,95	0,0010
Dum11q4	99,09	0,0003
Dum10q4	-107,27	0,0000
SELIC	-40,09	0,0000
BRL/USD	13,48	0,0003
CPI	4,72	0,0234
NFSP	2,78	0,0275
USD/GBP	-19,45	0,0176
MA(1)	0,98	0,0000
	Valor	p-valor
R^2	0,71	
Adj R^2	0,68	
Erro padrão da Regressão	28,9	
Breusch-Godfrey (autocorrelação)	1,83	0,14
Jarque-Bera (normalidade)	8,55	0,014
Augmented Dickey-Fuller (H ₀ : Há raiz unitária)	-10,17	0,000

Fonte: Própria

4.5.3 Análise da exposição aos riscos

O *exposure-based model* para o fluxo de caixa da Marinha revela a significância das variáveis *dummy* utilizadas. Caso essas variáveis não fossem incluídas, os coeficientes dos fatores de risco selecionados continuariam significantes a 5%, mas o R^2 e o R^2 ajustado do modelo seriam reduzidos para 0,50 e 0,45, respectivamente. Além disso, o modelo indica que o aumento de um ponto percentual na taxa mensal da SELIC, corresponderia, em média, a uma redução de R\$ 40,09 milhões daquele fluxo de caixa, o que confirma a expectativa de correlação negativa entre essas variáveis.

A observação da exposição à taxa de câmbio BRL/USD revela que, para cada aumento de R\$1,00 na taxa de câmbio, o fluxo de caixa da Marinha aumenta, em média, R\$ 13,48 milhões. De acordo com a metodologia utilizada, esse seria o resultado líquido dos diversos efeitos causados pela desvalorização da taxa de câmbio, a qual, segundo Martner (1992), desencadeia uma dinâmica macroeconômica complexa e difícil de quantificar. No que concerne à taxa de inflação americana (CPI), nota-se que o incremento de uma unidade percentual dessa variável representaria, em média, um aumento de R\$ 4,72 milhões no fluxo de caixa. Essa relação positiva entre CPI e fluxo de caixa pode ser explicada em parte pela elevação da arrecadação nominal do Governo Federal oriunda dos impostos do comércio exterior relativos a bens importados mais caros.

Já a redução, em média, de R\$ 19,44 milhões no fluxo de caixa da Marinha para cada aumento de US\$ 1,00 na taxa de câmbio USD/GBP vai ao encontro das expectativas mencionadas anteriormente já que a Marinha importa frequentemente equipamentos e itens sobressalentes da Inglaterra.

O modelo de exposição também revela que para cada aumento percentual da NFSP em relação ao PIB, a variação do fluxo de caixa da Marinha é maior, em média, em R\$ 2,78 milhões. Esse resultado, como já relatado, também vai ao encontro dos resultados esperados. Entretanto, além de evidenciar relações pertinentes entre as variáveis de interesse, o referido modelo apresenta outros benefícios.

Por exemplo, na Tabela 18, que mostra as correlações das variáveis independentes após serem diferenciadas uma vez (ΔX_{it}), verifica-se que USD/GBP e CPI são positivamente correlacionados, mas, de acordo com a Tabela 17, o fluxo de caixa da Marinha apresenta exposição negativa em relação ao primeiro fator de risco (-19,45) e, positiva em relação ao segundo (4,72). Assim, o efeito combinado dessas variáveis independentes tenderá, em média, a reduzir o risco do fluxo de caixa da Marinha.

Tabela 18: Correlação das variáveis independentes depois de diferenciá-las

	CPI	USD/GBP	NFSP	BRL/USD	SELIC
CPI	1				
USD/GBP	0,26	1			
NFSP	-0,24	-0,24	1		
BRL/USD	-0,23	-0,29	0,09	1	
SELIC	0,06	-0,16	0,19	0,12	1

Fonte: Própria


Outro benefício do *Exposure-based CFaR model* é sua capacidade de facilitar as decisões de *hedge*, uma vez que a informação sobre o volume financeiro a ser protegido está contida nos coeficientes do modelo. Por exemplo, na Tabela 16 observa-se uma exposição de R\$ 13,48 milhões para cada redução unitária na taxa de câmbio (BRL/USD). Isso significa que se o gestor esperar uma queda unitária dessa taxa de câmbio e quiser neutralizar sua exposição a esse fator de risco para o próximo trimestre, ele poderá buscar, no mercado financeiro, proteção proporcional ao tamanho dessa exposição. Todavia, Andrén *et al* (2005) relembram que os coeficientes de exposição são estimados estatisticamente e, portanto, são associados à incerteza.

4.5.4 Simulação do cash-flow-at-risk

Usando-se a matriz de covariâncias das variáveis independentes estatisticamente significativas, simulou-se 10.000 cenários para essas variáveis. Desse modo, seguindo-se a metodologia descrita na seção 4.2, para cada uma das 10.000 simulações, estimou-se o fluxo de caixa da Marinha como uma função das variáveis macroeconômicas e de mercado simuladas multiplicadas pelos seus respectivos coeficientes de exposição, mais uma constante e uma série de erros gerada por um processo de média móvel de primeira ordem – MA(1) em função da identificação de autocorrelação nos resíduos da regressão múltipla estimada.

Ao seguir essa metodologia, chegou-se a uma distribuição do esperado fluxo de caixa da Marinha, a qual reflete o fluxo de caixa sensível a cada fator de risco e a esperada covariância entre esses fatores.

Essa distribuição permitiu que se calculasse o CFaR da Marinha. Como pode se observar na Figura 4, há 5% de chance de o fluxo de caixa da Marinha, conforme definido na seção 4.3.1, cair abaixo -R\$ 55,225 milhões.



A Tabela 19 apresenta o CFaR da Marinha como percentual do fluxo de caixa esperado.

Tabela 19: Estimativas do *Exposure-based CFaR* para o 1Tri/2014

	Fluxo de Caixa Esperado (Média)	CFaR a 5% de nível de confiança	CFaR em percentual ($ A-B /A \times 100$)
	(A)	(B)	
Fluxo de Caixa da Marinha do Brasil (Em R\$ milhões)	9,354	-55,225	690%

Fonte: Própria

Pela Tabela 19 nota-se que, com 95% de nível de confiança, o fluxo de caixa esperado não cairá por um valor maior que R\$ 64,579 milhões. Em outras palavras, em um a cada vinte cenários espera-se que o fluxo de caixa caia abaixo de R\$ -55,225 milhões ($=9,354-64,579$).

4.6 Conclusão

A preocupação das instituições financeiras e não financeiras com a administração de riscos já se manifesta há muito tempo. Todavia, faz-se necessário discutir a adoção de métricas de risco também para as instituições publicas.

Este trabalho lançou mão do modelo do *Cash-Flow at Risk* para estimar o risco de liquidez de um Órgão da Administração Pública Direta: a Marinha do Brasil. Os resultados demonstram que, em média, a Marinha apresentaria fluxo de caixa positivo da ordem de R\$ 9,354 milhões para o primeiro trimestre de 2014. Entretanto, conforme pôde ser verificado pelo cálculo do CFaR, há 5% de chance de o fluxo de caixa da Marinha ficar abaixo de -R\$55,225 milhões para o mesmo período, o que evidencia, portanto, sua grande volatilidade, uma vez que esse risco de queda medido pelo CFaR representa uma variação negativa de 690% em relação ao valor do fluxo de caixa esperado.

Por fim, há que se reconhecer limitações a esse estudo, principalmente pelo fato de os dados de fluxo de caixa disponíveis estarem restritos aos da Marinha do Brasil. Estudos futuros poderiam lançar mão de dados do Exército Brasileiro (EB) e da Força Aérea Brasileira (FAB) para se obter uma medida de risco de liquidez no âmbito de todo o setor de defesa brasileiro, o que aumentaria a robustez da investigação realizada nesse trabalho.

Além disso, o modelo parte do pressuposto que a correlação dos fatores de risco é constante ao longo do tempo. Todavia, Tsay (2010, p. 525) esclarece que em aplicações reais as correlações tendem a variar ao longo do tempo. Assim, trabalhos futuros poderiam lançar mão de modelos que permitam a variação temporal da matriz de correlações como é o caso dos modelos de correlação dinâmica.

Outra limitação deste ensaio é o uso da TJLP como *proxy* do custo do crédito de longo prazo no Brasil. Como essa taxa é determinada pelo Governo, estudos futuros poderiam utilizar as Notas do Tesouro Nacional com vencimentos longos para capturar o efeito do custo do crédito no longo prazo.

5 Conclusão

Fruto do incremento da volatilidade nos mercados ocasionada, tanto pela recente crise financeira internacional, quanto pela intensificação do fluxo de capitais para os países emergentes; esta tese foi composta por três ensaios, dos quais dois avaliaram os riscos de mercado de alguns países emergentes, enquanto que o terceiro estimou e analisou o risco de liquidez de um Órgão Público brasileiro.

No primeiro ensaio mostrou-se que observações mais antigas são relativamente mais importantes que as mais recentes na previsão de volatilidade para horizontes de previsão mais longos, quando se utiliza modelos da família GARCH. Essa conclusão é relevante, pois as previsões de volatilidade para períodos superiores a um dia são necessárias para o apreçamento de opções e para o cálculo de medidas de Value-at-Risk (VaR), nas situações em que os horizontes de previsão são superiores à frequência de observação dos dados utilizados para gerar essas previsões.

No segundo ensaio investigou-se se a utilização dos modelos de memória longa (FIGARCH) melhora a previsão para observações fora da amostra (out-of-sample) de VaR e ES para múltiplos períodos à frente para os retornos dos índices de ações de Brasil, África do Sul, Rússia, Índia e Turquia. Concluiu-se que os modelos de memória longa apresentaram melhor desempenho que os modelos de memória curta com o aumento do horizonte de previsão. Ademais, verificou-se que, para observações dentro da amostra (*in-sample*), em geral, os modelos FIGARCH superaram os modelos GARCH na descrição dos retornos dos índices de ações investigados.

Por fim, no terceiro ensaio desta tese, abordou-se a utilização de métricas de risco em um Órgão Público de um país emergente: a Marinha do Brasil. Por meio da utilização do *Cash-Flow-at-Risk model* foi possível estimar o risco de liquidez da Marinha do Brasil, bem como detectar os fatores de risco macroeconômicos e de mercado que impactam seus fluxos de caixa.

Este trabalho teve como propósito contribuir com a literatura acerca da previsão de volatilidade e medidas de risco de longo prazo em mercados emergentes, considerada reduzida quando comparada àquelas referentes aos mercados de países desenvolvidos. Além disso, o trabalho propôs a aplicação de um modelo de gerenciamento de riscos no âmbito de um Órgão Público. Entretanto, este estudo apresentou a limitação de usar um tamanho único para a amostra utilizada na estimação dos modelos de previsão de volatilidade, VaR e ES. Angelidis *et al* (2004) destacam que, dependendo do tamanho da amostra adotado para a estimação, pode-se chegar a resultados distintos. Assim, visando a dar maior robustez aos resultados encontrados nos dois primeiros ensaios, sugere-se que estudos futuros lancem mão de tamanhos de amostra distintos para a estimação dos modelos utilizados para previsão.

No que concerne à estimação do *Cash-Flow-at-Risk* para Órgãos Públicos, sugere-se que estudos futuros ampliem o escopo de análise para outros Órgãos Públicos e que lancem mão de modelos que permitam a variação temporal da matriz de correlações como é o caso dos modelos de correlação dinâmica.

ACERBI, C.; TASCHE, D. On the coherence of expected shortfall. **Journal of Banking & Finance**, v. 26, n. 7, p. 1487-1503, 2002. ISSN 0378-4266. Disponível em:

<<http://www.sciencedirect.com/science/article/pii/S0378426602002832>>.

AKAIKE, H. **A new look at the statistical model identification**. Automatic Control, IEEE Transactions on, v. 19, n. 6, p. 716-723, 1974. ISSN 0018-9286.

ALBUQUERQUE, C.; MEDEIROS, M.; FEIJÓ, P. H. **Gestão de Finanças Públicas**. 1. Brasília: v. 488. 2006.

ALLOUI, C.; HAMIDA, H. B. Modelling and forecasting value at risk and expected shortfall for GCC stock markets: Do long memory, structural breaks, asymmetry, and fat-tails matter? **The North American journal of economics and finance**, v. 29, p. 349-380, 07/01 2014. ISSN 1062-9408.

_____.; MABROUK, S. Value-at-risk estimations of energy commodities via long-memory, asymmetry and fat-tailed GARCH models. **Energy Policy**, v. 38, n. 5, p. 2326-2339, 2010. ISSN 0301-4215. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0301421509009768>>.

ANDERSEN, T. G.; BOLLERSLEV, T. Heterogeneous Information Arrivals and Return Volatility Dynamics: Uncovering the Long-Run in High Frequency Returns. **The Journal of Finance**, v. 52, n. 3, p. 975-1005, 1997. ISSN 00221082. Disponível em: <<http://www.jstor.org/stable/2329513>>.

_____.; _____.; DIEBOLD, F.X. Chapter 15 Volatility and Correlation Forecasting. In: G. ELLIOTT, C. W. J. G. A. A. T. (Ed.). **Handbook of Economic Forecasting**; Elsevier, v. 1, p.777-878. 2006. ISBN 1574-0706.

ANDRÉN, N.; JANKENSGARD, H.; OXELHEIM, L. Exposure-Based Cash-Flow-at-Risk: An Alternative to VaR for Industrial Companies. **Journal of Applied Corporate Finance**, v. 17, n. 3, p. 11, 2005. ISSN 1745-6622.

ANGELIDIS, T.; BENOS, A.; DEGIANNAKIS, S. The use of GARCH models in VaR estimation. **Statistical Methodology**, v. 1, n. 1, p. 105-128, 2004. ISSN 1572-3127.

_____.; DEGIANNAKIS, S. Backtesting VaR models: A two-stage procedure. **Journal of Risk Model Validation**, v. 1, n. 2, p. 27-48, 2007.

ARTZNER, P.; DELBAEN, F.; EBER, J.; HEATH, D. Thinking coherently. **Risk**, n. 10, p. 68-71, 1997.

BAILLIE, R. T.; BOLLERSLEV, T.; MIKKELSEN, H. O. Fractionally integrated generalized autoregressive conditional heteroskedasticity. **Journal of Econometrics**, v. 74, n. 1, p. 3-30, 1996. ISSN 0304-4076. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0304407695017496>>.

BASEL COMMITTEE ON BANKING SUPERVISION. **Amendment to the capital accord to incorporate market risks**. Basel 1996.

BAUMAN, J.; SARATORE, S.; LIDDLE, W. **A practical framework for corporate exposure management**. London: Risk Publication 1999.

BLACK, F.; SCHOLES, M. The Pricing of Options and Corporate Liabilities. **Journal of Political Economy**, v. 81, n. 3, p. 637-654, 1973. ISSN 00223808. Disponível em: <<http://www.jstor.org/stable/1831029>>.

BLOOMBERG. Bloomberg Markets. 2013. Disponível em: <<http://www.bloomberg.com/slideshow/2013-01-30/the-top-20-emerging-markets.html#slide15>>. Acesso em: 17/09/2015.

BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. **Journal of Econometrics**, v. 31, n. 3, p. 307-327, 4// 1986. ISSN 0304-4076. Disponível em:

<<http://www.sciencedirect.com/science/article/pii/0304407686900631>>.

_____.; OLE MIKKELSEN, H. Modeling and pricing long memory in stock market volatility. **Journal of Econometrics**, v. 73, n. 1, p. 151-184, 1996. ISSN 0304-4076. Disponível em:

<<http://www.sciencedirect.com/science/article/pii/0304407695017364>>.

_____.; WOOLDRIDGE, J. M. Quasi-maximum likelihood estimation and inference in dynamic models with time-varying covariances. **Econometric reviews**, v. 11, n. 2, p. 143-172, 1992. ISSN 0747-4938.

BRASIL. **Lei Complementar nº 101, 4 de maio 2000**.

BROOKS, C. **Introductory econometrics for finance**. Cambridge university press, 2014. ISBN 1139916459.

CAPORIN, M. Evaluating value-at-risk measures in the presence of long memory conditional volatility. **Journal of Risk**, v. 10, n. 3, p. 79, 2008 Spring 2008. ISSN 14651211. Disponível em:

<<http://go.galegroup.com/ps/i.do?id=GALE%7CA177943208&v=2.1&u=capes&it=r&p=AONE&sw=w&asid=23be685f79e9a7bd66787f0987bff130>>. Acesso em: 11/10/2015.

CHRISTOFFERSEN, P. F. **Elements of financial risk management**. 2nd. United States: Elsevier, 2012.

_____. Evaluating interval forecasts. **International Economic Review**, v. 39, n. 4, p. 841-862, 1998. ISSN 0020-6598.

_____.; DIEBOLD, F. X. How relevant is volatility forecasting for financial risk management? **Review of Economics and Statistics**, v. 82, n. 1, p. 12-22, 2000.

_____.; _____.; SCHUERMANN, T. Horizon problems and extreme events in financial risk management. **Economic Policy Review**, v. 4, n. 3, p. 98-16, 1998.

CHUNG, C. F. Estimating the fractionally integrated GARCH model. **unpublished paper**, National Taiwan University, 1999.

CLARK, T. E.; MCCracken, M. W. Tests of equal forecast accuracy and encompassing for nested models. **Journal of econometrics**, v. 105, n. 1, p. 85-110, 2001. ISSN 0304-4076.

CROUHY, M.; GALAI, D.; MARK, R. **Risk Management**. New York: McGraw-Hill, 2000. ISBN 978-0-07-135731-9.

DANIELSSON, J. **Financial risk forecasting: the theory and practice of forecasting market risk with implementation in R and Matlab**. John Wiley & Sons, 2011. ISBN 1119977118.

DEGIANNAKIS, S.; FLOROS, C.; DENT, P. Forecasting value-at-risk and expected shortfall using fractionally integrated models of conditional volatility: International evidence. **International Review of Financial Analysis**, v. 27, p. 21-33, 2013. ISSN 1057-5219. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S1057521912000397>>.

DIEBOLD, F. X.; MARIANO, R. S. Comparing Predictive Accuracy. **Journal of Business & Economic Statistics**, v. 13, n. 3, p. 253-263, 1995.

DING, Z.; GRANGER, C. W. Modeling volatility persistence of speculative returns: a new approach. **Journal of econometrics**, v. 73, n. 1, p. 185-215, 1996. ISSN 0304-4076.

_____.; _____.; ENGLE, R. F. A long memory property of stock market returns and a new model. **Journal of empirical finance**, v. 1, n. 1, p. 83-106, 1993. ISSN 0927-5398.

DUARTE JR, A. M.; VARGA, G. Gestão de riscos no Brasil. **Rio de Janeiro: Financial Consultoria**, 2003.

EDERINGTON, L. H.; GUAN, W. Forecasting volatility. **Journal of Futures Markets**, v. 25, n. 5, p. 465-490, 2005. ISSN 1096-9934.

_____. Longer-Term Time-Series Volatility Forecasts. **Journal of Financial and Quantitative Analysis**, v. 45, n. 4, p. 1055-1076, 2010. ISSN 1756-6916.

ENGLE, R. Risk and volatility: Econometric models and financial practice. **American Economic Review**, v. 94, n. 3, p. 405-420, 2004. ISSN 0002-8282.

_____.; BOLLERSLEV, T. Modelling the persistence of conditional variances. **Econometric reviews**, v. 5, n. 1, p. 1-50, 1986. ISSN 0747-4938.

_____.; MANGANELLI, S. CAViaR: Conditional autoregressive value at risk by regression quantiles. **Journal of Business & Economic Statistics**, v. 22, n. 4, p. 367-381, 2004. ISSN 0735-0015.

_____.; NG, V. K. Measuring and Testing the Impact of News on Volatility. **The Journal of Finance**, v. 48, n. 5, p. 1749-1778, 1993. ISSN 00221082. Disponível em: <<http://www.jstor.org/stable/2329066>>.

FIGLEWSKI, S. Forecasting volatility. **Financial markets, institutions & instruments**, v. 6, n. 1, p. 1-88, 1997. ISSN 1468-0416.

GEWEKE, J.; PORTER-HUDAK, S. The estimation and application of long-memory times series models. **Journal of Time Series Analysis**, v. 4, n. 4, p. 221-238, 1983.

GIACOMINI, R.; WHITE, H. Tests of Conditional Predictive Ability. **Econometrica**, v. 74, n. 6, p. 1545-1578, 2006. ISSN 00129682. Disponível em: <<http://www.jstor.org/stable/4123083>>.

GIOT, P.; LAURENT, S. Value-at-risk for long and short trading positions. **Journal of Applied Econometrics**, v. 18, n. 6, p. 641-663, 2003. ISSN 1099-1255.

_____.; _____. Modelling daily value-at-risk using realized volatility and ARCH type models. **Journal of Empirical Finance**, v. 11, n. 3, p. 379-398, 2004. ISSN 0927-5398.

GROUP, R. **Corporate Metrics: Technical Document**. RiskMetrics Group, 1999.

HANSEN, P. R.; LUNDE, A. A forecast comparison of volatility models: does anything beat a GARCH (1,1)? **Journal of applied econometrics**, v. 20, n. 7, p. 873-889, 2005. ISSN 1099-1255.

HÄRDLE, W. K.; MUNGO, J. **Value-at-Risk and Expected Shortfall when there is long range dependence**. Discussion paper. Germany: Humbolt-universität zuBerlin 2008.

HARRIS, R. I.; SOLLIS, R. **Applied time series modelling and forecasting**. J. Wiley, 2003. ISBN 0470844434.

HAYT, G.; SONG, S. Handle with sensitivity. **Risk**, v. 8, n. 9, p. 94-99, 1995.

INSTITUTE OF INTERNATIONAL FINANCE. **Anual Report 2015**.

JORION, P. **Value at risk: a nova fonte de referência para a gestão do risco financeiro**. 2 Ed. São Paulo: Bolsa de Mercadorias & Futuros, 2003. ISBN 8574380075.

_____. Risk management for hedge funds with position information. **Journal of Portfolio Management**, v. 34, n. 1, p. 127-134, 2007.

KAMAN, S.; TURGUTLU, E.; AYHAN, A. D. Long memory in stock returns. **Applied economics letters**, v. 16, n. 16/18, p. 1763-1768, 2009. ISSN 1350-4851.

KUESTER, K.; MITTNIK, S.; PAOLELLA, M. S. Value-at-risk prediction: A comparison of alternative strategies. **Journal of Financial Econometrics**, v. 4, n. 1, p. 53-89, 2006. ISSN 1479-8409.

KUPIEC, P. Techniques for verifying the accuracy of risk measurement models. **Journal of Derivatives**, v. 3, n. 2, p. 73-84, 1995.

LA ROCQUE, E. D.; LOWENKRON, A. **Métricas e Particularidades da Gestão de Risco em Corporações**. Lista de Riscos. RISKCONTROL. Brasil: RiskControl: 18 p. 2004.

LAURENT, S. **G@RCH 6. An Ox package for estimating and forecasting GARCH models**. London: Timberlake Consultants Press 2009.

LO, A. W. Long-Term Memory in Stock Market Prices. **Econometrica**, v. 59, n. 5, p. 1279-1313, 1991. ISSN 00129682. Disponível em: <<http://www.jstor.org/stable/2938368>>.

MABROUK, S.; SAADI, S. Parametric Value-at-Risk analysis. **The Quarterly review of economics and finance**, v. 52, n. 3, p. 305-321, 2012. ISSN 1062-9769.

MARCELLINO, M.; STOCK, J. H.; WATSON, M. W. A comparison of direct and iterated multistep AR methods for forecasting macroeconomic time series. **Journal of econometrics**, v. 135, n. 1, p. 499-526, 2006. ISSN 0304-4076.

MARTNER, R. Efeitos macroeconômicos de uma desvalorização cambial: análise de simulações para o Brasil. **Pesquisa e Planejamento Econômico**, v. 22, n. 1, p. 35-72, 1992.

MCMILLAN, D. G.; KAMBOUROUDIS, D. Are RiskMetrics forecasts good enough? Evidence from 31 stock markets. **International Review of Financial Analysis**, v. 18, n. 3, p. 117-124, 2009. ISSN 1057-5219.

MINISTÉRIO DA FAZENDA. **Manual de Contabilidade Aplicada ao Setor Público**. NACIONAL, S. D. T. Brasília 2012.

MINISTÉRIO DAS RELAÇÕES EXTERIORES. O que faz o BRICS?, 2014. Disponível em: [http://www.itamaraty.gov.br/index.php?option=com_content&view=article&id=3672&catid=159&itemid=436\(=pt-BR](http://www.itamaraty.gov.br/index.php?option=com_content&view=article&id=3672&catid=159&itemid=436(=pt-BR) >.

MOREIRA, J. M. D. S.; LEMGRUBER, E. F. O uso de dados de alta frequência na estimação da volatilidade e do valor em risco para o IBOVESPA. **Revista Brasileira de Economia**, v. 58, n. 1, p. 100-120, 2004. ISSN 0034-7140.

NAGAYASU, J. Japanese stock movements from 1991 to 2005: evidence from high- and low-frequency data. **Applied Financial Economics**, v. 18, n. 4, p. 295-307, 2008. ISSN 09603107. Disponível em: [http://search.ebscohost.com/login.aspx?direct=true&db=buh&AN=52521124\(=pt-br&site=ehost-live](http://search.ebscohost.com/login.aspx?direct=true&db=buh&AN=52521124(=pt-br&site=ehost-live) >.

NELSON, D. B. Conditional heteroskedasticity in asset returns: A new approach. **Econometrica: Journal of the Econometric Society**, p. 347-370, 1991. ISSN 0012-9682.

NEWBY, W.; WEST, K. A Simple Positive Definite, Heteroskedasticity and Autocorrelation Consistent Covariance Matrix. **Econometrica**, v. 55, n. 3, p. 703-708, 1987.

NYBLOM, J. Testing for the Constancy of Parameters Over Time. **Journal of the American Statistical Association**, v. 84, n. 405, p. 223-230, 1989. ISSN 01621459. Disponível em: <http://www.jstor.org/stable/2289867> >.

OXELHEIM, L.; WIHLBORG, C. **Managing in the Turbulent World Economy**. Corporate Performance and Risk Exposure. 1997.

PEROBELLI, F. F. C.; JANUZZI, F. V.; BERBET, L. J. S.; MEDEIROS, D. S. Fluxo de Caixa em Risco: Diferentes Métodos de Estimação Testados no Setor Siderúrgico Brasileiro. **Revista Brasileira de Finanças**, v. 5, n. 2, p. 165-204, 2007.

POON, S.-H.; GRANGER, C. W. Forecasting volatility in financial markets: A review. **Journal of economic literature**, v. 41, n. 2, p. 478-539, 2003. ISSN 0022-0515.

ROLL, R.; ROSS, S. A. The arbitrage pricing theory approach to strategic portfolio planning. **Financial analysts journal**, v. 40, n. 3, p. 14-26, 1984. ISSN 0015-198X.

_____. The arbitrage pricing theory approach to strategic portfolio planning. **Financial Analysts Journal**, v. 51, n. 1, p. 122-131, 1995. ISSN 0015-198X.

ROSSIGNOLO, A. F.; FETHI, M. D.; SHABAN, M. Value-at-Risk models and Basel capital charges: Evidence from Emerging and Frontier stock markets. **Journal of Financial Stability**, v. 8, n. 4, p. 303-319, 12// 2012. ISSN 1572-3089. Disponível em:
<<http://www.sciencedirect.com/science/article/pii/S1572308911000581> >.

RUPPERT, D. **Statistics and data analysis for financial engineering**. Springer, 2010. ISBN 1441977864.

SHAO, X.-D.; LIAN, Y.-J.; YIN, L.-Q. Forecasting Value-at-Risk using high frequency data: The realized range model. **Global Finance Journal**, v. 20, n. 2, p. 128-136, 2009. ISSN 1044-0283.

SHAPIRO, A.; TITIMAN, S. An Integrated Approach to Corporate Risk Management. In: CHEW, G. B. E. D. (Ed.). **Corporate Risk: Strategies and Management**. London: Risk Publications, 1999.

SHIMKO, D. Cash Before Value: Corporates need to think carefully how they convert cashflow-at-risk to value-at-risk measurements. **Risk-London-Risk Magazine Limited**, v. 11, p. 51-52, 1998. ISSN 0952-8776.

SITIMA, I.; HLATYWAYO, C. K. A Risk Metric Assessment of Scenario-Based Market Risk Measures for Volatility and Risk Estimation: Evidence from Emerging Markets. **South East European Journal of Economics and Business**, v. 9, n. 2, p. 21-32, 2015. ISSN 2233-1999.

STEIN, J. C.; USHER, S.E.; LA GATTUTA, D.; YUGEN, J. A Comparables Approach to Measuring Cashflow-at-Risk for Non-Financial Firms. **Journal of Applied Corporate Finance**, v. 13, n. 4, p. 100-109, 2001. ISSN 1745-6622.

STULZ, R. M. Risk management failures: What are they and when do they happen? **Journal of Applied Corporate Finance**, v. 20, n. 4, p. 39-48, 2008.

_____.; WILLIAMSON, R. **Identifying and quantifying exposures**. Fisher College of Business, 1996.

TANG, T.-L.; SHIEH, S.-J. Long memory in stock index futures markets: A value-at-risk approach. **Physica A: Statistical Mechanics and its Applications**, v. 366, n. 1, p. 437-448, 7/1/2006. ISSN 0378-4371. Disponível em:
<<http://www.sciencedirect.com/science/article/pii/S0378437105010903> >.

TAYLOR, S. J. Forecasting the volatility of currency exchange rates. **International Journal of Forecasting**, v. 3, n. 1, p. 159-170, 1987. ISSN 0169-2070.

TSAY, R. S. **Analysis of financial time series**. John Wiley & Sons, 2010. ISBN 978-0-470-41435-4.

TURNER, C. Var is an Industrial Tool: How an industrial corporate can measure the risk to its earnings using VAR. **Risk London-Risk Magazine Limited**, v. 9, n. 3, p. 38-41, 1996. ISSN 0952-8776.

VERMEULEN, E. **Corporate risk management: a multi-factor approach=Risico-management: een multi-factor benadering**. [Rotterdam]: Tinbergen Research Institute, 1994. ISBN 9051703031.

VILASUSO, J. Forecasting exchange rate volatility. **Economics Letters**, v. 76, n. 1, p. 59-64, 6// 2002. ISSN 0165-1765. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0165176502000368>>.

WHITE, H. A heteroskedasticity-consistent covariance matrix estimator and a direct test for heteroskedasticity. **Econometrica: Journal of the Econometric Society**, v. 48, n. 4, p. 817-838, 1980. ISSN 0012-9682.

XEKALAKI, E.; DEGIANNAKIS, S. **ARCH models for financial applications**. United Kingdom: John Wiley & Sons, 2010.

YAN, M.; MAXIMILIAN, J. B.; TURNER, P. Estimating liquidity risk using the exposure-based cash-flow-at-risk approach: An application to the UK banking sector. **International journal of finance and economics**, 2014. ISSN 1076-9307.

ZAKOIAN, J.-M. Threshold heteroskedastic models. **Journal of Economic Dynamics and control**, v. 18, n. 5, p. 931-955, 1994. ISSN 0165-1889.

7 Apêndice

De acordo com as contribuições de Degiannakis *et al.*(2013), Xekalaki e Degiannakis (2010), e Christoffersen (2012), apresenta-se o algoritmo de simulação de Monte Carlo utilizado para o cálculo de $\text{VaR}_{t+\tau|t}^{(95\%)}$ e $\text{ES}_{t+\tau|t}^{(95\%)}$ baseado em modelo fracionalmente integrado de volatilidade condicional. Considere a especificação AR (1)-FIGARCH (1,1):

$$\begin{aligned} y_t &= c_0(1 - c_1) + c_1 y_{t-1} + \varepsilon_t \\ \varepsilon_t &= \sigma_t z_t \\ z_t^{i.i.d.} &\sim f(w; 0,1) \\ \sigma_t^2 &= (a_1 - b_1)\varepsilon_{t-1}^2 + \sum_{j=1}^{\infty} \left(\pi_j L^j (\varepsilon_t^2 - a_1 \varepsilon_{t-1}^2) \right) + b_1 \sigma_{t-1}^2 \end{aligned} \quad (\text{A1})$$

Onde $f(\cdot)$ é a função densidade de z_t e w , um vetor de parâmetros de f a ser estimado para as distribuições normal (n), t de *Student* (t), normal generalizada (ged) e t de *Student* assimétrica (skt).

As estimativas de VaR e expected shortfall, com 95% de nível de confiança, para passos à frente são obtidas da seguinte forma:

Horizonte temporal de um passo à frente

Passo 1.1. Computar a variância para um passo à frente como:

$$\sigma_{t+1|t}^2 = \sqrt{a_0^{(t)} + (a_1^{(t)} - b_1^{(t)})\varepsilon_{t|t}^2 + \sum_{j=1}^{\infty} \left(\frac{d^{(t)}\Gamma(j - d^{(t)})}{\Gamma(1 - d^{(t)})\Gamma(j + 1)} L^j (\varepsilon_{t+1|t+j}^2 - a_1^{(t)}\varepsilon_{t|t+j}^2) \right) + b_1^{(t)}\sigma_{t|t}^2} \quad (\text{A2})$$

Passo 1.2. Gerar 5000 números aleatórios $\{\tilde{z}_{i,1}\}_{i=1}^{5000}$ da distribuição escolhida dentre as quatro utilizadas neste artigo (normal, ged, t de *Student* e t de *Student* assimétrica).

Passo 1.3. Criar retornos hipotéticos para o tempo $t + 1$, usando $\tilde{y}_{i,t+1} = c_0^{(t)}(1 - c_1^{(t)}) + c_1^{(t)}y_t + \sigma_{t+1|t}\tilde{z}_{i,1}$ para $i = 1, \dots, 5000$.

Horizonte temporal de dois passos à frente

Passo 2.1. Criar a previsão da variância para o tempo $t + 2$, $\tilde{\sigma}_{i,t+2}^2$.

Passo 2.2. Gerar 5000 números aleatórios $\{\tilde{z}_{i,2}\}_{i=1}^{5000}$ da distribuição escolhida dentre as quatro utilizadas neste artigo (normal, ged, t de *Student* e t de *Student* assimétrica).

Passo 2.3. Criar retornos hipotéticos para o tempo $t + 2$, usando $\tilde{y}_{i,t+2} = c_0^{(t)}(1 - c_1^{(t)}) + c_1^{(t)}\tilde{y}_{i,t+1} + \tilde{\sigma}_{i,t+2}\tilde{z}_{i,2}$ para $i = 1, \dots, 5000$.

Horizonte temporal de três passos à frente

Passo 3.1. Criar a previsão da variância para o tempo $t + 3$, $\tilde{\sigma}_{i,t+3}^2$.

Passo 3.2. Gerar 5000 números aleatórios $\{\tilde{z}_{i,3}\}_{i=1}^{5000}$ da distribuição escolhida dentre as quatro utilizadas neste artigo (normal, ged, t de *Student* e t de *Student* assimétrica).

Passo 3.3. Criar retornos hipotéticos para o tempo $t + 3$, usando $\tilde{y}_{i,t+3} = c_0^{(t)}(1 - c_1^{(t)}) + c_1^{(t)}\tilde{y}_{i,t+2} + \tilde{\sigma}_{i,t+3}\tilde{z}_{i,3}$ para $i = 1, \dots, 5000$.

Horizonte temporal de τ passos à frente

Passo τ .1. Gerar 5000 números aleatórios $\{\tilde{z}_{i,\tau}\}_{i=1}^{5000}$ da distribuição escolhida dentre as quatro utilizadas neste artigo (normal, ged, t de *Student* e t de *Student* assimétrica).

Passo τ .2. Criar retornos hipotéticos para o tempo $t + \tau$, usando $\tilde{y}_{i,t+\tau} = c_0^{(t)}(1 - c_1^{(t)}) + c_1^{(t)}\tilde{y}_{i,t+\tau-1} + \tilde{\sigma}_{i,t+\tau}\tilde{z}_{i,\tau}$ para $i = 1, \dots, 5000$.

Passo τ .3. Calcular o VaR para τ passos à frente usando a equação $\text{VaR}_{t+\tau|t}^{(95\%)}$ =

$f_{5\%}(\{\tilde{y}_{i,t+\tau}\}_{i=1}^{5000})$ e a ES para τ passos à frente usando a equação $\text{ES}_{t+\tau|t}^{(95\%)}$ =

$$\tilde{k}^{-1} \sum_{i=1}^{\tilde{k}} \left(\text{VaR}_{t+\tau|t}^{(1-0,05+i0,05(\tilde{k}+1)^{-1})} \right).$$