

**UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
FACULDADE DE CIÊNCIAS ECONÔMICAS
PROGRAMA DE PÓS-GRADUAÇÃO EM ECONOMIA**

BRUNO MAIA CAVALCANTE

**GRAU DE INVESTIMENTO EM ECONOMIAS EMERGENTES E SUAS
CONSEQUÊNCIAS SOBRE A VOLATILIDADE EM BOLSA DE VALORES: OS
CASOS DO MÉXICO, CHILE, RÚSSIA, ÍNDIA E CORÉIA DO SUL.**

Porto Alegre

2009

BRUNO MAIA CAVALCANTE

**GRAU DE INVESTIMENTO EM ECONOMIAS EMERGENTES E SUAS
CONSEQUÊNCIAS SOBRE A VOLATILIDADE EM BOLSA DE VALORES: OS
CASOS DO MÉXICO, CHILE, RÚSSIA, ÍNDIA E CORÉIA DO SUL.**

Dissertação de Mestrado submetida ao Programa de Pós-Graduação em Economia da Faculdade de Ciências Econômicas da UFRGS, como quesito parcial para obtenção do título de Mestre em Economia com ênfase em Economia Aplicada.

Orientador: Prof. Dr. Ronald Otto Hillbrecht

Porto Alegre

2009

C376g

Cavalcante, Bruno Maia

Grau de investimento em economias emergentes e suas conseqüências sobre a volatilidade em bolsa de valores : os casos do México, Chile, Rússia, Índia e Coréia do Sul / Bruno Maia Cavalcante. – Porto Alegre, 2009.

000 f. : il.

Orientador: Ronaldo Otto Hillbrecht.

Ênfase em Economia Aplicada.

Dissertação (Mestrado em Economia) - Universidade Federal do Rio Grande do Sul, Faculdade de Ciências Econômicas, Programa de Pós-Graduação em Economia, Porto Alegre, 2009.

1. Investimento estrangeiro : Países em desenvolvimento. 2. Mercado financeiro : Volatilidade : Países em desenvolvimento. 3. Bolsa de valores : Países em desenvolvimento. I. Hillbrecht, Ronald Otto. II. Universidade Federal do Rio Grande do Sul. Faculdade de Ciências Econômicas. Programa de Pós-Graduação em Economia. III. Título.

CDU 339.727.22

BRUNO MAIA CAVALCANTE

**GRAU DE INVESTIMENTO EM ECONOMIAS EMERGENTES E SUAS
CONSEQUÊNCIAS SOBRE A VOLATILIDADE EM BOLSA DE VALORES: OS
CASOS DO MÉXICO, CHILE, RÚSSIA, ÍNDIA E CORÉIA DO SUL.**

Dissertação de Mestrado submetida ao Programa de Pós-Graduação em Economia da Faculdade de Ciências Econômicas da UFRGS, como quesito parcial para obtenção do título de Mestre em Economia com ênfase em Economia Aplicada.

Aprovada em: Porto Alegre, Agosto de 2009.

Prof. Dr. Ronald Otto Hillbrecht (Orientador)
UFRGS

Prof. Dr. Oscar Claudino Galli
UFRGS

Prof. Dr. Gilberto de Oliveira Kloeckner
UFRGS

Prof. Dr. Stefano Florissi
UFRGS

**Dedico ao meu pai, à minha mãe e à minha
irmã.**

AGRADECIMENTOS

Eu gostaria de agradecer ao meu pai, por ter sempre me dado força e apoio nos meus estudos; à minha mãe, por ter me ensinado a ter fascínio e respeito pelo saber e pelo meio acadêmico; à minha irmã querida, pelo apoio emocional e pelo carinho; à minha avó Itamê, por ter ensinado aos filhos e netos o valor do estudo; ao meu tio Nelson, pelo grande incentivo dado para que eu descobrisse a Ciência Econômica; ao meu primo Alexandre, por ter me mostrado que a carreira de economista tem muito a oferecer; aos meus amigos, que sempre torceram por mim; aos meus professores de graduação – Ivan Castelar, Jair do Amaral, Flávio Ataliba e José Raimundo – pelos incentivos dados para eu ingressar no mestrado; ao professor Marcelo Portugal pelas aulas de Econometria que me possibilitaram ter o domínio de ferramentas poderosas de Métodos Quantitativos, além do grande apoio dado no início da minha carreira profissional; ao meu orientador Ronald Hillbrecht, pela disponibilidade e pelos comentários construtivos ao longo do período de desenvolvimento desta pesquisa; à secretaria da Pós-Graduação em Economia, por todo o suporte e informações prestadas possibilitando o perfeito andamento do curso. Por fim, eu gostaria de deixar o meu agradecimento especial aos meus colegas de mestrado – André Nunes, Bruno Spínola, Fábio Nunes e Pedro Lutz – por terem compartilhado forças comigo para conseguirmos, juntos, passar por todas as barreiras que nos foram colocadas ao longo do mestrado, o que permitiu a formação de uma equipe de vencedores.

RESUMO

A elevação de economias emergentes ao status de Grau de Investimento (GI) atesta que o país premiado seja seguro para o investimento, ou seja, que a disposição e capacidade do governo central de honrar os seus compromissos financeiros são elevadas. O objetivo central desta pesquisa é o de testar a hipótese de que a elevação de economias emergentes a Grau de Investimento, por agências de avaliação de *rating*, tem como consequência a mitigação de volatilidade em bolsa de valores no médio e no longo prazo. Para tanto, foi selecionado um grupo representativo de economias emergentes que já receberam o status de GI – México, Chile, Rússia, Índia e Coréia do Sul – e foram modeladas as séries de retornos dos principais índices de bolsa de valores das economias amostradas, fazendo uso de modelos da família GARCH. Desta forma, foi possível avaliar o comportamento da volatilidade condicional dos retornos de cada índice no médio e longo prazo. Os resultados obtidos validam em parte a hipótese levantada. Ou seja, foi verificado que todas as cinco economias amostradas apresentaram mitigação da volatilidade em bolsa de valores, no médio prazo, após a primeira elevação a GI. No longo prazo, no entanto, apenas o México, o Chile e a Rússia apresentaram persistência de mitigação de volatilidade em bolsa. Na Índia e na Coréia do Sul, por outro lado, houve reversão do movimento de mitigação de volatilidade, observado no médio prazo, havendo aumento no longo prazo. Ao avaliar o histórico de *rating* soberano dos países estudados, foi constatado que aqueles que tiveram rebaixamento de nota após o primeiro registro de GI – Índia e Coréia do Sul – somente apresentaram mitigação de volatilidade em bolsa no médio prazo, não tendo esse movimento se prolongado no longo prazo.

Palavras-Chave: Grau de Investimento. Economias Emergentes. Volatilidade. Modelos GARCH.

ABSTRACT

The upgrade of emerging markets to the status of Investment Grade country attest that the upgraded country is safe for investment, which means that the willingness and capacity of central government to honor its financial obligations are high. The main objective of this research is to test the hypothesis that emerging countries that have their sovereign rating upgraded to Investment Grade, by rating agencies, have as consequence mitigations of stock market volatility in the medium and long run. A set of five representative emerging countries that received Investment Grade status in the past was selected – Mexico, Chile, Russia, India and South Korea – and, using GARCH family models, their main stock market index returns were modeled. So it was possible to assess the medium and long run behavior of conditional volatility of returns for every country selected. The result was that all the five economies had volatility mitigation in the medium run after the first Investment Grade status was granted. However, only Mexico, Chile and Russia had stock market volatility mitigation in the long run. India and Korea reverted volatility mitigation movement and showed gain of volatility in the long run. Assessing the sovereign rating historic of the five countries it was noticed that the countries that suffered rating downgrade after the first Investment Grade elevation – India and Korea – had stock market volatility growth in the long run.

Key-Words: Investment Grade. Emerging Countries. Volatility. GARCH Models.

LISTA DE QUADROS

Quadro 1 – Histórico de rating da Moody’s (México).....	34
Quadro 2 – Histórico de rating da S&P (México).....	34
Quadro 3 – Histórico de rating da Fitch (México).....	35
Quadro 4 – Histórico de rating da Moody’s (Chile).....	36
Quadro 5 – Histórico de rating da S&P (Chile).....	36
Quadro 6 – Histórico de rating da Fitch (Chile).....	36
Quadro 7 – Histórico de rating da Moody’s (Índia).....	37
Quadro 8 – Histórico de rating da S&P (Índia).....	37
Quadro 9 – Histórico de rating da Fitch (Índia).....	37
Quadro 10 – Histórico de rating da Moody’s (Rússia).....	39
Quadro 11 – Histórico de rating da S&P (Rússia).....	39
Quadro 12 – Histórico de rating da Fitch (Rússia).....	40
Quadro 13 – Histórico de rating da Moody’s (Coréia do Sul).....	41
Quadro 14 – Histórico de rating da S&P (Coréia do Sul).....	41
Quadro 15 – Histórico de rating da Fitch (Coréia do Sul).....	42
Quadro16 – Critério de informação de Akaike e Swarz (Mexbol).....	48
Quadro 17– Critério de informação de Akaike e Swarz (Ipsa).....	52
Quadro 18– Critério de informação de Akaike e Swarz (BSE Sensex 30).....	56
Quadro 19– Critério de informação de Akaike e Swarz (RTS).....	60
Quadro 20– Critério de informação de Akaike e Swarz (KOSPI).....	64

LISTA DE FIGURAS

Figura 1 – Gráfico do retorno do índice de bolsa (Mexbol).....	45
Figura 2 – Gráfico da função de densidade Kernel (Mexbol).....	46
Figura 3 – Histograma e quadro resumo de estatísticas (Mexbol).....	46
Figura 4 – Gráfico QQ-Normal dos retornos padronizados (Mexbol).....	47
Figura 5 – Gráfico do retorno do índice de bolsa (Ipsa).....	50
Figura 6 – Gráfico da função de densidade Kernel (Ipsa).....	50
Figura 7 – Histograma e quadro resumo de estatísticas (Ipsa).....	51
Figura 8 – Gráfico QQ-Normal dos retornos padronizados (Ipsa).....	51
Figura 9 – Gráfico do retorno do índice de bolsa (BSE Sensex 30).....	54
Figura 10 – Gráfico da função de densidade Kernel (BSE Sensex 30).....	54
Figura 11 – Histograma e quadro resumo de estatísticas (BSE Sensex 30).....	55
Figura 12 – Gráfico QQ-Normal dos retornos padronizados (BSE Sensex 30).....	55
Figura 13 – Gráfico do retorno do índice de bolsa RTS da Rússia.....	58
Figura 14 – Gráfico da função de densidade Kernel (RTS).....	58
Figura 15 – Histograma e quadro resumo de estatísticas (RTS).....	59
Figura 16 – Gráfico QQ-Normal dos retornos padronizados (RTS).....	59
Figura 17 – Gráfico do retorno do índice de bolsa (KOSPI).....	62
Figura 18 – Gráfico da função de densidade Kernel (KOSPI).....	62
Figura 19 – Histograma e quadro resumo de estatísticas (KOSPI).....	63
Figura 20 – Gráfico QQ-Normal dos retornos padronizados (KOSPI).....	63
Figura 21 – Gráfico da volatilidade condicional (Mexbol - AR(1)-TARCH(1,1)).....	69
Figura 22 – Gráfico da volatilidade condicional (Ipsa - AR(1)-TARCH(1,1)).....	70
Figura 23 – Gráfico da volatilidade condicional (BSE AR(1)-TARCH(1,1)).....	71

Figura 24 – Gráfico da volatilidade condicional (RTS AR(1)-GARCH(1,1)).....72

Figura 25 – Gráfico da volatilidade condicional (KOSPI AR(1)-GARCH(1,1)).....73

SUMÁRIO

1 Introdução.....	14
2 Ferramentas para avaliação de volatilidade.....	18
2.1 Fatos Estilizados em séries financeiras.....	18
2.2 Modelos para avaliar volatilidade.....	19
2.2.1 Volatilidade Histórica.....	19
2.2.2 Média móvel com ponderação exponencial.....	20
2.2.3 Volatilidade Implícita.....	20
2.2.4 Modelo ARCH.....	21
2.2.5 Modelo GARCH.....	25
2.2.6 Modelo TARCH.....	28
2.2.7 Modelo EGARCH.....	29
3 Avaliação e histórico de <i>rating</i>.....	31
3.1 Conceito e avaliação de <i>rating</i> soberano.....	31
3.2 Histórico de <i>rating</i>	34
3.2.1 México.....	34
3.2.2 Chile.....	36
3.2.3 Índia.....	37
3.2.4 Rússia.....	39
3.2.5 Coreia do Sul.....	41
4 Modelando volatilidade.....	44
4.1 Dados.....	44
4.2 Modelagem.....	45
4.2.1 México.....	45
4.2.2 Chile.....	50
4.2.3 Índia.....	54
4.2.4 Rússia.....	58
4.2.5 Coreia do Sul.....	62
5 Comparação da volatilidade condicional <i>ex-ante</i> e <i>ex-post</i>.....	66
5.1 México.....	69
5.2 Chile.....	70
5.3 Índia.....	71

5.4 Rússia.....	72
5.5 Coréia do Sul.....	73
6 Conclusão.....	75
Referências.....	79
ANEXO A - Correlograma dos resíduos padronizados (Mexbol).....	82
ANEXO B - Resultado da estimação do modelo TARCH(1,1) (Mexbol).....	84
ANEXO C - Correlograma dos resíduos padronizados (IPSA).....	85
ANEXO D - Resultado da estimação do modelo TARCH(1,1) (Ipsa).....	87
ANEXO E - Correlograma dos resíduos padronizados (BSE Sensex 30).....	88
ANEXO F - Resultado da estimação do modelo TARCH(1,1) (BSE Sensex 30).....	90
ANEXO G - Correlograma dos resíduos padronizados (RTS).....	91
ANEXO H - Resultado da estimação do modelo GARCH(1,1) (RTS).....	93
ANEXO I - Correlograma dos resíduos padronizados (KOSPI).....	94
ANEXO J - Resultado da estimação do modelo GARCH(1,1) (KOSPI).....	96

1 INTRODUÇÃO

Um tema que ganhou espaço desde o ano de 2007 na imprensa e meio acadêmico brasileiros diz respeito às consequências da - até então provável - elevação da dívida soberana brasileira a Grau de Investimento (GI) por agências de avaliação de risco. Ao longo de 2007, a grande pergunta referia-se a quando o Brasil seria contemplado com o GI, visto que os fundamentos econômicos domésticos, estes cada vez mais sólidos, sinalizavam por uma provável elevação da classificação de risco soberano mais cedo ou mais tarde.

Em 2008, a tão esperada elevação da nota atribuída à dívida de longo prazo em moeda estrangeira do Brasil para “BBB-”, feita pela Standard & Poor’s, aconteceu no dia 30 abril. Um mês depois, no dia 29 de maio, a Fitch *Ratings* também elevou o Brasil a Grau de Investimento, selando de vez a nova marca de país seguro para o investimento.

Com a vinda do Grau de Investimento as discussões ganharam novo rumo, qual seja: uma vez recebido o carimbo de GI, qual o futuro para a economia brasileira? Será que ganhos potenciais, em decorrência do evento, serão sentidos ainda no curto prazo ou somente no longo prazo? Será que a convergência da economia brasileira para patamar semelhante ao do mundo desenvolvido seja possível? Muitos foram os novos questionamentos que se desenharam acerca das consequências, de curto e longo prazo, para a economia brasileira da concessão do GI.

O status de Grau de Investimento pode trazer uma série de benefícios para a economia premiada:

[...] trata-se de um evento significativo que deve se refletir e impactar, no médio prazo, três variáveis estratégicas para a economia [...] (i) melhores condições de financiamento; (ii) maior oferta de capital de empréstimo, sobretudo de longo prazo; e (iii) aceitação, por parte dos investidores, de menores taxas de retorno para aplicar em capital de risco. (CASTRO, BRANDÃO, 2008, p. 2)

Ou seja, a elevação do risco de crédito soberano a GI, em tese, permite que a captação de recursos – *funding* - no exterior, tanto pelo setor público como pela iniciativa privada, seja feita a um custo mais baixo, melhorando as condições de financiamento do sistema financeiro nacional, com impacto direto sobre as empresas domésticas que passam a ter acesso a crédito de melhor qualidade. Desta forma, a avaliação do risco de crédito de empresas está atrelada ao risco soberano, ou seja, uma elevação de *rating* soberano permite elevações do *rating* corporativo de empresas nacionais. Assim, é razoável pensar que o risco de se investir em empresas listadas em bolsa diminui com a concessão de GI, o que tende a diminuir os

movimentos de volatilidade em bolsa de valores. Além disso, espera-se que os investidores no mercado financeiro aceitem prêmios de risco menores por conta de um status de risco soberano seguro, aumentando a demanda por ativos domésticos e diminuindo a fuga de investimentos.

“[...] o Investment Grade, embora diga respeito em princípio ao risco dos títulos da União, influi na percepção do mercado internacional de que as empresas brasileiras, de um modo geral, tornam-se menos arriscadas, diminuindo assim o seu custo de captação.” (CASTRO, BRANDÃO, 2008, p. 3)

Por ser o risco de crédito soberano uma importante âncora da confiança dos investidores sobre o mercado de capitais doméstico, a elevada a GI garante maior atratividade para investimentos de longo prazo no país premiado. Muitos fundos de pensão e de investimento têm como regra estatutária, para investimentos em carteira, a exigência de aplicação de recursos somente em ativos provenientes de economias com status de GI. A maior parte dos investimentos dessas instituições tem caráter de longo prazo, estes estáveis por natureza. Com o aumento da participação de capital de longo prazo, na composição dos investimentos em renda variável, é de se esperar que haja mitigação de volatilidade em bolsa de valores ao longo do tempo na economia elevada a GI.

Cada vez mais as economias emergentes têm ganhado espaço na preferência de investidores do mundo desenvolvido. Segundo Polwitoon e Tawatnuntachai (2008), existe evidência empírica de que a alocação de recursos em ativos de economias emergentes tem como consequência a elevação do retorno de investidores, mantendo inalterado o nível de risco envolvido.

We also find that emerging funds are a viable asset to add to an existing portfolio of various asset classes. By including 20% emerging funds in their portfolios, U.S. investors can enhance the portfolio returns by 0.81% to 1.53% per year without increasing risk.

Tal atratividade por ativos financeiros de mercados emergentes, com baixa percepção de risco, em muito está ligado a elevações de *rating* soberano.

Outro efeito esperado da elevação da dívida soberana a GI é a redução do efeito contágio entre mercados. Segundo Canuto e Santos (2003), as economias emergentes com Grau Especulativo de *rating* têm alta sensibilidade a flutuações de variáveis macroeconômicas em outros países – desenvolvidos – e a elevação daquelas economias a GI as daria maior autonomia, permitindo a redução do efeito contágio potencial. Ou seja, a elevação de *rating*, para o patamar de Grau de Investimento, tornaria a economia premiada menos dependente de

flutuações exógenas de preços, diminuindo, assim, a volatilidade dos retornos dos ativos domésticos.

Neste trabalho são feitos testes empíricos com uma amostra de cinco economias emergentes que já receberam o carimbo de GI antes do Brasil – México, Chile, Índia, Rússia e Coreia do Sul - buscando respostas para algumas das perguntas que se configuraram ao longo dos últimos anos. Mais especificamente, o objetivo principal desta pesquisa é o de testar a hipótese básica de que a concessão de GI a economias emergentes tem como consequência a mitigação de volatilidade em bolsa de valores, tanto no médio como no longo prazo. Para tanto, são modeladas as volatilidades dos retornos dos principais índices de bolsas de valores dos países amostrados, fazendo uso de modelos da família GARCH, o que possibilita avaliar a evolução da volatilidade condicional dos retornos desses índices ao longo do tempo.

A segunda seção desta pesquisa consiste em uma revisão teórica de ferramentas tradicionais de avaliação de volatilidade, permitindo fazer uma discussão sobre os pontos fortes e fracos de cada ferramenta. Com a fundamentação teórica, obtida nesse capítulo, são escolhidos os modelos apropriados para modelar os retornos dos índices amostrados tal a obter resultados robustos. Também são expostos na seção 2 alguns fatos estilizados comuns em séries financeiras, como o efeito assimétrico e os clusters de volatilidade.

Na seção 3 é feita uma exposição dos critérios usados para a avaliação de risco de crédito soberano pelas agências de *rating*, além de ser discutido alguns conceitos importantes como o de risco-soberano e risco-país. Ainda no capítulo 3, são expostos os históricos de *rating* construídos pelas três principais agências de avaliação de risco - a Moody's, a Standard & Poor's e a Fitch - da dívida soberana de longo prazo em moeda estrangeira das economias estudadas. O primeiro registro de elevação das economias a GI é tomado como ponto de corte nesta pesquisa; ou seja, a partir dele são feitas as comparações entre volatilidade *ex-ante* e *ex-post* ao evento concessão de GI.

Na seção 4 são modeladas as séries de retornos de cada índice analisado, fazendo uso de modelos da família GARCH. São rodados diversos modelos e os critérios usados para a escolha do mais adequado são os critérios de informação de Akaike e Schwarz, além da significância estatística dos parâmetros estimados. Também são verificadas algumas características estatísticas das séries de retornos dos índices selecionados, quais sejam: os coeficientes de kurtose e de assimetria, o histograma e a densidade kernel, o gráfico QQ-normal dos retornos padronizados, bem como o teste LM-ARCH. Com a escolha da modelagem adequada para cada série de retornos, é possível avaliar a volatilidade de forma

robusta tal a gerar, a partir de cada modelo escolhido, a volatilidade condicional das séries amostradas.

No capítulo 5, são comparadas as volatilidades *ex-ante* e *ex-post* à concessão do primeiro Grau de Investimento para as cinco economias estudadas. São seccionados três períodos para cada série de volatilidade condicional: o primeiro, considerado como período base de comparação, correspondente aos vinte e quatro meses imediatamente anteriores ao corte¹; o segundo, considerado com médio prazo; e o terceiro como período representativo do longo prazo. É calculada a volatilidade condicional média para cada período, permitindo a comparação da volatilidade de médio e longo prazo com respeito ao período base.

Como detalhado na conclusão desta pesquisa, os testes empíricos realizados confirmam parcialmente a hipótese básica levantada. É observado mitigação da volatilidade em bolsa de valores no médio prazo para as cinco economias pesquisadas. No longo prazo, no entanto, somente para o México, o Chile e a Rússia houve persistência de mitigação de volatilidade em bolsa. Um fato interessante é que a continuidade do movimento de mitigação de volatilidade, no longo prazo, só foi observada para aquelas economias que não sofreram rebaixamento de nota após o primeiro registro de GI. Esses resultados serão aprofundados ao longo deste trabalho.

¹ O corte deve ser entendido como a data do primeiro registro de Grau de Investimento por uma das três agências de classificação de *rating* para a economia em questão.

2 FERRAMENTAS PARA AVALIAÇÃO DE VOLATILIDADE

Neste capítulo é feita uma exposição de ferramentas tradicionalmente usadas para avaliar volatilidade, e são apontados pontos fortes e fracos para cada uma. É dado foco aos modelos econométricos da família GARCH, já que estes são usados nesta pesquisa como ferramenta de mensuração da volatilidade condicional. Inicialmente, são expostos alguns fatos estilizados importantes para o estudo de séries financeiras.

2.1 - Séries Financeiras – Fatos Estilizados

As séries financeiras têm características bem específicas como já observado em inúmeros trabalhos empíricos. Alguns padrões bem definidos de flutuações de preços de ativos financeiros compõem um conjunto de fatos estilizados importantes, sendo interessante a análise de alguns deles.

O primeiro fato estilizado diz respeito à curtose observada em distribuições de probabilidade de retornos de ativos financeiros. Retornos de séries financeiras geralmente seguem distribuições de probabilidade com coeficiente de curtose maior que 3, ou seja, uma distribuição mais afunilada – concentrada – que a normal, o que torna as caudas da distribuição mais densas ou, em outras palavras, mais pesadas. Tal distribuição é chamada de leptocúrtica. Dados que seguem distribuições mais afuniladas, ou menos achatadas, têm probabilidade de ocorrência de *outliers* maior que dados que seguem distribuição normal. Isso quer dizer que a modelagem de dados financeiros, supondo normalidade na distribuição, muito provavelmente levará à subestimação da ocorrência de valores extremos.

Segundo Ziegelmann (2002, p. 9):

It is well known that the unconditional distribution of asset returns tends to be leptokurtic. [...] heavy tails are closely linked to the existence of autocorrelation between squared returns (although, in general, the original returns are not autocorrelated). This autocorrelation is known both to be small at first order and to show a slow decay afterwards.

O Segundo fato estilizado passível de comentários é conhecido como *cluster* de volatilidade. Movimentos elevados de retornos de ativos financeiros tendem a ser seguidos por movimentos também elevados na mesma direção. Ou seja, se hoje o retorno de determinado ativo sobe bruscamente é esperado que, não só amanhã mas também nos próximos dias, o

retorno persista elevado. Esses *clusters* de volatilidade são entendidos, como dito na citação acima, decorrentes de auto-correlação entre os retornos ao quadrado do ativo, o que dá persistência às oscilações dos retornos. No longo prazo, no entanto, clusters de volatilidade tendem a se desfazer. Volatilidade alta no curto prazo converge para oscilações baixas no longo prazo.

Um outro fato estilizado conhecido é o efeito assimétrico da volatilidade como resposta a variações de preços. Ou seja, a variação negativa de preços tende a gerar volatilidade superior àquela observada em momentos de alta de preços. Isto porque os agentes tendem a ficar mais apreensivos a movimentos de baixa de preços de ativos do que para movimentos de alta de preços. O efeito assimétrico é um ponto importante na escolha da modelagem adequada para descrever a volatilidade de séries financeiras, como veremos adiante.

Para concluir, outro ponto que merece comentário diz respeito à correlação da volatilidade entre retornos de ativos negociados em mercados distintos. É fácil aceitar o fato de que alta volatilidade no índice de bolsa nos EUA tenha efeito contágio sobre volatilidade de vários outros índices ao redor do mundo. A globalização financeira é um dos pilares explicativos para tal. Ou seja, é comum que movimentos de volatilidade em mercados específicos sejam explicados por variáveis exógenas.

2.2 - Modelos Para Avaliar Volatilidade

2.2.1 - Volatilidade histórica:

A forma mais simples de calcular volatilidade é fazendo uso da volatilidade histórica, que baseia-se simplesmente no cálculo da variância ou desvio-padrão do retorno de ativos ao longo de determinado período. No mercado financeiro é prática comum usar volatilidade histórica como *input* de modelos de precificação de ativo para calcular o conhecido *value-at-risk*. Um dos problemas do uso dessa medida para o cálculo de volatilidade é que é dado igual peso para todas as observações de retornos, independente da distância da ocorrência da observação. “A major problem with equally weighted averages is that extreme events which either occurred yesterday or a long time ago are equally important to current estimates.” (ZIEGELMANN, 2002, p.14). Mesmo com essa limitação o cálculo da volatilidade histórica serve de *benchmark* para comparação com estimativas de volatilidade que fazem uso de

modelos sofisticados. O método da média móvel com ponderação exponencial aparece como evolução do método de volatilidade histórica.

2.2.2 – Média móvel com ponderação exponencial:

Neste método, a observação que entra no cálculo da média quadrática recebe ponderação que decai, exponencialmente, à medida que esteja mais distante no tempo. Já informações recentes recebem alta ponderação. Analiticamente temos:

$$\sigma_t^2 = (1 - \lambda) \sum_{j=0}^{\infty} \lambda^{j-1} (r_{t-j} - \bar{r})^2$$

Onde σ_t^2 é a estimativa de variância para o período “t”, que pode ser usada como previsão para volatilidade futura. \bar{r} é o retorno médio do ativo em questão, e λ é o fator de decaimento, que determina o quanto de peso cada informação irá receber.

The decay factor could be estimated, but in many studies is set 0.94 as recommended by RiskMetrics, producers of popular risk measurement software. Note also that RiskMetrics and many academic papers assume that the average return, \bar{r} , is zero. For data that is of daily frequency or higher, this is not an unreasonable assumption, and is likely to lead to negligible loss of accuracy since it will typically be very small. (BROOKS, p. 443).

2.2.3 – Volatilidade Implícita:

Outra forma, largamente usada no mercado financeiro, para avaliar a volatilidade de ativos financeiros é através do cálculo da volatilidade implícita. Tal cálculo baseia-se em modelos de precificação de ativos como o tradicional Black&Scholes.

All pricing models for financial options require a volatility estimate or forecast as an input. Given the price of a traded option obtained from transactions data, it is possible to determine the volatility forecast over the lifetime of the option implied by the option’s valuation. For example, if the

standard Black&Scholes model is used, the option price, the time to maturity, risk-free rate of interest, the strike price and current value of the underlying asset, are all either specified in the details of the options contracts or are available from market data. Therefore, given all of these quantities, it is possible to use a numerical procedure, such as the method of bisections or Newton-Raphson to derive the volatility implied by the option. This implied volatility is the market's forecast of the volatility of underlying asset returns over the lifetime of the option (BROOKS, p. 442).

2.2.4 – *Autoregressive conditional heteroscedastic (ARCH) models:*

Como exposto anteriormente, o cálculo da média quadrática móvel, tanto com ponderação constante como com ponderação exponencial, é uma forma de mensurar a volatilidade incondicional. Tal volatilidade, como o próprio nome indica, não leva em consideração a evolução do conjunto informacional ao longo do tempo. Ou seja, não leva em consideração o processo gerador de volatilidade. Em períodos de mudança brusca de volatilidade, por exemplo, o simples cálculo da variância incondicional não é apropriado, pois a quebra observada da volatilidade não é incorporada na conta. O correto, para evitar esse problema, é utilizar o cálculo da volatilidade condicional. Duas classes principais de modelos não-lineares permitem o cálculo da volatilidade condicional, quais sejam: a família de modelos determinísticos - *Generalised Autoregressive Conditional Heteroscedasticity (GARCH) models* - e a família de modelos de volatilidade estocástica - *Stochastic Volatility (SV) models*. Nesses modelos o cálculo da volatilidade é condicional ao conjunto de informação disponível até o momento do cálculo, e o processo gerador da volatilidade é levado em conta.

Although the global volatility is still assumed invariant, the conditional volatility is modeled as a random variable. As a result, the conditional distribution of the returns changes at each point in time. This is the key point to understand the distinction between conditional (stochastic) and unconditional (constant) volatility. Besides, what distinguishes the GARCH from the SV class is that whereas GARCH models have their conditional information set by observed random variables, SV models have theirs composed by latent random variables. (ZIEGELMANN, 2002, p.14).

Dado o seguinte modelo linear:

$$y_t = \beta_1 + \beta_2 x_{2t} + \beta_3 x_{3t} + \beta_4 x_{4t} + \mu_t \quad \mu_t \sim N(0, \sigma_t^2) \quad (1)$$

O termo de erro é heteroscedástico e segue distribuição normal com média zero. Na equação acima temos um exemplo de modelagem simples – linear - da média condicional da variável y_t . Como a variância do erro é heteroscedástica, isto indica que a variância apresenta autocorrelação e que podemos, além de modelar a média, também modelar a variância do termo de erro, uma vez que ela é condicional a valores passados do erro ao quadrado. Supõe-se a seguinte estrutura de parametrização para a variância do erro:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 \quad (2)$$

Esse modelo é conhecido como ARCH (1), onde a variância do erro em “t” - σ_t^2 - depende do erro anterior elevado ao quadrado. Podemos generalizar (2) para o caso em que a variância condicional do erro é função não somente do erro ao quadrado uma vez defasado, mas do erro defasado até a q-ésima ordem como segue:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_2 \mu_{t-2}^2 + \dots + \alpha_q \mu_{t-q}^2 \quad (3)$$

Obs. Com a equação acima fica claro que estamos lidando com a variância condicional do termo de erro μ_t . Ou seja, que

$$\sigma_t^2 = \text{var}(\mu_t / \mu_{t-1}, \mu_{t-2}, \dots, \mu_{t-q}) = E[\mu_t^2 / \mu_{t-1}, \mu_{t-2}, \mu_{t-3}, \dots, \mu_{t-1}].$$

Escrevendo o processo estocástico $\{\mu_t\}$ como um ARCH (q) de forma genérica. Vem:

$$\begin{aligned} \mu_t &= \sigma_t v_t \\ \sigma_t^2 &= \alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_{t-1} \mu_{t-2}^2 + \dots + \alpha_{t-q} \mu_{t-q}^2 \end{aligned} \quad (4)$$

Com $v_t \sim IID(0,1)$

É fácil ver que $E\mu_t = 0$, como segue:

$$\begin{aligned} \mu_t &= \sigma_t v_t = (\alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_{t-1} \mu_{t-2}^2 + \dots + \alpha_{t-q} \mu_{t-q}^2) v_t \\ E\mu_t &= (\alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_{t-1} \mu_{t-2}^2 + \dots + \alpha_{t-q} \mu_{t-q}^2) E v_t = 0 \end{aligned}$$

Para a expressão correspondente à variância condicional é necessário impor condição de não-negatividade sobre os coeficientes, ou seja:

$$\alpha_i \geq 0 \quad i = 0, 1, \dots, q$$

Já que a medida de variância, por definição, não pode assumir valor negativo.

Segundo Fan e Yau (2002) existe um importante teorema a ser observado.

Teorema.1

(*) É condição necessária e suficiente para que o processo estocástico $\{\mu_t\}$ possua estacionariedade em variância ($E\mu_j^2 < \infty$), que:

$$\sum_{i=1}^q \alpha_i < 1.$$

É fácil ver isso.

Prova.1:

De (4), vem:

$$\mu_t^2 = \sigma_t^2 v_t^2 = (\alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_{t-1} \mu_{t-2}^2 + \dots + \alpha_{t-q} \mu_{t-q}^2) v_t^2$$

$$\mu_t^2 = (\alpha_0 + \sum_{i=1}^q \alpha_i \mu_{t-i}^2) v_t^2$$

$$E\mu_t^2 = \alpha_0 + E\mu_t^2 \sum_{i=1}^q \alpha_i$$

$$\therefore E\mu_t^2 = \frac{\alpha_0}{1 - \sum_{i=1}^q \alpha_i}$$

Caso $\sum_{i=1}^q \alpha_i \geq 1$ então $E\mu_t^2$ não estaria definido para a igualdade, ou para a desigualdade assumiria sinal negativo, o que não faz sentido matemático. ◦

(**) Outra imposição do teorema é que o quarto momento de $\{\mu_t\}$ seja bem definido, ou seja, que $E\mu_t^4 < \infty$.

A modelagem ARCH apresenta algumas limitações importantes de serem abordadas neste ponto. A primeira fragilidade diz respeito à identificação do modelo, ou seja, a definição do “q” – de quantas defasagens deve ser parametrizadas. Adicionalmente existe o problema de que o modelo ARCH é pouco parcimonioso, ou seja, na prática são exigidas muitas defasagens tal a incorporarmos todas as informações necessárias ao modelo.

O caráter não parcimonioso da modelagem ARCH trás um problema secundário, qual seja: dificilmente aplicações empíricas respeitarão a hipótese de não-negatividade, uma vez que a existência de muitos parâmetros certamente trará algum valor negativo. Nas palavras de Brooks (2002, p. 452): “Non-negativity constraints might be violated. Everything else equal, the more parameter that are in the conditional variance equation, the more likely it is that one or more of them will have negative estimated values.”

Devido às limitações citadas acima, o modelo ARCH raramente é utilizado na prática. A família de modelos GARCH, no entanto, possui outros modelos além do ARCH que são bastante populares e superam as fragilidades do modelo apresentado.

Uma forma popular para a estimação dos parâmetros de um modelo ARCH, por se tratar de um modelo não-linear, é fazendo uso da estimação por Máxima Verossimilhança (MV). O procedimento de estimação consiste em maximizar a função de verossimilhança condicional logaritimizada em relação ao vetor de parâmetros a ser estimado.

Segundo Ziegelmann (2002) a partir do modelo ARCH(q) indicado em (4) é possível obter a seguinte função de log-verossimilhança condicional supondo, por simplicidade, normalidade da distribuição dos erros:

$$l(\theta) = \sum_{t=q+1}^n \log f(\mu_t / \mu_{t-1}, \dots, \mu_{t-q}, \theta)$$

$$= \sum_{t=q+1}^n (\log \sigma_t^2 + \mu_t^2 / \sigma_t^2)$$

Onde “ θ ” é o vetor de parâmetros dado por $\theta = (\alpha_0, \alpha_1, \dots, \alpha_q)$; “n” é o tamanho da amostra; e $f(\cdot)$ é a função de densidade normal. Substituindo σ_t^2 pela expressão $\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_{t-1} \mu_{t-2}^2 + \dots + \alpha_{t-q} \mu_{t-q}^2$ na função de log-verossimilhança condicional acima é possível obter o estimador do vetor “ θ ”, maximizando a função acima em relação aos parâmetros individuais do vetor. Uma vez obtidos os estimadores de MV basta substituí-los

em (4) para achar o estimador para a variância condicional “ σ_t^2 ” . São usados métodos numéricos para a otimização da função de log-verossimilhança condicional.

O procedimento de estimação aplicado ao modelo ARCH(q) pode ser aplicado – fazendo os devidos ajustes – aos demais modelos da família GARCH que serão expostos nos tópicos seguintes.

2.2.5 – *Generalised ARCH (GARCH) models:*

Definimos um GARCH(1,1) como segue:

$$\mu_t = \sigma_t v_t$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_2 \sigma_{t-1}^2 \quad (5)$$

Com $v_t \sim IID(0,1)$

A volatilidade condicional é função não só do termo de erro defasado ao quadrado, mas também da própria volatilidade defasada. Generalizando o modelo acima, vem:

$$\sigma_t^2 = \alpha_0 + \sum_{i=1}^p \alpha_i \mu_{t-i}^2 + \sum_{j=1}^q \beta_j \sigma_{t-j}^2$$

O modelo acima é um GARCH (p,q). Note que o modelo ARCH(p) é um caso particular do GARCH(p,q) com os coeficientes β_j iguais a zero.

O modelo GARCH nada mais é que um ARMA aplicado à volatilidade condicional. Segue a prova:

Prova.2:

Considere que:

$$\varepsilon_t = \mu_t^2 - \sigma_t^2 \text{ ou seja } \sigma_t^2 = \mu_t^2 - \varepsilon_t \quad (*)$$

Substituindo (*) em (5), vem:

$$\mu_t^2 - \varepsilon_t = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \beta_1 (\mu_{t-1}^2 - \varepsilon_{t-1})$$

$$\mu_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \beta_1 \mu_{t-1}^2 - \beta_1 \varepsilon_{t-1} + \varepsilon_t$$

$$\mu_t^2 = \alpha_0 + (\alpha_1 + \beta_1) \mu_{t-1}^2 - \beta_1 \varepsilon_{t-1} + \varepsilon_t$$

Acima temos a expressão para um modelo ARMA(1,1) para o quadrado do erro. ◦

Qual a vantagem de usar uma GARCH ao invés de um ARCH? A resposta direta para a pergunta é que a modelagem GARCH é bastante parcimoniosa. Um GARCH(1,1) corresponde a um ARCH infinito, como segue demonstrado abaixo:

Prova.3:

Dado um GARCH(1,1):

$$\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_2 \sigma_{t-1}^2 \quad (5.1)$$

Defasando os dois lados uma vez:

$$\sigma_{t-1}^2 = \alpha_0 + \alpha_1 \mu_{t-2}^2 + \alpha_2 \sigma_{t-2}^2 \quad (5.2)$$

Defasando mais uma vez:

$$\sigma_{t-2}^2 = \alpha_0 + \alpha_1 \mu_{t-3}^2 + \alpha_2 \sigma_{t-3}^2 \quad (5.3)$$

Substituindo (5.2) em (5.1), vem:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_2 (\alpha_0 + \alpha_1 \mu_{t-2}^2 + \alpha_2 \sigma_{t-2}^2)$$

Desenvolvendo a expressão:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_2 \alpha_0 + \alpha_1 \alpha_2 \mu_{t-2}^2 + \alpha_2^2 \sigma_{t-2}^2$$

Substituindo (5.3) acima:

$$\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_2 \alpha_0 + \alpha_1 \alpha_2 \mu_{t-2}^2 + \alpha_2^2 (\alpha_0 + \alpha_1 \mu_{t-3}^2 + \alpha_2 \sigma_{t-3}^2)$$

$$= \alpha_0 + \alpha_1 \mu_{t-1}^2 + \alpha_2 \alpha_0 + \alpha_1 \alpha_2 \mu_{t-2}^2 + \alpha_2^2 \alpha_0 + \alpha_1 \alpha_2^2 \mu_{t-3}^2 + \alpha_2^3 \sigma_{t-3}^2$$

$$\therefore \sigma_t^2 = \alpha_0 (1 + \alpha_2 + \alpha_2^2) + \alpha_1 \mu_{t-1}^2 (1 + \alpha_2 L + \alpha_2^2 L^2) + \alpha_2^3 \sigma_{t-3}^2$$

Repetindo o processo recursivo infinitas vezes, teremos:

$$\sigma_t^2 = \alpha_0(1 + \alpha_2 + \alpha_2^2 + \dots) + \alpha_1\mu_{t-1}^2(1 + \alpha_2L + \alpha_2^2L^2 + \dots) + \lim_{i \rightarrow \infty} \alpha_2^i \sigma_{t-i}^2$$

No infinito, a expressão $\lim_{i \rightarrow \infty} \alpha_2^i \sigma_{t-i}^2$ tende a zero. Como o primeiro elemento da soma à direita da igualdade é uma constante – que podemos chamar de φ_0 – reescrevemos a expressão como segue:

$$\sigma_t^2 = \varphi_0 + \varphi_1\mu_{t-1}^2 + \varphi_2\mu_{t-2}^2 + \varphi_3\mu_{t-3}^2 + \dots \quad (6)$$

A expressão (6) nada mais é que uma processo ARCH(∞). Ou seja, o GARCH(1,1) corresponde a um ARCH(∞). Em outras palavras, um GARCH(1,1) consegue incorporar o efeito de infinitos erros ao quadrado defasados, isto com um número pequeno de parâmetros. A expressão (6) com infinitos parâmetros corresponde à expressão (5.1) com somente três parâmetros. ◦

Assim como foi apresentado um teorema para garantir estacionariedade ao modelo ARCH, aqui também cabe o mesmo teorema feitos os devidos ajustes:

Teorema.2

(*) É condição necessária e suficiente para que o modelo GARCH(p,q) exiba estacionariedade em variância ($E\mu_t^2 < \infty$), que:

$$\sum_{i=1}^p \alpha_i + \sum_{j=1}^q \beta_j < 1$$

A prova do teorema segue a mesma lógica daquela apresentada para o teorema 1 do modelo ARCH, onde chegamos às seguintes expressões:

$$E\mu_t = 0$$

$$E\mu_t^2 = \frac{\alpha_0}{1 - \sum_{i=1}^p \alpha_i - \sum_{j=1}^q \beta_j}$$

(**) Outra imposição do teorema é que o quarto momento de $\{\mu_t\}$ seja bem definido, ou seja, que $E\mu_t^4 < \infty$.

A modelagem GARCH possui vantagens quando comparada com o modelo ARCH; no entanto, também possui algumas fragilidades. A primeira delas é a possibilidade de violação da restrição de não-negatividade dos parâmetros. O fato de o modelo ser parcimonioso simplesmente mitiga a possibilidade de violação da restrição de não-negatividade, de forma algum impede. Outra limitação do modelo GARCH é que ele não capta o efeito assimétrico dos dados, ou seja, o modelo dá igual importância - efeito simétrico - para respostas em termos de volatilidade para altas e baixas de preços, o que viola um importante fato estilizado em séries financeiras: o de que choques negativos têm, como consequência, volatilidade maior que aquela decorrente de choques positivos. Lembrando que o termo de erro entra na equação da variância condicional elevado ao quadrado, impedindo a diferenciação entre choques positivos e negativos. No entanto, existem modelos que suprimem as fragilidades do modelo GARCH como será visto ao longo dos próximos tópicos.

2.2.6 – *Threshold GARCH (TARCH) models:*

Também conhecido como GJR, “Glosten, Jagannathan and Runkle (1993) use this model to capture the asymmetric effects of returns on volatility.” (ZIEGELMANN, 2002, p. 24). Este é um exemplo de modelo que incorpora o efeito assimétrico. Segue a expressão analítica de um TGARCH (1,1)

$$\mu_t = \sigma_t v_t$$

$$\sigma_t^2 = \alpha_0 + \alpha_1 \mu_{t-1}^2 + \beta \sigma_{t-1}^2 + \gamma \mu_{t-1}^2 I_{t-1}$$

Com $v_t \sim IID(0,1)$

Onde $I_{t-1} = 1$ se $\mu_{t-1} < 0$

$I_{t-1} = 0$ caso contrário.

Para que o efeito assimétrico seja realmente incorporado esperamos que γ seja maior que zero; tal que para cada valor negativo do erro, teremos maior valor incorporado à volatilidade observada.

Note que se $\gamma > \alpha_1$, supondo $\gamma > 0$, implica que choques negativos incorporam mais volatilidade marginal que choques positivos, o que é coerente com fatos estilizados de séries financeiras. “... quando $\gamma > 0$ captura-se o efeito *leverage* e com $\gamma = 0$, o modelo GJR(1,1) reduz-se a um GARCH(1,1). Neste sentido o modelo GARCH é aninhado ao modelo GJR.” (MORAIS, PORTUGAL, 1999, p. 311).

A restrição de não-negatividade para o modelo acima é a seguinte:

$$\alpha_0 > 0; \alpha_1 > 0; \beta > 0; (\alpha_1 + \gamma) > 0$$

Uma das fragilidades do modelo GARCH, que é a não incorporação do efeito assimétrico, é superada com o TARARCH. No entanto, ainda é possível que a restrição de não negatividade seja violada. O modelo apresentado no próximo tópico – o EGARCH – além de incorporar o efeito assimétrico também suprime o problema de violação da restrição de não-negatividade.

2.2.7 – Exponential GARCH (EGARCH) models:

O modelo EGARCH pode ser apresentado, em formato simplificado, como segue:

$$\mu_t = \sigma_t v_t$$

$$\ln(\sigma_t^2) = \omega + \beta \ln(\sigma_{t-1}^2) + \gamma \frac{\mu_{t-1}}{\sqrt{\sigma_{t-1}^2}} + \alpha \left[\frac{\lfloor \mu_{t-1} \rfloor}{\sqrt{\sigma_{t-1}^2}} - \sqrt{\frac{2}{\pi}} \right]$$

Note a vantagem do modelo acima em relação aos anteriores. Nele o fato de a volatilidade condicional aparecer no logaritmando garante a não-negatividade da volatilidade. O modelo também capta efeito assimétrico, uma vez que γ será negativo caso a relação entre retorno e volatilidade seja inversa. “O modelo é assimétrico devido à existência do coeficiente γ , que capta o efeito *leverage*.” (MORAIS, PORTUGAL, 1999, p. 311)

Neste capítulo foram apresentadas ferramentas tradicionais de avaliação de volatilidade, além da exposição dos principais fatos estilizados, observados em séries financeiras, como o efeito assimétrico e os clusters de volatilidade. Posteriormente, foi dado

foco aos modelos da família GARCH usados para o cálculo da volatilidade condicional, tendo sido apontado os pontos fortes e fracos dos mesmos. Estes últimos serão usados para fazer as aplicações empíricas desta pesquisa ao longo do capítulo 4.

3 AVALIAÇÃO E HISTÓRICO DE *RATING*

Este capítulo abre, inicialmente, uma discussão objetiva sobre alguns conceitos importantes como o de risco-soberano e o de risco-país. Também são listados alguns critérios usados pelas agências de *rating* para avaliar risco de crédito soberano. Posteriormente, é feito o acompanhamento dos históricos de *rating* dos países amostrados, de acordo com as três principais agências de *rating* consideradas nesta pesquisa.

3.1 Conceito de risco-soberano e critérios usados na avaliação de *rating* soberano.

Antes de entrar nos históricos de *rating*, cabe fazer uma breve discussão sobre o conceito de risco-soberano e sobre alguns critérios usados, pelas agências de *rating*, para avaliar risco de crédito de governos centrais.

A classificação de risco-soberano refere-se ao potencial e à disposição de um governo de honrar suas dívidas nos termos acordados. “O resultado desta avaliação é sintetizado em classificações, que são estimativas da probabilidade de um dado governo entrar em moratória, o que significa não apenas a suspensão do pagamento dos juros ou principal da dívida na data de seu vencimento, mas também sua troca ou reestruturação “involuntária” ” (CANUTO, SANTOS, p. 9, 2003)

As agências de *rating* avaliam risco de crédito tanto de um emissor, bem como de uma emissão específica. Como bem lembra Canuto e Santos (2003), pode acontecer que uma emissão específica tenha um *rating* superior – de menor risco – que o *rating* do próprio emissor, basta que sejam apresentadas garantias de elevada qualidade contra a emissão. As agências também diferenciam emissões conforme o prazo – curto e longo prazo – e conforme a moeda utilizada – doméstica ou estrangeira. Emissões de curto prazo seriam aquelas com vencimento inferior a um ano.

Uma distinção importante de ser feita diz respeito ao conceito de risco-país e risco-soberano. O primeiro é um conceito mais abrangente que o segundo. Quando se fala de risco-soberano estar-se falando do risco de inadimplência do governo, como já comentado, enquanto que o risco-país está ligado ao risco de inadimplência dos demais credores residentes em um país, considerando fatores que são exógenos aos residentes, como, por exemplo, o risco cambial e o risco regulatório.

O risco-país diz respeito a todos os ativos financeiros do país, impondo-lhes uma carga compensatória de prêmio no retorno por eles oferecido. Evidentemente, os dois riscos guardam relação de parentesco, já que uma moratória na dívida soberana tende a exercer impacto negativo sobre os demais fluxos de capital para o país, afetando também dívidas externas privadas. (CANUTO, SANTOS, p. 16, 2003)

O EMBI+ é um indicador que capta o prêmio de risco de títulos de economias emergentes. O índice é composto por uma cesta de títulos de emissão governamental de economias emergentes. “O EMBI+ é composto principalmente por títulos da dívida externa (Brades e Eurobônus), mas pode também incluir empréstimos negociados (*traded loans*) e títulos domésticos denominados em moeda estrangeira.” (CANUTO e SANTOS, 2003, p. 17).

A decomposição do EMBI+ em seus índices componentes de emergentes nos dá as margens soberanas de cada país. Cada margem nada mais é que a diferença entre a remuneração do título público do emergente em relação à remuneração paga pelo título americano (*treasure*). Essa margem soberana é costumeiramente chamada de risco-país. Mas note que, como o EMBI+ é composto somente por títulos públicos, a nomenclatura risco-país não é a mais apropriada neste caso, sendo a denominação risco-soberano a mais adequada. Ou seja, o diferencial de remuneração do título público do país emergente e do título público americano reflete a margem soberana, “*sovereign spread*”, que representa uma parte do risco-país – este mais abrangente como discutido em parágrafo anterior.

“Como no cálculo da margem soberana são considerados apenas títulos emitidos pelos governos centrais, corresponde a um indicador de risco-soberano, sendo algo imprecisa sua denominação como “risco-país.” (CANUTO, SANTOS, 2003, p. 17)

As flutuações das margens soberanas refletem a percepção de risco do mercado, esta bastante influenciada por movimentos de curto prazo em variáveis econômicas relevantes. Mas esses movimentos de curto prazo têm relação explicativa sobre as classificações de *rating* soberano das agências? Canuto e Santos (2003) argumentam que, em momentos de normalidade econômica, a incorporação da percepção de risco do mercado – esta refletida pela margem soberana – torna instável a avaliação de *rating* e, portanto, tal variável de curto prazo não é levada em conta pelas agências de *rating* para avaliar risco de crédito soberano. Já em momentos de muita volatilidade nos mercados, a incorporação da margem soberanas nas classificações de *rating* é importante, visto que nesses casos extremos o acesso ao mercado financeiro doméstico fica comprometido, podendo impactar no potencial de financiamento do setor público. As avaliações de *rating* devem ser estáveis e refletirem os fundamentos macroeconômicos da economia avaliada, e não flutuações de curto prazo.

[...] mostramos a estreita relação entre as classificações soberanas e a margem soberana (sovereign spread) do índice EMBI+, indicador mais usado como referência de medida de prêmios de risco-soberano cobrados nos mercados secundários de títulos de dívida de economias emergentes e que, corriqueiramente, tem sido identificado como medida para os “riscos-país”. Índices como o EMBI+ movem-se intensamente no curto prazo, ao passo que as classificações soberanas tenderiam a refletir mudanças de duração mais longa, bem como eventos com conseqüências amplas e profundas. No longo prazo, a convergência entre eles seria esperada. (CANUTO, SANTOS, 2003, p.5).

A avaliação de *rating* soberano é mais ampla que a simples análise da capacidade de pagamento do governo central. Ela também tem como objetivo avaliar a disposição do governo de honrar os seus compromissos financeiros no futuro. Este segundo ponto – a disposição em honrar compromissos - não é de fácil mensuração e envolve muito mais fatores subjetivos do que variáveis quantitativas.

A decisão final de concessão de *rating* pelas agências de avaliação de risco é tomada em comitês, através de votação. Diversos analistas expõem informações quantitativas e qualitativas, tal a traçar um prognóstico da disposição e do potencial de pagamento de um governo central. Geralmente são feitas algumas visitas de analistas ao país em processo de avaliação. Em tais visitas os profissionais das agências têm reuniões com representantes do governo; analistas econômicos; acadêmicos; jornalistas; dentre outros. Essas informações colhidas *in loco* são expostas nos comitês de votação e compõem o caráter subjetivo da avaliação de *rating*.

Algumas projeções de variáveis macroeconômicas são comumente usadas pelas agências nas suas análises, por exemplo: PIB nominal per capita (em dólares); crescimento real do PIB per capita; resultado nominal do governo geral / PIB; dívida líquida geral ou consolidada do governo / PIB; despesas brutas com juros / receitas brutas; inflação medida pelo índice de preços ao consumidor; necessidade bruta de financiamento externo / reservas internacionais; dívida externa líquida do setor público / receitas de conta corrente do balanço de pagamentos; e dívida externa líquida do setor privado não-financeiro / receitas de conta corrente do balanço de pagamentos, Canuto e Santos (2003).

3.2 Histórico de *rating* da Dívida soberana de longo prazo em moeda estrangeira dos países amostrados, considerando as três principais agências de *rating*.

Abaixo segue o histórico de *rating* referente à dívida soberana de longo prazo, em moeda estrangeira, dos países analisados. Para cada país foi disposto o histórico de notas das três principais agências de *rating* – a Moody's, a Standard & Poor's e a Fitch – estando frisado em negrito a primeira data em que cada agência concedeu o título de Grau de Investimento ao país. O primeiro registro de GI, dado por uma das três agências, será tomado como corte para esta pesquisa no propósito de avaliar a evolução da volatilidade em bolsa de valores.

3.2.1 MÉXICO

Moody's		
20/02/91	Ba2	Neutro
03/09/98	Ba2 (-)	Rebaixamento
10/02/99	Ba2	Elevação
21/06/99	Ba2 (+)	Elevação
10/08/99	Ba1	Elevação
02/02/00	Ba1 (+)	Elevação
07/03/00	Baa3	Elevação
06/02/02	Baa2	Elevação
06/01/05	Baa1	Elevação

Quadro 1 – Histórico de *rating* da Moody's em relação à dívida soberana de longo prazo em moeda estrangeira do México (Fonte: Bloomberg).

S&P		
29/07/92	BB+	Neutro
10/02/95	BB	Rebaixamento
13/03/00	BB +	Elevação
07/02/02	BBB-	Elevação
31/01/05	BBB	Elevação
08/10/07	BBB+	Elevação

Quadro 2 – Histórico de *rating* da S&P em relação à dívida soberana de longo prazo em moeda estrangeira do México (Fonte: Bloomberg).

Fitch		
30/08/95	BB	Neutro
11/04/00	BB (+)	Elevação
03/05/00	BB+	Elevação
15/01/02	BBB-	Elevação
07/12/05	BBB	Elevação
19/09/07	BBB+	Elevação

Quadro 3 – Histórico de rating da Fitch em relação à dívida soberana de longo prazo em moeda estrangeira do México (Fonte: Bloomberg).

A Moody's concedeu o primeiro registro de GI entre as três agências consideradas em 07/03/2000, data que será tomada como corte nesta pesquisa. Foi mantida progressividade na avaliação feita pela Moody's com mais duas elevações de nota nos anos subsequentes.

A Fitch elevou o México a Grau de investimento em 2002, mesmo ano que a S&P fez sua elevação. É válido frisar que, além da Moody's, a S&P e a Fitch também mantiveram progressividade nas suas avaliações de risco de crédito soberano de longo prazo do México, com uma sequência de duas elevações de nota após o registro de GI.

3.2.2 CHILE

Moody's		
25/05/99	Baa1	Neutro
21/03/06	Baa1 (+)	Elevação
07/07/06	A2	Elevação
20/11/08	A2 (+)	Elevação

Quadro 4 – Histórico de rating da Moody's em relação à dívida soberana de longo prazo em moeda estrangeira do Chile (Fonte: Bloomberg).

S&P		
07/12/92	BBB	Elevação
20/12/93	BBB+	Elevação
11/07/95	A-	Elevação
14/01/04	A	Elevação
18/12/07	A+	Elevação

Quadro 5 – Histórico de rating da S&P em relação à dívida soberana de longo prazo em moeda estrangeira do Chile (Fonte: Bloomberg).

Fitch		
10/11/94	BBB+	Neutro
30/08/95	A-	Elevação
28/03/05	A	Elevação

Quadro 6 – Histórico de rating da Fitch em relação à dívida soberana de longo prazo em moeda estrangeira do Chile (Fonte: Bloomberg).

A S&P foi a primeira entre as três agências a dar nota Grau de Investimento para o Chile em 07/12/1992, data que será considerada como corte nesta pesquisa.

No histórico de *rating* das três agências só aparece avaliação GI para a dívida soberana do Chile. As três agências mantiveram progressividade nas suas avaliações com uma sucessão de elevações de nota até o último registro.

3.2.3 ÍNDIA

Moody's

28/01/88	A2	Neutro
04/10/90	Baa1	Rebaixamento
26/03/91	Baa3	Rebaixamento
24/06/91	Ba2	Rebaixamento
14/09/94	Ba2 (+)	Elevação
01/12/94	Baa3	Elevação
08/01/98	Baa3 (-)	Rebaixamento
19/06/98	Ba2	Rebaixamento
14/11/02	Ba2 (+)	Elevação
03/02/03	Ba1	Elevação
22/01/04	Baa3	Elevação
24/05/06	Baa2	Elevação

Quadro 7 – Histórico de rating da Moody's em relação à dívida soberana de longo prazo em moeda estrangeira da Índia (Fonte: Bloomberg).

S&P

07/12/92	BB+	Neutro
22/10/98	BB	Rebaixamento
02/02/95	BB+	Elevação
30/1/2007	BBB-	Elevação

Quadro 8 – Histórico de rating da S&P em relação à dívida soberana de longo prazo em moeda estrangeira da Índia (Fonte: Bloomberg).

Fitch

08/03/00	BB+	Neutro
21/11/01	BB	Rebaixamento
21/01/04	BB+	Elevação
01/08/06	BBB-	Elevação

Quadro 9 – Histórico de rating da Fitch em relação à dívida soberana de longo prazo em moeda estrangeira da Índia (Fonte: Bloomberg).

O primeiro registro de Grau de Investimento no caso da Índia data de 28/01/88, com a concessão dada pela Moody's. No entanto, esta não manteve consistência em sua avaliação, tendo sido observado uma conjunção de elevações e rebaixamentos de *rating*.

Tanto a Fitch como a S&P têm como último registro histórico a nota GI que fora concedida recentemente. Note que nos três casos não existe consistência na avaliação de *rating*, sendo observada uma sucessão de elevações e rebaixamentos de nota.

3.2.4 RÚSSIA

Moody's		
21/11/96	Ba2	Neutro
11/03/98	Ba3	Rebaixamento
29/05/98	B1	Rebaixamento
13/08/98	Ba2	Rebaixamento
21/08/98	Ba3	Rebaixamento
23/08/00	B3 (+)	Elevação
05/09/01	B2	Elevação
29/11/01	Ba3	Elevação
17/10/02	Ba3 (+)	Elevação
17/12/02	Ba2	Elevação
28/07/03	Ba2 (+)	Elevação
08/10/03	Baa3	Elevação
08/09/05	Baa3 (+)	Elevação
25/10/05	Baa2	Elevação
27/03/08	Baa2 (+)	Elevação
16/07/08	Baa1	Elevação

Quadro 10 – Histórico de rating da Moody's em relação à dívida soberana de longo prazo em moeda estrangeira da Rússia (Fonte: Bloomberg).

S&P		
07/10/96	BB-	Neutro
09/06/98	B+	Rebaixamento
13/08/98	B-	Rebaixamento
17/08/98	CCC	Rebaixamento
16/09/98	CCC-	Rebaixamento
27/01/99	SD	Rebaixamento
08/12/00	B-	Elevação
28/06/01	B	Elevação
19/12/01	B+	Elevação
26/07/02	BB-	Elevação
05/12/02	BB	Elevação
27/01/04	BB+	Elevação
31/01/05	BBB-	Elevação
15/12/05	BBB	Elevação
04/09/06	BBB+	Elevação
08/12/08	BBB	Rebaixamento

Quadro 11 – Histórico de rating da S&P em relação à dívida soberana de longo prazo em moeda estrangeira da Rússia (Fonte: Bloomberg).

Fitch		
07/10/96	BB+	Neutro
05/06/98	BB	Rebaixamento
30/07/98	BB-	Rebaixamento
17/08/98	B-	Rebaixamento
26/08/98	CCC	Rebaixamento
14/02/00	CCC (+)	Elevação
08/05/00	B- (+)	Elevação
29/08/00	B	Elevação
04/10/01	B+	Elevação
02/05/02	BB-	Elevação
13/05/03	BB+	Elevação
18/11/04	BBB-	Elevação
03/08/05	BBB	Elevação
25/07/06	BBB+	Elevação
04/02/09	BBB	Rebaixamento

Quadro 12 – Histórico de rating da Fitch em relação à dívida soberana de longo prazo em moeda estrangeira da Rússia (Fonte: Bloomberg).

A primeira agência a conceder GI para a Rússia foi a Moody's em 08/10/2003, data que será usada como corte. A Moody's foi a única entre as três agências a manter progressividade, até o último registro de nota, na sua avaliação de risco de crédito soberano, dando uma sequência de mais quatro elevações de nota. Tanto a S&P como a Fitch registraram rebaixamento de *rating*, mas mantendo o status de GI.

3.2.5 CORÉIA DO SUL

Moody's

09/04/98	Ba1	Neutro
12/02/99	Baa3	Elevação
23/08/99	Baa3 (+)	Elevação
16/12/99	Baa2	Elevação
06/02/02	Baa2 (+)	Elevação
28/03/02	A3	Elevação
03/07/07	A3 (+)	Elevação
25/07/07	A2	Elevação

Quadro 13 – Histórico de rating da Moody's em relação à dívida soberana de longo prazo em moeda estrangeira da Coréia do Sul (Fonte: Bloomberg).

S&P

01/10/88	A+	Neutro
03/05/95	AA-	Elevação
24/10/97	A+	Rebaixamento
25/11/97	A-	Rebaixamento
11/12/97	BBB-	Rebaixamento
22/12/97	B+	Rebaixamento
16/01/98	B+	Neutro
18/02/98	BB+	Elevação
25/01/99	BBB-	Elevação
11/11/99	BBB	Elevação
13/11/01	BBB+	Elevação
24/07/02	A-	Elevação
27/07/05	A	Elevação

Quadro 14 – Histórico de rating da S&P em relação à dívida soberana de longo prazo em moeda estrangeira da Coréia do Sul (Fonte: Bloomberg).

Fitch

27/06/96	AA-	Neutro
18/11/97	A+	Rebaixamento
26/11/97	A	Rebaixamento
11/12/97	BBB-	Rebaixamento
23/12/97	B-	Rebaixamento
02/02/98	BB+	Elevação
19/01/99	BBB-	Elevação
26/04/99	BBB- (+)	Elevação
24/06/99	BBB	Elevação
30/03/00	BBB+	Elevação
13/05/02	BBB+ (+)	Elevação
27/06/02	A	Elevação
19/09/05	A (+)	Elevação
24/10/05	A+	Elevação

Quadro 15 – Histórico de rating da Fitch em relação à dívida soberana de longo prazo em moeda estrangeira da Coréia do Sul (Fonte: Bloomberg).

A primeira nota GI foi dada à Coréia do Sul em 01/10/88 pela S&P, que será considerada data de corte. A S&P, no entanto, não manteve consistência em sua avaliação dando, na sequência, uma elevação de nota e quatro rebaixamentos, chegando a retirar o status de GI dado anteriormente. A Moody's manteve consistência na sua avaliação após a concessão da nota GI, fazendo sucessivas elevações de *rating*. Já a Fitch não manteve consistência fazendo quatro rebaixamentos após a concessão e, assim como a S&P, retirando o status de GI.

Abaixo segue o resumo de notações usadas, por cada agência de *rating*, para a classificação de dívidas de longo prazo²:

Moody's

Grau de Investimento: Aaa, Aa1, Aa2, Aa3, A1, A2, A3, Baa1, Baa2, Baa3

Grau Especulativo: Ba1, Ba2, Ba3, B1, B2, B3, Caa1, Caa2, Caa3, Ca, C

S&P

Grau de Investimento: AAA, AA+, AA, AA-, A+, A, A-, BBB+, BBB, BBB-

Grau Especulativo: BB+, BB, BB-, B+, B, B-, CCC+, CCC, CCC-, CC, R, SD e D, NR

Fitch

Grau de Investimento: AAA, AA+, AA, AA-, A+, A, A-, BBB+, BBB, BBB-

Grau Especulativo: BB+, BB, BB-, B+, B, B-, CCC+, CCC, CCC-, CC, C, DDD, DD, RD, D, WD, PIF, NR

Neste capítulo foram expostos conceitos importantes com o de risco-soberano e risco país. Este, como comentado, é mais amplo que o primeiro, envolvendo variáveis que visam captar o risco de crédito de emissões privadas domésticas, além de emissões do governo. O risco-soberano, por sua vez, é mais restrito e envolve apenas a avaliação de risco de crédito de emissões do governo. Também foi feita uma discussão sobre alguns critérios usados pelas agências de *rating* para avaliar risco de crédito soberano, tendo sido destacado que essa avaliação envolve tanto variáveis quantitativas bem como variáveis qualitativas de cunho subjetivo. Por fim, foram expostos os históricos de *rating* das economias amostradas, construídos pelas três principais agências de avaliação de risco. Como visto, as concessões de GI ao México, Chile e Rússia foram consistentes; ou seja, uma vez concedida a primeira avaliação GI, tal status manteve-se até o final do histórico de *rating* nas três agências. Já para a Índia e Coréia do Sul, não houve consistência na avaliação de *rating*, tendo sido observado uma sucessão de rebaixamentos e elevações de nota após o primeiro registro de GI.

² Fonte: Bloomberg.

4 MODELANDO A VOLATILIDADE DOS RETORNOS DOS ÍNDICES DE BOLSA DE VALORES DOS PAÍSES AMOSTRADOS.

Neste capítulo são escolhidos os modelos, da família GARCH, adequados para modelar a volatilidade dos retornos dos índices estudados. Primeiramente, são expostas informações estatísticas das séries de retornos, como a função de densidade Kernel; o histograma; o teste Jarque-Bera; a medida de curtose; o coeficiente de assimetria; o gráfico QQ-Normal; e o teste do efeito ARCH. Para a escolha dos modelos para modelar a volatilidade dos retornos são usados os critérios de informação de Akaike e Schwarz, bem como a significância estatística dos parâmetros estimados.

4.1 Dados

Os dados usados foram obtidos da Bloomberg, em 12/01/2009, correspondendo às séries históricas, do valor de fechamento de mercado, dos principais índices de bolsa de valores dos países amostrados. A periodicidade aplicada foi diária. O período de amostragem usado varia de índice para índice, visto que para alguns a série histórica de cotações é mais curta que para outros. No caso do México e do Chile a mostra usada vai do início de 1989 até a última informação disponível em 2008. Para a Coréia do Sul e Índia a amostra usada vai do início de 1985 até 2008. Já para a Rússia a amostra vai de 1995 até 2008, já que a série histórica disponível só tem início em 1995.

Para achar os retornos dos índices foi usado o logaritmo natural do quociente entre o valor do índice em “t” e seu o valor anterior em “t-1”. O retorno do índice está representado

pela letra Y_t . Sendo X_t o valor do índice em “t”, vem: $Y_t = \text{Log}\left(\frac{X_t}{X_{t-1}}\right)$.

Para calcular o retorno de uma série de valores discretos, usamos a fórmula

$r_{d,t} = \frac{(A_t - A_{t-1})}{A_{t-1}}$ onde A_t é o preço do ativo A no instante t=i. O desvio-

padrão calculado para uma série de retornos calculados por essa fórmula também pode ser chamado risco. Por outro lado, ao trabalharmos com séries

contínuas deveremos usar a fórmula $r_{c,t} = \text{Log}\left(\frac{A_t}{A_{t-1}}\right)$. O desvio-padrão

dessa nova série de retornos é chamado de volatilidade. (SECURATO, 2008, p. 366-367)

4.2 Modelagem

Para modelar a volatilidade dos retornos dos índices amostrados foram usados modelos da família GARCH, possibilitando a obtenção do processo gerador da volatilidade e, conseqüentemente, as volatilidades condicionais de cada série de retornos.

O critério de escolha do tipo de modelo, bem como da identificação do mesmo, baseou-se na significância dos parâmetros estimados e nos critérios de informação de Akaike e de Schwarz. O nível de significância crítico usado neste trabalho é de 2%. Para a escolha da modelagem da média dos retornos foram utilizadas as funções de auto-correlação e auto-correlação parcial dos resíduos, estes obtidos das séries de retornos dos índices, sendo observado o comportamento do correlograma ao longo das defasagens consideradas. Para a estimação dos modelos foi utilizado o software E-views versão 5.0.

4.2.1 México

Gráfico do retorno do índice Mexbol do México:




Figura 1 – Gráfico do retorno do índice de bolsa Mexbol do México.

Abaixo segue a função de densidade Kernel, o histograma e um quadro resumo de algumas estatísticas referentes à série de retornos do índice Mexbol:

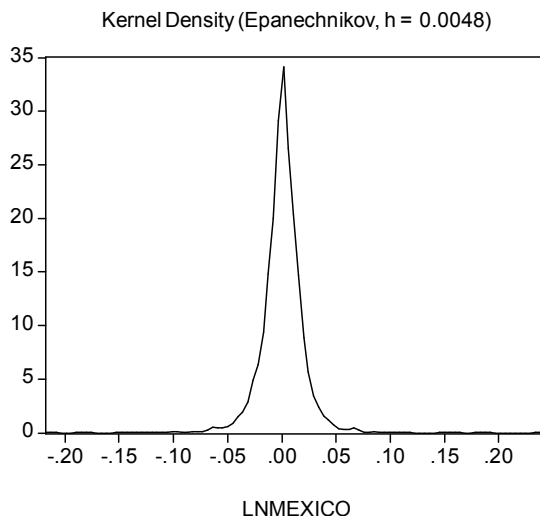


Figura 2 – Gráfico da função de densidade Kernel para a série de retornos do índice Mexbol




Figura 3 – Histograma e quadro resumo de estatísticas referentes à série de retornos do índice Mexbol

O teste Jarque-Bera permite rejeitar a hipótese nula de normalidade da distribuição que deu origem aos dados. A medida de curtose confirma o teste anterior ao atingir valor superior a 3, o que indica que a distribuição é mais afunilada – concentrada- que a normal e caracteriza uma distribuição leptocúrtica, que tem como característica a existência de caldas pesadas, o que é comum em séries financeiras. O coeficiente de assimetria menor que zero de -0,16 indica assimetria negativa, ou seja, que as observações estão mais concentradas à direita do zero, sendo mais provável encontrar retornos positivos que negativos para o índice em questão.

A figura 4 com o gráfico QQ-Normal, dos retornos padronizados do Mexbol, confirma que estes não distribuem-se normalmente, sendo observado a existência de caudas pesadas.




Figura 4 – Gráfico QQ-Normal dos retornos padronizados do índice Mexbol.

Antes de modelar a série de retorno do Mexbol é conveniente, segundo Brooks (p. 449, 2002), testar a existência do efeito ARCH nos resíduos. O primeiro passo para tal é regredir, por mínimos quadrados, a variável retorno diário do Mexbol sobre uma constante C , obtendo-se uma série de resíduos.

O segundo passo consiste em regredir a série de resíduos obtida, ao quadrado, sobre ela própria defasada até a quinta defasagem³. Dessa regressão obtemos o R^2 que, multiplicado pelo tamanho da amostra, nos dá a estatística para o teste de Engle. Tal estatística segue uma distribuição $\chi^2_{(q)}$, sendo q o número de defasagens usado.

Rodado o teste foram obtidas as seguintes estatísticas:

Estatística F: 135.2469

Estatística LM: 599.1830

Como esperado o teste realizado rejeitou a hipótese nula, o que indica existência de efeito ARCH. Portanto, com a confirmação do teste, é conveniente modelar a volatilidade dos

³ Lembrando que o número de defasagens usado fica a critério do pesquisador, sendo o número “5” uma sugestão dada por Brooks(2002).

resíduos. Antes, no entanto, é necessário modelar a média dos retornos, que é feito utilizando as funções de auto-correlação e auto-correlação parcial que sugerem um processo AR(1); o que é confirmado, uma vez que os resíduos padronizados, em nível e elevados ao quadrado, não exibem auto-correlação ao longo das defasagens com a imposição da estrutura auto-regressiva - como indicam os correlogramas - garantindo boa especificação do modelo (ver anexo A).

Para modelar a volatilidade dos resíduos foram rodados modelos da classe GARCH, EGARCH e TARCH, quais sejam: GARCH(0,1), GARCH(1,0), GARCH(1,1), GARCH(2,1), GARCH(1,2), GARCH(2,2), TARCH(0,1), TARCH(1,0), TARCH(1,1), TARCH(2,1), TARCH(1,2), TARCH(2,2), EGARCH(0,1), EGARCH(1,0), EGARCH(1,1), EGARCH(2,1), EGARCH(1,2), EGARCH(2,2). Destes modelos foram selecionados aqueles com alta significância estatística⁴, quais sejam: GARCH(0,1), GARCH(1,0), GARCH(1,1), GARCH(2,1), GARCH(1,2), TARCH(1,0), TARCH(1,1), EGARCH(1,0), EGARCH(1,1), EGARCH(2,1), EGARCH(1,2). Na escolha do melhor modelo foram usados os critérios de informação de Akaike e Schwarz entre aqueles que apresentaram alta significância estatística dos parâmetros estimados (ver quadro 16):

	AIC	SIC
<i>GARCH(0,1)</i>	-5.349937	-5.343649
<i>GARCH(1,0)</i>	-5.409262	-5.402974
<i>GARCH(1,1)</i>	-5.499353	-5.491808
<i>GARCH(2,1)</i>	-5.500045	-5.491242
<i>GARCH(1,2)</i>	-5.500011	-5.491208
<i>TARCH(0,1)</i>	-5.515674	-5.508129
<i>TARCH(1,0)</i>	-5.412895	-5.405349
<i>TARCH(1,1)</i>	-5.519199	-5.510396
<i>EGARCH(1,0)</i>	-5.390912	-5.384624
<i>EGARCH(1,1)</i>	-5.493983	-5.486438
<i>EGARCH(2,1)</i>	-5.495696	-5.486893
<i>EGARCH(1,2)</i>	-5.495346	-5.486543

Quadro 16 – Quadro comparativo com relação ao critério de informação de Akaike e Schwarz dos modelos selecionados para modelar a volatilidade dos resíduos, obtidos da série de retornos do Mexbol.

⁴ Considerando o nível de significância de 2%.

Pelo critério informacional o modelo escolhido foi o TARCH(1,1), com base nas informações dispostas no quadro 16.

Modelo Escolhido: AR(1) – TARCH(1,1)⁵

$$Y_t = 0.000896 + 0.150110Y_{t-1}$$

(4.13) (10.73)

$$\sigma_t^2 = 1.13 + 0.035697\mu_{t-1}^2 + 0.845840\sigma_{t-1}^2 + 0.168941\mu_{t-1}^2 I_{t-1}$$

(7.76) (3.41) (68.35) (9.14)

Onde $I_{t-1} = 1$ se $\mu_{t-1} < 0$
 $= 0$ caso contrário

Em parênteses as estatísticas de teste “t”.

Note que os choques negativos têm respostas bem superiores em termos de volatilidade que os choques positivos, visto que $\alpha_1 = 0.035697$ enquanto $\gamma = 0.168941$. Todos os parâmetros estimados são positivos, respeitando a restrição de não-negatividade e garantindo que o efeito assimétrico seja capturado corretamente.

Para avaliar a adequação do modelo TARCH(1,1) escolhido é conveniente verificar se o efeito ARCH fora suprimido após a modelagem. Segue as estatísticas obtidas no teste:

Estatística F: 0.859013

Estatística LM: 4.296473

Não é possível rejeitar a hipótese nula de inexistência de efeito ARCH na série de resíduos obtidos do modelo TARCH(1,1). Tal fato indica que a modelagem usada está bem especificada e consegue capturar os movimentos de volatilidade dos resíduos.

⁵ Ver anexo B quadro-resumo da estimação do modelo (admitindo distribuição t-student).

4.2.2 Chile

Gráfico do retorno do índice Ipsa do Chile:

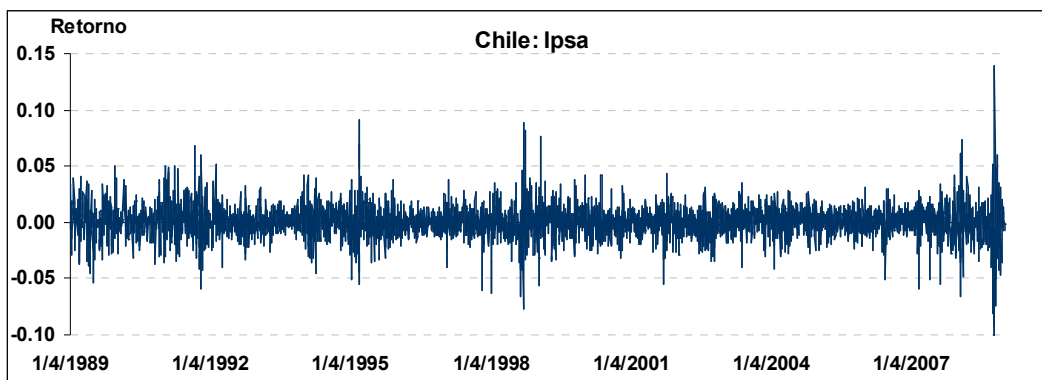


Figura 5 – Gráfico do retorno do índice de bolsa Ipsa do Chile.

Abaixo segue a função de densidade Kernel, o histograma e um quadro resumo de algumas estatísticas referentes à série do retorno do índice Ipsa:

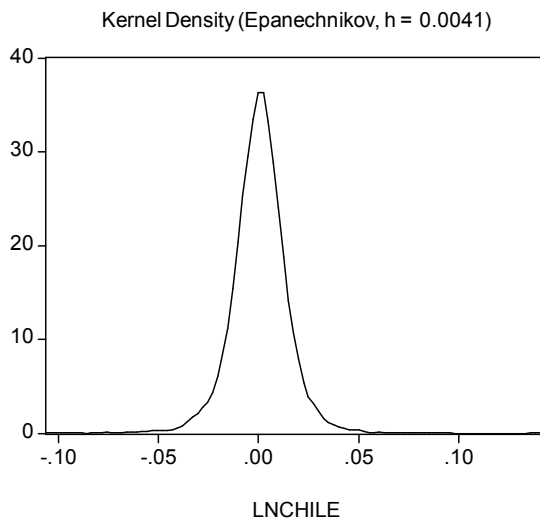


Figura 6 – Gráfico da função de densidade Kernel para a série de retornos do índice Ipsa.




Figura 7 – Histograma e quadro resumo das estatísticas referentes à série do índice Ipsi.

O teste Jarque-Bera permite rejeitar a hipótese nula de normalidade da distribuição que deu origem aos dados. A medida de curtose confirma o teste anterior ao atingir valor superior a 3, o que indica que a distribuição é mais afunilada – concentrada- que a normal e caracteriza uma distribuição leptocúrtica que tem como característica a existência de caldas pesadas. O coeficiente de assimetria de 0.018013, próximo de zero, sugere simetria da distribuição, o que pode ser visualmente confirmado na figura 6 com a densidade de Kernel.

A figura 8 com o gráfico QQ-Normal dos retornos padronizados do Mexbol confirma que estes não distribuem-se normalmente, sendo observado a existência de caldas pesadas.




Figura 8 – Gráfico QQ-Normal dos retornos padronizados do índice IPSA.

Testando a existência do efeito ARCH nos resíduos obtidos a partir da série de retornos em questão, chegamos às seguintes estatísticas de teste:

Estatística F: 227.1010

Estatística LM: 925.5080

Como esperado o teste realizado rejeitou a hipótese nula, o que indica existência de efeito ARCH. Com a confirmação do teste, é conveniente modelar a volatilidade dos resíduos. Antes, no entanto, é necessário modelar a média dos retornos, que é feita utilizando as funções de auto-correlação e auto-correlação parcial que sugerem um processo AR(1); o que é confirmado, uma vez que os resíduos padronizados, em nível e elevados ao quadrado, não exibem auto-correlação ao longo das defasagens com a imposição da estrutura auto-regressiva - como indicam os correlogramas - garantindo boa especificação do modelo (ver anexo C).

Para modelar a volatilidade dos resíduos foram rodados modelos da classe GARCH – EGARCH, TARCH e GARCH, quais sejam: GARCH(0,1), GARCH(1,0), GARCH(1,1), GARCH(2,1), GARCH(1,2), GARCH(2,2), TARCH(0,1), TARCH(1,0), TARCH(1,1), TARCH(2,1), TARCH(1,2), TARCH(2,2), EGARCH(0,1), EGARCH(1,0), EGARCH(1,1), EGARCH(2,1), EGARCH(1,2), EGARCH(2,2). Destes modelos foram selecionados aqueles com alta significância estatística⁶, quais sejam: GARCH(1,0), GARCH(1,1), TARCH(0,1), TARCH(1,1), EGARCH(0,1), EGARCH(1,0), EGARCH(1,1). Para escolher o melhor modelo foram usados os critérios de informação de Akaike e Schwarz como segue (ver quadro 17):

	AIC	SIC
<i>GARCH(1,0)</i>	-5.943344	-5.936806
<i>GARCH(1,1)</i>	-6.020585	-6.012741
<i>TARCH(0,1)</i>	-5.999303	-5.991458
<i>TARCH(1,1)</i>	-6.023956	-6.014804
<i>EGARCH(0,1)</i>	-5.889319	-5.882782
<i>EGARCH(1,0)</i>	-5.927283	-5.920746
<i>EGARCH(1,1)</i>	-6.018852	-6.011007

Quadro 17 – Quadro comparativo com relação ao critério de informação de Akaike e Schwarz dos modelos selecionados para modelar a volatilidade dos resíduos obtidos da série de retornos do Ipsa.

⁶ Considerando o nível de significância de 2%.

Pelo critério informacional o modelo escolhido foi o TARCH(1,1) com base nas informações dispostas no quadro 17.

Modelo Escolhido: AR(1) – TARCH(1,1)⁷

$$Y_t = 0.00059 + 0.23671Y_{t-1}$$

(2.93) (16.73)

$$\sigma_t^2 = 7.95 + 0.107452\mu_{t-1}^2 + 0.809816\sigma_{t-1}^2 + 0.079542\mu_{t-1}^2 I_{t-1}$$

(6.52) (7.10) (50.15) (4.12)

Onde $I_{t-1} = 1$ se $\mu_{t-1} < 0$
 $= 0$ caso contrário

Em parênteses as estatísticas de teste “t”.

O resultado da estimação mostra que choques positivos têm maior resposta em termo de volatilidade do que choques negativos, visto que $\alpha_1 = 0.107452$ enquanto $\gamma = 0.079542$.

Note que todos os parâmetros estimados são positivos, respeitando a restrição de não negatividade e garantindo que o efeito assimétrico seja captado corretamente.

Para avaliar a adequação do modelo TARCH(1,1) escolhido é conveniente verificar se o efeito ARCH fora suprimido após a modelagem. Segue as estatísticas obtidas no teste:

Estatística F: 0.698118

Estatística LM: 3.492351

Não é possível rejeitar a hipótese nula de inexistência do efeito ARCH na série de resíduos obtidos da modelagem TARCH(1,1). Tal fato indica que o modelo usado está bem especificado e consegue capturar os movimentos de volatilidade dos resíduos.

⁷ Ver anexo D o quadro-resumo da estimação do modelo (admitindo distribuição t-student).

4.2.3 Índia

Gráfico do retorno do índice BSE Sensex 30 da Índia:

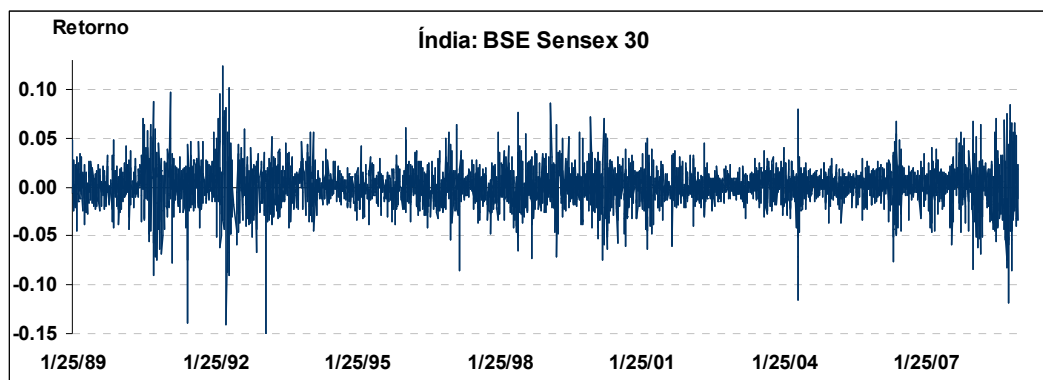


Figura 9 – Gráfico do retorno do índice de bolsa BSE Sensex 30 da Índia.

Abaixo segue a função de densidade Kernel, o histograma e um quadro resumo de algumas estatísticas referentes à série do retorno do índice BSE Sensex 30:




Figura 10 – Gráfico da função de densidade Kernel para a série de retornos do índice BSE Sensex 30.




Figura 11 – Histograma e quadro resumo das estatísticas referentes à série do índice BSE Sensex 30.

O teste Jarque-Bera permite rejeitar a hipótese nula de normalidade da distribuição que deu origem aos dados. A medida de curtose confirma o teste anterior ao atingir valor superior a 3, o que indica que a distribuição é mais afunilada – concentrada- que a normal e caracteriza uma distribuição leptocúrtica que tem como característica a existência de caldas pesadas. O coeficiente de assimetria de -0.296267 sugere assimetria negativa do histograma, ou seja, é mais provável a ocorrência de retornos positivos que negativos.

A figura 12 com o gráfico QQ-Normal dos retornos padronizados do BSE Sensex 30 confirma que estes não distribuem-se normalmente, sendo observado a existência de caldas pesadas.




Figura 12 – Gráfico QQ-Normal dos retornos padronizados do índice BSE Sensex 30.

Testando a existência do efeito ARCH nos resíduos, obtemos as seguintes estatísticas de teste:

Estatística F: 125.6841

Estatística LM: 564.9793

Como esperado o teste realizado rejeitou a hipótese nula, o que indica existência de efeito ARCH. Com a confirmação do teste é conveniente modelar a volatilidade dos resíduos.

Para modelar a média dos retornos foram utilizadas as funções de auto-correlação e auto-correlação parcial que sugerem um processo AR(1); O que é confirmado, uma vez que com a imposição do processo AR(1) os resíduos padronizados, em nível e elevados ao quadrado, não exibem auto-correlação ao longo das defasagens, como indicam os correlogramas, garantindo boa especificação do modelo (ver anexo 5).

Para modelar a volatilidade dos resíduos foram rodados modelos da classe GARCH, EGARCH e TARCH, como segue: GARCH(0,1), GARCH(1,0), GARCH(1,1), GARCH(2,1), GARCH(1,2), GARCH(2,2), TARCH(0,1), TARCH(1,0), TARCH(1,1), TARCH(2,1), TARCH(1,2), TARCH(2,2), EGARCH(0,1), EGARCH(1,0), EGARCH(1,1), EGARCH(2,1), EGARCH(1,2), EGARCH(2,2). Destes modelos foram selecionados aqueles com alta significância estatística⁸, quais sejam: GARCH(1,0), GARCH(1,1), TARCH(0,1), TARCH(1,0), TARCH(1,1), EGARCH(0,1), EGARCH(1,0), EGARCH(1,1), EGARCH(2,2). Para escolher o melhor modelo foram usados os critérios de informação de Akaike e Schwarz, como segue.

	AIC	SIC
<i>GARCH(1,0)</i>	-5.270928	-5.264960
<i>GARCH(1,1)</i>	-5.369733	-5.362571
<i>TARCH(0,1)</i>	-5.348691	-5.341529
<i>TARCH(1,0)</i>	-5.272598	-5.265437
<i>TARCH(1,1)</i>	-5.372960	-5.364604
<i>EGARCH(0,1)</i>	-5.225509	-5.219541
<i>EGARCH(1,0)</i>	-5.258517	-5.252548
<i>EGARCH(1,1)</i>	-5.367356	-5.360194
<i>EGARCH(2,2)</i>	-5.367503	-5.357954

Quadro 18 – Quadro comparativo com relação ao critério de informação de Akaike e Schwarz dos modelos selecionados para modelar a volatilidade dos resíduos obtidos da série de retornos do BSE Sensex 30.

⁸ Considerando 2% de significância.

Pelo critério informacional o modelo escolhido foi o TARCH(1,1) com base nas informações dispostas no quadro 18.

Modelo Escolhido: AR(1) – TARCH(1,1)⁹

$$Y_t = 0.000725 + 0.125789Y_{t-1} + \varepsilon_t$$

(3.29) (9.01)

$$\sigma_t^2 = 1.07 + 0.090989\mu_{t-1}^2 + 0.845062\sigma_{t-1}^2 + 0.077079\mu_{t-1}^2 I_{t-1}$$

(6.27) (7.11) (65.44) (4.30)

Onde $I_{t-1} = 1$ se $\mu_{t-1} < 0$
 $= 0$ caso contrário

Em parênteses as estatísticas de teste “t”.

O resultado da estimação mostra que choques positivos têm maior resposta em termo de volatilidade do que choques negativos, visto que $\alpha_1 = 0.090989$ enquanto $\gamma = 0.077079$.

Note que todos os parâmetros estimados são positivos, respeitando a restrição de não negatividade e garantindo que o efeito assimétrico seja capturado corretamente.

Para avaliar a adequação do modelo TARCH(1,1) escolhido para modelar a volatilidade dos resíduos é conveniente verificar se o efeito ARCH fora suprimido após a modelagem. Segue as estatísticas obtidas no teste:

Estatística F: 0.266767

Estatística LM: 1.334961

Não é possível rejeitar a hipótese nula de inexistência de efeito ARCH na série de resíduos obtidos da modelagem TARCH(1,1). Tal fato indica que o modelo usado está bem especificado e consegue capturar os movimentos de volatilidade dos resíduos.

⁹ Ver anexo F o quadro-resumo da estimação do modelo (admitindo distribuição t-student).

4.2.4 Rússia

Gráfico do retorno do índice RTS da Rússia:




Figura 13 – Gráfico do retorno do índice de bolsa RTS da Rússia.

Abaixo segue a função de densidade Kernel, o histograma e um quadro resumo de algumas estatísticas referentes à série do retorno do índice RTS:

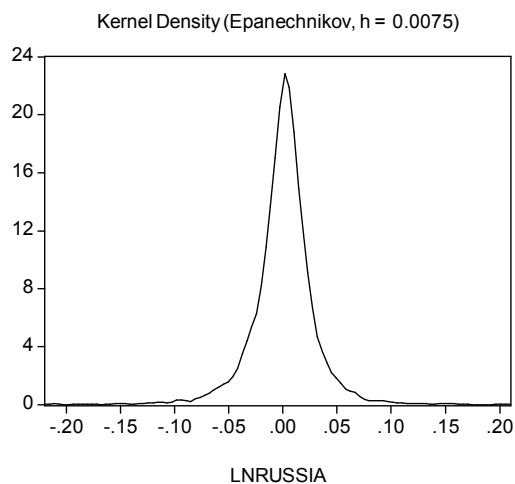


Figura 14 – Gráfico da função de densidade Kernel para a série de retornos do índice RTS.




Figura 15 – Histograma e quadro resumo das estatísticas referentes à série do índice RTS.

O teste Jarque-Bera permite rejeitar a hipótese nula de normalidade da distribuição que deu origem aos dados. A medida de curtose confirma o teste anterior ao atingir valor superior a 3, o que indica que a distribuição é mais afunilada – concentrada- que a normal e caracteriza uma distribuição leptocúrtica que tem como característica a existência de caldas pesadas. O coeficiente de assimetria de -0.402871 sugere assimetria negativa do histograma, ou seja, é mais provável a ocorrência de retornos positivos que negativos.

A figura 16 com o gráfico QQ-Normal dos retornos padronizados do RTS confirma que estes não se distribuem normalmente, sendo observada a existência de caldas pesadas.




Figura 16 – Gráfico QQ-Normal dos retornos padronizados do índice RTS.

Testando a existência do efeito ARCH nos resíduos, obtemos as seguintes estatísticas de teste:

Estatística F: 87.28038

Estatística LM: 386.1858

Como esperado, o teste realizado rejeitou a hipótese nula, o que indica existência de efeito ARCH. Com a confirmação do teste é conveniente modelar a volatilidade dos resíduos.

Para modelar a média dos retornos foram utilizadas as funções de auto-correlação e auto-correlação parcial que sugerem um processo AR(1). De fato, o processo é confirmado, uma vez que com a imposição do processo AR(1) os resíduos padronizados, em nível e elevados ao quadrado, não exibem auto-correlação ao longo das defasagens, como indicam os correlogramas, garantindo boa especificação do modelo (ver anexo G).

Para modelar a volatilidade dos resíduos foram rodados modelos da classe GARCH, EGARCH e TARCH, quais sejam: GARCH(0,1), GARCH(1,0), GARCH(1,1), GARCH(2,1), GARCH(1,2), GARCH(2,2), TARCH(0,1), TARCH(1,0), TARCH(1,1), TARCH(2,1), TARCH(1,2), TARCH(2,2), EGARCH(0,1), EGARCH(1,0), EGARCH(1,1), EGARCH(2,1), EGARCH(1,2), EGARCH(2,2). Destes modelos foram selecionados aqueles com alta significância estatística¹⁰, quais sejam: GARCH(1,0), GARCH(1,1), TARCH(0,1), EGARCH(1,0), EGARCH(1,1). Para escolher o melhor modelo foram usados os critérios de informação de Akaike e Schwarz, como segue.

	<i>AIC</i>	<i>SIC</i>
<i>GARCH(1,0)</i>	-4.652874	-4.643661
<i>GARCH(1,1)</i>	-4.786301	-4.775247
<i>TARCH(0,1)</i>	-4.739294	-4.728240
<i>EGARCH(1,0)</i>	-4.616313	-4.607101
<i>EGARCH(1,1)</i>	-4.781756	-4.770701

Quadro 19 – Quadro comparativo com relação ao critério de informação de Akaike e Schwarz dos modelos selecionados para modelar a volatilidade dos resíduos obtidos da série de retornos do RTS.

Pelo critério informacional o modelo escolhido foi o GARCH(1,1) com base nas informações dispostas no quadro 19.

¹⁰ Considerando 2% de nível de significância.

Modelo Escolhido: AR(1) – GARCH(1,1)¹¹

$$Y_t = 0.001986 + 0.12119Y_{t-1} + \varepsilon_t$$

(5.64) (6.79)

$$\sigma_t^2 = 1.26 + 0.163293\mu_{t-1}^2 + 0.834654\sigma_{t-1}^2$$

(4.81) (9.48) (55.78)

Em parênteses as estatísticas de teste “t”.

Note que os parâmetros estimados são todos positivos, respeitando a hipótese de não-negatividade exigida nos modelos GARCH.

Para avaliar a adequação do modelo GARCH(1,1) escolhido para modelar a volatilidade dos resíduos é conveniente verificar se o efeito ARCH fora suprimido após a modelagem. Segue as estatísticas obtidas no teste:

Estatística F: 1.02325

Estatística LM: 5.117617

Não é possível rejeitar a hipótese nula de inexistência de efeito ARCH na série de resíduos obtidos do modelo GARCH(1,1). Tal fato indica que o modelo usado está bem especificado e consegue capturar os movimentos de volatilidade dos resíduos.

¹¹ Ver anexo H o quadro-resumo da estimação do modelo (admitindo distribuição t-student).

4.2.5 Coréia do Sul

Gráfico do retorno do índice KOSPI da Coréia do Sul:




Figura 17 – Gráfico do retorno do índice de bolsa KOSPI da Coréia do Sul.

Abaixo segue a função de densidade Kernel, o histograma e um quadro resumo de algumas estatísticas referentes à série do retorno do índice KOSPI:

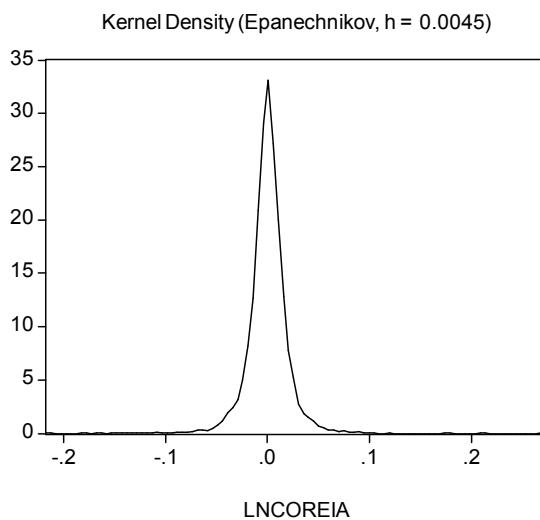


Figura 18 – Gráfico da função de densidade Kernel para a série de retornos do índice KOSPI.




Figura 19 – Histograma e quadro resumo das estatísticas referentes à série do índice KOSPI.

O teste Jarque-Bera permite rejeitar a hipótese nula de normalidade da distribuição que deu origem aos dados. A medida de curtose confirma o teste anterior ao atingir valor bem superior a 3, o que indica que a distribuição é mais afunilada – concentrada- que a normal e caracteriza uma distribuição leptocúrtica que tem como característica a existência de caldas pesadas. O coeficiente de assimetria de -0.04129 sugere leve assimetria negativa do histograma, ou seja, é mais provável a ocorrência de retornos positivos que negativos.

A figura 20 com o gráfico QQ-Normal dos retornos padronizados do KOSPI confirma que estes não distribuem-se normalmente, sendo observado a existência de caldas pesadas.




Figura 20 – Gráfico QQ-Normal dos retornos padronizados do índice KOSPI.

Testando a existência do efeito ARCH nos resíduos, obtemos as seguintes estatísticas de teste:

Estatística F: 284.7456

Estatística LM: 1169.153

Como esperado o teste realizado rejeitou a hipótese nula, o que indica existência de efeito ARCH. Com a confirmação do teste é conveniente modelar a volatilidade dos resíduos.

O processo AR(1) é apropriado para modelar a média dos retornos, como indicam os correlogramas¹² dos resíduos padronizados em nível e elevados ao quadrado. Estes não exibem auto-correlação ao longo das defasagens com a imposição da estrutura AR(1).

Foram rodados modelos da classe GARCH, EGARCH e TARCH, quais sejam: GARCH(0,1), GARCH(1,0), GARCH(1,1), GARCH(2,1), GARCH(1,2), GARCH(2,2), TARCH(0,1), TARCH(1,0), TARCH(1,1), TARCH(2,1), TARCH(1,2), TARCH(2,2), EGARCH(0,1), EGARCH(1,0), EGARCH(1,1), EGARCH(2,1), EGARCH(1,2), EGARCH(2,2). Destes modelos foram selecionados aqueles com alta significância estatística¹³, quais sejam: GARCH(0,1), GARCH(1,0) e GARCH(1,1). Para escolher o melhor modelo foram usados os critérios de informação de Akaike e Schwarz, como segue.

	AIC	SIC
<i>GARCH(0,1)</i>	-5.345939	-5.340734
<i>GARCH(1,0)</i>	-5.402991	-5.397787
<i>GARCH(1,1)</i>	-5.598880	-5.592634

Quadro 20 – Quadro comparativo com relação ao critério de informação de Akaike e Schwarz dos modelos selecionados para modelar a volatilidade dos resíduos obtidos da série de retornos do índice KOSPI.

Pelo critério informacional o modelo escolhido foi o GARCH(1,1) com base nas informações dispostas no quadro 20.

¹² Ver anexo I.

¹³ Considerando 2% de significância.

Modelo Escolhido: AR(1) – GARCH(1,1)¹⁴

$$Y_t = 0.000427 + 0.095871Y_{t-1} + \varepsilon_t$$

(2.76) (7.42)

$$\sigma_t^2 = 1.15 + 0.102981\mu_{t-1}^2 + 0.901192\sigma_{t-1}^2$$

(3.60) (13.0) (130.12)

Em parênteses as estatísticas de teste “t”.

Note que todos os parâmetros estimados pelo modelo GARCH(1,1) são positivos, respeitando, portanto, a hipótese de não-negatividade exigida pelos modelos GARCH.

Para avaliar a adequação do modelo GARCH(1,1) escolhido para modelar a volatilidade dos resíduos é conveniente verificar se o efeito ARCH fora suprimido após a modelagem. Segue as estatísticas obtidas no teste:

Estatística F: 1.436467

Estatística LM: 7.181033

Não é possível rejeitar a hipótese nula de inexistência de efeito ARCH na série de resíduos obtidos do modelo GARCH(1,1). Tal fato indica que o modelo usado está bem especificado e consegue capturar os movimentos de volatilidade dos resíduos.

Neste capítulo foram escolhidos os modelos adequados para modelar a volatilidade dos retornos dos índices estudados. Os modelos escolhidos para o caso do México, do Chile e da Índia foram o modelo AR(1)-TARCH(1,1), e os modelos escolhidos para os casos da Rússia e da Coréia do Sul foi o AR(1)-GARCH(1,1). A partir dos modelos é possível obter a volatilidade condicional para cada série de retornos, como será feito no próximo capítulo.

¹⁴ Ver anexo J o quadro-resumo da estimação do modelo (admitindo distribuição t-student).

5 COMPARAÇÃO DA VOLATILIDADE CONDICIONAL *EX-ANTE* E *EX-POST* À CONCESSÃO DO GRAU DE INVESTIMENTO

Como descrito na introdução, esta pesquisa busca responder à seguinte pergunta: a elevação de uma economia emergente a GI tem como consequência a mitigação da volatilidade em bolsa de valores, isto no médio e longo prazo?

Neste capítulo é avaliada a evolução da volatilidade condicional dos principais índices de bolsa de valores de uma amostra, representativa, de economias emergentes que tiveram suas dívidas soberanas¹⁵ elevadas a Grau de Investimento no passado. A data da primeira elevação da economia emergente a GI é usada como corte no propósito de comparar a volatilidade condicional *ex-ante* e *ex-post* ao evento concessão de GI.

É razoável pensar que a elevação de uma economia emergente a GI torne mais estável os fluxos de investimentos no mercado de capitais doméstico, reduzindo, assim, a volatilidade em bolsa de valores. Isto porque o risco de crédito soberano é uma importante âncora da confiança de investidores em relação a uma economia e, conseqüentemente, do seu mercado de capitais. Com a melhora da percepção de risco, por conta do status de GI, é intuitivo pensar que a participação de investimentos de longo prazo, estes estáveis por natureza, na composição dos investimentos totais em bolsa de valores tenda a aumentar. Isto teria como consequência a redução da volatilidade em bolsa. Morais e Portugal (2009) chegaram a resultados empíricos que confirmam a ocorrência de mitigação de volatilidade, em bolsa de valores, de economias emergentes que tiveram elevação de *rating* soberano: “Results point out that a higher grade awarded to sovereign debt bonds by an international agency leads to periods of lower volatility in the local stock market. This is associated with improved risk perception by the agents.”

Uma vez modelada a volatilidade dos retornos dos índices amostrados, é conhecido o processo gerador de volatilidade em cada caso e, portanto, é possível avaliar a evolução da volatilidade condicional das séries de retornos dos índices.

Para responder à pergunta levantada nesta pesquisa, é gerada uma série de volatilidade condicional, para cada índice amostrado, a partir dos modelos econométricos selecionados. Estas séries são seccionadas em três períodos. O primeiro período corresponde aos vinte e quatro meses imediatamente anteriores à concessão do primeiro GI, que é usado como período base de comparação nesta pesquisa. O segundo período, corresponde aos vinte e quatro meses

¹⁵ De longo prazo em moeda estrangeira.

imediatamente posteriores à ocorrência do evento; e, por fim, o terceiro período seccionado corresponde aos vinte e quatro meses posteriores ao término do segundo período.

É calculada a média aritmética da volatilidade condicional de cada um dos três períodos. Posteriormente, são feitas as razões entre cada uma das volatilidades condicionais médias dos dois períodos *ex-post* ao evento - primeira concessão de GI¹⁶ - com relação à volatilidade média referente ao período base de comparação, este *ex-ante* ao evento. Desta forma, se a razão das volatilidades condicionais médias supera a unidade, conclui-se por mais volatilidade *ex-post*; caso contrário, conclui-se por mitigação de volatilidade. Nesta pesquisa, o término do segundo período seccionado será tomado como médio prazo, enquanto o término do terceiro período será tomado como longo prazo.

Analiticamente:

Seja:

$Vol(t) = \sigma_t^2$ a volatilidade condicional em “t”

Define-se:

$Vol^*(\kappa_i)$ como a volatilidade condicional média do período “ κ_i ”, sendo $i = 1, 2, 3$.

Onde:

$\kappa_1 \Rightarrow$ Período de 24 meses imediatamente anterior ao corte¹⁷ (período base)

$\kappa_2 \Rightarrow$ Período de 24 meses imediatamente posterior ao corte (médio prazo)

$\kappa_3 \Rightarrow$ Período de 24 meses imediatamente posterior ao término de κ_2 (longo prazo)

¹⁶ O termo “evento” usado nesta pesquisa deve ser entendido como a primeira concessão de GI à economia.

¹⁷ Lembrando que o corte usado nesta pesquisa refere-se à ocorrência do evento “primeira concessão de GI à Economia.

Define-se:

$I(\kappa_i, \kappa_1) = \frac{Vol^*(\kappa_i)}{Vol^*(\kappa_1)}$ que permite comparação - de médio e longo prazo - entre a volatilidade média condicional *ex-post* e *ex-ante* ao corte.

Caso $I(\kappa_i, \kappa_1) > 1$, com $i \neq 1 \Rightarrow$ Volatilidade média condicional *ex-post* supera a volatilidade média condicional *ex-ante*. Caso $I(\kappa_i, \kappa_0) < 1$ a volatilidade média condicional *ex-ante* supera a volatilidade condicional média *ex-post*; havendo, portanto, mitigação de volatilidade.

5.1 México

Inicialmente é interessante visualizar o gráfico da série de volatilidade condicional - obtida do modelo AR(1) – TARCH(1,1) - tal a buscar intuição gráfica da evolução da volatilidade dos retornos do índice Mexbol. A barra marcada no gráfico corresponde à data tomada como corte que corresponde à primeira concessão de GI para o México.

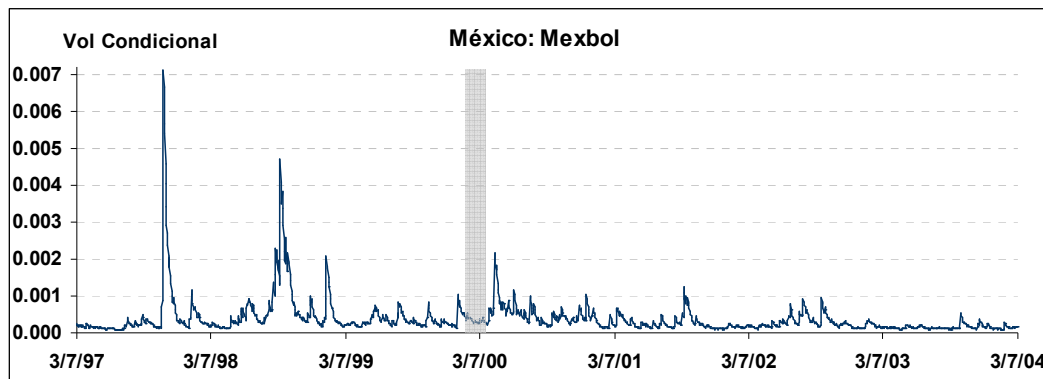


Figura 21 – Gráfico da volatilidade condicional do retorno do índice Mexbol obtida do modelo AR(1)-TARCH(1,1).

O gráfico acima sugere mitigação de volatilidade tanto no médio como no longo prazo, sendo a mitigação gradual iniciada no médio prazo e intensificada no longo prazo.

Comparando a volatilidade condicional média de médio e longo prazo em relação ao período base:

$$I(\kappa_2, \kappa_1) = \frac{Vol^*(\kappa_2)}{Vol^*(\kappa_1)} = \frac{0.00036631}{0.000507931} = 0.721179154$$

$$I(\kappa_3, \kappa_1) = \frac{Vol^*(\kappa_3)}{Vol^*(\kappa_1)} = \frac{0.00021543}{0.000507931} = 0.424132117$$

A intuição gráfica é confirmada. No médio prazo, a volatilidade cai em mais de 27%. Tal movimento de mitigação se intensifica no longo prazo, com queda de mais de 55% da volatilidade média. Isto confirma a hipótese levantada nesta pesquisa, de que a concessão de GI a uma economia emergente tem como consequência a mitigação de volatilidade em bolsa de valores no médio e longo prazo.

5.2 Chile

Abaixo é visualizado o gráfico da série de volatilidade condicional - obtida do modelo AR(1) – TARCH(1,1) - tal a buscar intuição gráfica da evolução da volatilidade dos retornos do índice IPSA no período considerado. A barra marcada no gráfico corresponde à data tomada como corte que indica a primeira concessão de GI para o Chile.

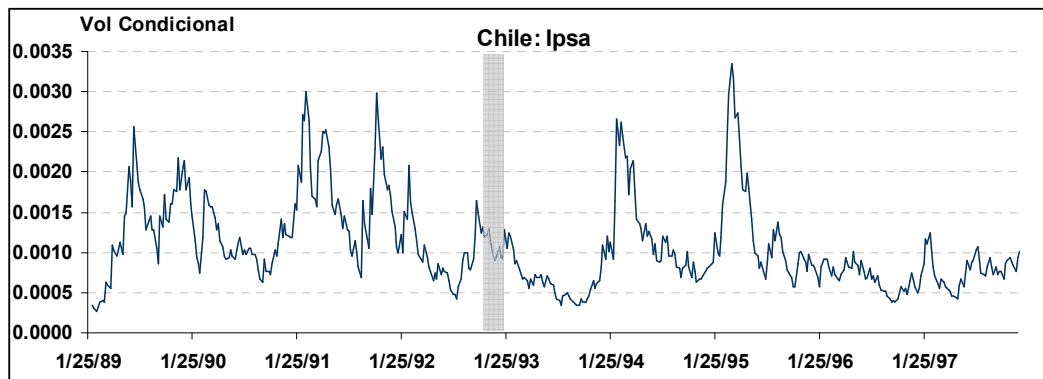


Figura 22 – Gráfico da volatilidade condicional do retorno do índice Ipsa obtida do modelo AR(1)-TARCH(1,1).

Apesar de haver dois picos de volatilidade após o corte, o gráfico sugere que houve mitigação de volatilidade *ex-post* tanto no médio como no longo prazo.

Comparando a volatilidade condicional média de médio e longo prazo em relação ao período base:

$$I(\kappa_2, \kappa_1) = \frac{Vol^*(\kappa_2)}{Vol^*(\kappa_1)} = \frac{0.00013265}{0.00021709} = 0.61102445$$

$$I(\kappa_3, \kappa_1) = \frac{Vol^*(\kappa_3)}{Vol^*(\kappa_1)} = \frac{0.00017712}{0.00021709} = 0.81588734$$

A intuição gráfica é confirmada. No médio prazo a volatilidade média cai em mais de 38%. No longo prazo também houve mitigação de volatilidade, com queda aproximada de 18% na comparação com o período base. Assim como no caso mexicano, é confirmada a

hipótese levantada de que a concessão de GI a economias emergentes tem como consequência a mitigação de volatilidade em bolsa de valores, tanto no médio como no longo prazo.

5.3 Índia

Abaixo é visualizado o gráfico da série de volatilidade condicional - obtida do modelo AR(1) – TARCH(1,1) - tal a buscar intuição gráfica da evolução da volatilidade dos retornos do índice BSE Sensex no período considerado. A barra marcada no gráfico corresponde à data tomada como corte que indica a primeira concessão de GI para a Índia.




Figura 23 – Gráfico da volatilidade condicional do retorno do índice BSE Sensex obtida do modelo AR(1)-TARCH(1,1).

A percepção gráfica é a de que a volatilidade em bolsa apresentou uma queda inicial no médio prazo, mas na sequência apresentou forte elevação de volatilidade no longo prazo; contrariando, em parte, a hipótese de que a concessão de GI teria efeito de mitigação da volatilidade tanto no médio como no longo prazo.

Comparando a volatilidade condicional média de médio e longo prazo em relação ao período base:

$$I(\kappa_2, \kappa_1) = \frac{Vol^*(\kappa_2)}{Vol^*(\kappa_1)} = \frac{0.000282287}{0.000353662} = 0.798182548$$

$$I(\kappa_3, \kappa_1) = \frac{Vol^*(\kappa_3)}{Vol^*(\kappa_1)} = \frac{0.000557837}{0.000353662} = 1.577316363$$

A intuição gráfica é confirmada. No médio prazo a volatilidade média sofre mitigação com uma queda aproximada de 20% em relação ao período base. Já no longo prazo, no entanto, o movimento de mitigação de volatilidade observado no médio prazo foi revertido em uma elevação de volatilidade, com a alta aproximada de 57% da volatilidade média. Desta forma, a hipótese levantada nesta pesquisa de que a concessão de GI a economias emergentes tem como consequência a mitigação, tanto no médio como no longo prazo, da volatilidade em bolsa só foi confirmada parcialmente no caso da Índia, já que só foi observado mitigação de volatilidade no médio prazo.

5.4 Rússia

Abaixo é visualizado o gráfico da série de volatilidade condicional - obtida do modelo AR(1) – GARCH(1,1) - selecionado tal a buscar intuição gráfica da evolução da volatilidade dos retornos do índice RTS no período considerado. A barra marcada no gráfico corresponde à data tomada como corte que indica a primeira concessão de GI à Rússia.



Figura 24 – Gráfico da volatilidade condicional do retorno do índice RTS obtida do modelo AR(1)-GARCH(1,1).

A intuição gráfica mostra que a volatilidade *ex-ante* e *ex-post* continua no mesmo patamar tanto no médio como no longo prazo, o que sugere neutralidade da ocorrência do evento de concessão de GI sobre a volatilidade *ex-post*.

Comparando a volatilidade condicional média de médio e longo prazo em relação ao período base:

$$I(\kappa_2, \kappa_1) = \frac{Vol^*(\kappa_2)}{Vol^*(\kappa_1)} = \frac{0.000390013}{0.000402441} = 0.9691177$$

$$I(\kappa_3, \kappa_1) = \frac{Vol^*(\kappa_3)}{Vol^*(\kappa_1)} = \frac{0.000388801}{0.000402441} = 0.9661077$$

A volatilidade média *ex-post* teve leve mitigação de aproximadamente 3% tanto no médio como no longo prazo, confirmando a intuição gráfica. Logo, assim como no caso do México e do Chile, foi confirmada a hipótese básica levantada nesta pesquisa.

5.5 Coréia do Sul

Abaixo é visualizado o gráfico da série de volatilidade condicional - obtida do modelo AR(1) – GARCH(1,1) - tal a buscar intuição gráfica da evolução da volatilidade dos retornos do índice KOSPI no período considerado. A barra marcada no gráfico corresponde à data tomada como corte que indica a primeira concessão de GI à Coréia do Sul.

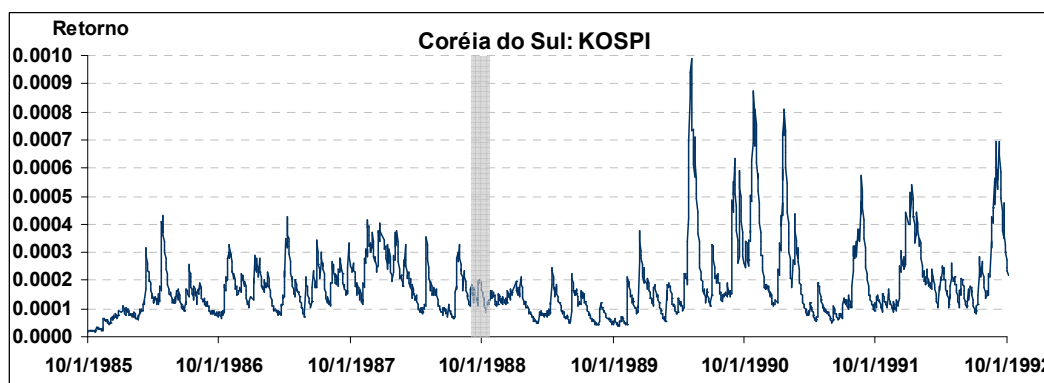


Figura 25 – Gráfico da volatilidade condicional do retorno do índice KOSPI obtida do modelo AR(1)-GARCH(1,1).

A intuição gráfica sugere que no médio prazo houve mitigação de volatilidade, e que no longo prazo tal movimento se reverteu em aumento da volatilidade média.

Comparando a volatilidade condicional média de médio e longo prazo em relação ao período base:

$$I(\kappa_2, \kappa_1) = \frac{Vol^*(\kappa_2)}{Vol^*(\kappa_1)} = \frac{0.000162291}{0.000193235} = 0.839867676$$

$$I(\kappa_3, \kappa_1) = \frac{Vol^*(\kappa_3)}{Vol^*(\kappa_1)} = \frac{0.000234597}{0.000193235} = 1.214055184$$

No médio prazo houve mitigação da volatilidade média superior a 15% em relação ao período base. No longo prazo, porém, foi observado aumento de aproximadamente 21% da volatilidade. Desta forma, assim como no caso da Índia, a hipótese levantada nesta pesquisa só foi confirmada parcialmente, já que somente houve mitigação de volatilidade em bolsa de valores no médio prazo.

Com a comparação feita entre volatilidade *ex-post* e *ex-ante* neste capítulo, foi possível verificar se a hipótese básica desta pesquisa tem evidência empírica confirmatória ou não. Nos casos do México, do Chile e da Rússia a hipótese levantada foi confirmada, tendo sido observado mitigação de volatilidade em bolsa tanto no médio como no longo prazo. Nos casos da Coreia do Sul e da Índia, por outro lado, a hipótese só foi parcialmente confirmada, tendo sido observado mitigação de volatilidade somente no médio prazo, movimento revertido em elevação de volatilidade no longo prazo. Um fato interessante de frisar é que para aquelas economias que tiveram consistência no seu histórico de *rating* – México, Chile e Rússia – a hipótese básica desta pesquisa foi confirmada. Já para os países que perderam o status de GI após a primeira elevação de *rating* – Índia e Coreia do Sul – a hipótese só foi confirmada parcialmente, tendo ocorrido reversão do movimento de mitigação de volatilidade observado no médio prazo para uma elevação de volatilidade no longo prazo.

6 CONCLUSÃO

O objetivo desta pesquisa foi o de avaliar se a concessão de Grau de Investimento (GI) a economias emergentes tem algum efeito de mitigação da volatilidade em bolsa de valores, no médio e longo prazo. É intuitivo pensar que a concessão de GI a economias provoque redução da percepção de risco de investidores em relação ao país premiado, o que atrai mais capital de longo prazo para investimento – este mais estável por natureza - tendo como consequência a estabilização do fluxo de investimento em bolsa de valores e, portanto, mitigação de volatilidade.

Para testar a hipótese descrita foi modelada a volatilidade dos principais índices de bolsa de valores de uma amostra, representativa, de cinco economias emergentes que tiveram suas dívidas soberanas elevadas a Grau de Investimento no passado. A modelagem usada consistiu em modelos da família GARCH. Dentre os modelos tradicionais, o TARARCH e o EGARCH são bastante flexíveis, resolvendo problemas como a falta de sensibilidade para capturar movimentos assimétricos de volatilidade, vistos em modelos GARCH e ARCH; ou mesmo resolvendo o problema da falta de parcimônia dos modelos ARCH.

Como critérios para a escolha dos modelos foram utilizados, além da significância estatística dos parâmetros, os critérios de informação de Akaike e Schwarz. Para modelar a média dos retornos, foram utilizadas as funções de auto-correlação e auto-correlação parcial que sugerem um processo AR(1) para todos os casos. De fato o processo é confirmado, uma vez que os resíduos padronizados em nível e elevados ao quadrado deixam de exibir auto-correlação ao longo das defasagens, após a imposição da estrutura auto-regressiva, garantindo boa especificação dos modelos.

Antes de modelar efetivamente as séries amostradas, foram examinadas algumas características estatísticas importantes de cada uma das cinco séries de retornos dos índices. Foi analisado o histograma; a função de densidade Kernel; o teste Jarque-Bera de normalidade; o gráfico QQ-normal dos retornos padronizados; os coeficientes de curtose e assimetria; e, por fim, o teste da existência do efeito ARCH.

Em todas as séries de retornos foram observados os seguintes pontos em comum: o teste Jarque-Bera rejeitou a hipótese nula de normalidade da distribuição que deu origem aos dados; a medida de curtose, superior a 3, confirmou o teste anterior indicando a existência de distribuição de probabilidade mais afunilada – concentrada - que a normal, caracterizando uma distribuição leptocúrtica que tem como característica caldas pesadas, sendo mais

provável a ocorrência *outliers*. O gráfico QQ-normal dos retornos padronizados deslocado da reta suporte de 45° também sugere não-normalidade das distribuições. E, por fim, o teste da existência do efeito ARCH rejeitou a hipótese nula de inexistência do efeito nos resíduos obtidos das séries de retornos, indicando ser conveniente modelar a volatilidade dos resíduos. Tais resultados confirmaram fatos estilizados verificados empiricamente para séries financeiras.

Após a consideração dos pontos descritos no parágrafo anterior, foram feitas as modelagens das séries amostradas. Para os casos do México, Chile e Índia o modelo selecionado foi um AR(1)-TARCH(1,1), mostrando forte significância estatística dos parâmetros estimados a 2% de significância. Em ambos os casos o efeito ARCH observado antes da modelagem foi suprimido com a aplicação dos modelos, ou seja, não foi possível rejeitar a hipótese nula de inexistência de efeito ARCH nas séries de resíduos obtidos dos modelos TARCH(1,1), indicando boa especificação dos mesmos. Vale salientar que a restrição de não-negatividade dos parâmetros foi atendida nos modelos estimados.

Para os casos da Rússia e da Coréia do Sul o modelo selecionado foi um AR(1) – GARCH(1,1), que, assim como nos casos anteriores, mostrou forte significância estatística além de eliminar o efeito ARCH dos resíduos. Aqui também os dois modelos estimados atenderam à restrição de não-negatividade dos parâmetros.

Uma vez modelados os retornos dos índices, foi possível gerar a volatilidade condicional dos retornos para cada série e, portanto, avaliar de forma robusta a evolução da volatilidade dos retornos. Para comparar a volatilidade condicional após a concessão do GI, foram seccionados três períodos como indicado no capítulo 5: um período base de comparação, e dois períodos representativos do médio e longo prazo.

Na comparação feita entre a volatilidade condicional média do período base – volatilidade *ex-ante* – e a volatilidade condicional média de médio e longo prazo, foi encontrado um padrão de comportamento em todas as cinco economias, confirmando em parte a hipótese básica desta pesquisa. Para os cinco países estudados, houve mitigação de volatilidade no médio prazo. Para o México a redução da volatilidade foi de aproximadamente 27%; para o Chile de 38%; para a Índia de 20%; para a Rússia de 3% e para a Coréia do sul de 16%. Ou seja, houve mitigação de dois dígitos da volatilidade em bolsa, no médio prazo, para as economias - com exceção da Rússia onde a mitigação observada foi apenas de um dígito.

No longo prazo, no entanto, somente três dos cinco países emergentes apresentaram persistência de mitigação da volatilidade em bolsa, quais sejam: o México, com aproximadamente 57% de mitigação de volatilidade; o Chile com 18% e a Rússia com 3%. Já

para a Índia e a Coréia do Sul houve reversão do movimento de redução de volatilidade, observado no médio prazo, para um aumento no longo prazo. A Índia apresentou elevação média de volatilidade aproximadamente de 57%, enquanto a Coréia apresentou elevação de 21% no longo prazo; contrariando, parcialmente, a hipótese levantada.

É interessante relembrar o histórico de *rating* da dívida soberana de longo prazo em moeda estrangeira das cinco economias estudadas. O México tem o seu primeiro registro de Grau de Investimento em 2000 concedido pela Moody's. Após tal registro a Moody's manteve progressividade na sua avaliação de risco de crédito soberano, apresentando mais duas elevações de *rating* após 2000. A Standard & Poor's (S&P) e a Fitch também mantiveram progressividade em suas avaliações de *rating* para o México após a concessão de GI, dando mais duas elevações de nota sequencialmente.

O Chile possui a nota Grau de Investimento em todo o histórico de *rating* das três agências de avaliação de risco. A primeira agência a avaliar a dívida soberana do Chile em GI foi a S&P em 1992. Todas as três agências mantiveram progressividade nas suas avaliações, com sucessivas elevações de *rating*.

Para a Índia foi a Moody's a primeira agência a conceder GI em 1988; no entanto, não houve consistência na sua avaliação tendo sido observado uma sucessão de elevações e rebaixamentos, inclusive com a retirada do status de GI. Já a S&P e a Fitch só foram conceder a nota GI para a Índia recentemente. Até meados dos anos 2000 ambas mantinham avaliação de Grau Especulativo.

A Rússia foi elevada a GI pela primeira vez em 2003 pela Moody's, que manteve consistência na sua avaliação com uma sequência de mais quatro elevações de nota. A S&P e a Fitch fizeram uma sucessão de rebaixamentos e elevações de nota, após a primeira concessão de GI, mas mantendo sempre o status de GI até o último registro.

A Coréia do Sul, por sua vez, ganhou a nota de GI em 1988 com a avaliação feita pela S&P. No entanto, não houve consistência na avaliação e tanto a S&P como a Fitch deram rebaixamento de nota após a elevação a GI, inclusive com a retirada do status de país seguro para investimento. A Moody's foi a única entre as três agências a manter consistência na avaliação apresentando sucessivas elevações de nota.

A evidência empírica permitiu confirmar, em parte, a hipótese de que a concessão de GI a economias emergentes tem como consequência mitigação de volatilidade em bolsa de valores, tanto no médio como no longo prazo. Como vimos, todas as cinco economias apresentaram mitigação de volatilidade no médio prazo, após o primeiro registro de GI, como esperado. No entanto, o mesmo não pôde ser dito para o período considerado como longo

prazo. Houve um misto de resultados, tendo sido observado persistência de mitigação de volatilidade no longo prazo apenas para os casos do México, Chile e Rússia. Para a Índia e a Coreia do Sul, no entanto, o movimento de redução de volatilidade, observado no médio prazo, sofreu reversão ao apresentar elevação no longo prazo. Um fato que chama a atenção é que tanto a Índia como a Coreia do Sul não apresentaram consistência nos seus históricos de *rating*, tendo ocorrido rebaixamentos de notas com a perda do status de GI ao longo do tempo. Já nas economias que tiveram um histórico de *rating* consistente, com a manutenção do status de GI até o último registro de nota – México, Chile e Rússia – houve mitigação de volatilidade tanto no médio como no longo prazo.

Fica como sugestão para pesquisas futuras a investigação do efeito da inconsistência da avaliação de notas, de agências de *rating*, sobre a volatilidade em bolsa de valores de economias emergentes.

Por fim, um prognóstico possível para a economia brasileira, que recentemente foi elevada a Grau de Investimento, é que no médio prazo¹⁸ pode-se esperar que a volatilidade média do Ibovespa sofra significativa mitigação. Como o final de 2008 e início de 2009 foi um período de elevada volatilidade do Ibovespa, como consequência do efeito contágio da crise financeira global, a evidência empírica sugere que, ao longo dos próximos meses até pelo menos o primeiro semestre de 2010, haverá forte mitigação de volatilidade em bolsa no Brasil. Somado a isso o fato de que valorizações prolongadas de índices de bolsas ocorrem acompanhadas de períodos de baixa volatilidade, é possível inferir que o Ibovespa manterá consistência da valorização observada no início de 2009 até, pelo mesmo, o primeiro semestre de 2010 - podendo ser prolongada por mais dois anos caso não haja rebaixamento de nota da dívida soberana doméstica.

¹⁸ Tomando como referência – corte - o mês de abril de 2008, mês em que o Brasil recebe o seu primeiro registro de GI.

6 REFERÊNCIAS

BALL, C. A. and TOROUS, W. N. **Stochastic Correlations Across International Stock Markets**. *Journal of Empirical Finance*, 7, 373 – 388, 2000.

BHEENICK, E. B. **Rating timing differences between the two leading agencies: Standard and Poor's and Moody's**, *Emerging Markets Review*, 5, pp. 361-378, 2004.

BOLLERSLEV, Tim; CHOU, Ray and KRONER, Keneth. **ARCH Modeling in Finance: a Review of the Theory and Empirical Evidence**. *Journal of Econometrics*, 52, p.5-59, 1992.

BROOKS, Chris. **Introductory Econometrics for Finance**. Cambridge: CAMBRIDGE, 2002.

CANUTO, Otaviano e SANTOS, Pablo Fonseca. **Risco-Soberano e Prêmio de Risco em Economias Emergentes**. Ministério da Fazenda – Secretaria de Assuntos Internacionais: Brasília, 2003.

CASELLA, George and BERGER, Roger L. **Statistical Inference**. 2 ed, Duxbury: USA, 2002.

CASTRO, Nivalde J. e BRANDÃO, Roberto. **Investment Grade: Impactos na Economia Brasileira e no Setor Elétrico Brasileiro**. Grupo de Estudos do Setor Elétrico, 2008.

CHRISTOFI, A. and PERICLI, A. **Correlation in Price Changes and Volatility of Major Latin America Stock Markets**. *Journal of Multinational Finance Management*, 9, 79 – 93, 1999.

ENDERS, W. **Applied Econometric Time Series**. John Wiley & Sons, Inc. 2nd Ed: EUA, 1995.

ENGLE, R. F.; NG, VICTOR K. **Measuring and Testing the Impact of News on Volatility**. *Journal of Finance*, n.48(5), p. 1749-78, 1993.

FAN, J. and YAO, Q. **Nonlinear Time Series Modelling and Prediction**. New York: Springer-Verlag, 2002.

FULOP, Andras. **Feedback effects of rating downgrades**. ESSEC Working paper, 2006.
GLASCOCK, J.L.; DAVIDSON, W.N.; HENDERSON, G.V. **Announcement effects of Moody's bond rating changes of equity returns**. Quarterly Journal of Business & Economics, Vol. 26, 67-78, 1987.

HAMILTON, J.D. **Time Series Analysis**. Princeton University Press, 1994.

HAND, J.R.M.; HOLTHAUSEN, R.W.; LEFTWICH, R.W. **The effect of Bond Rating Agency Announcements on Bond and Stock Prices**. The Journal of Finance, Vol.47, nº 2, 733-52, 1992.

HARVEY, A. C. **Forecasting structural time series models and the Kalman filter**. Cambridge University Press, 1989.

KIM, SUK-JOONG, WU, E. **Sovereign credit ratings, capital flows and financial sector development in emerging markets**. Emerging Markets Review, 9, 17-39, 2008.

LOPES, Daniel. C. **Análise quantitativa da volatilidade entre os índices Dow Jones, Ibovespa e S&P500**. UFRGS: Dissertação; Faculdade de Ciências Econômicas, Universidade Federal do Rio Grande Do Sul, Porto Alegre, 2006.

MORAIS, Igor A. e PORTUGAL, Marcelo S. **Modelagem e previsão de volatilidade determinística e estocástica para a série do Ibovespa**. Est. Econ, V. 29, N. 3, 303 – 341, 1999.

_____. **Investment Grade and Uncertainty in the Stock Market: an Analysis for Chile, México, South África, Rússia and india**: Publicado em 2009. Disponível em: <http://virtualbib.fgv.br/ocs/index.php/ebf/9EBF/paper/viewFile/615/108>; Acesso em: 13/09/2009.

MORETTIN, A. Pedro. **Econometria Financeira. Um curso em séries temporais financeiras**. Instituto de Matemática e Estatística da USP: São Paulo, 2006.

NELSON, D. B. **Conditional Heteroscedasticity in Asset Returns: a new approach**. Econométrica, 59, p.347-370, 1991.

POLWITTOON, Sirapat; TAWATNUNTACHAI, Oranee. **Emerging Market Bond Funds: A Comprehensive Analysis**. The Financial Review 43, 51-84, 2008.

POON, Ser-Huang and GRANGER, Clive. **Forecasting Volatility In Financial Markets: A Review**. Journal of Economic Literature, Vol. 41, No 2, 478 – 539, 2003.

RIBEIRO, Bruno P. S. **Modelagem e previsão de volatilidade para o setor siderúrgico brasileiro: volatilidade estocástica versus determinística**. UFRGS: Dissertação; Faculdade de Ciências Econômicas, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2009.

RIGOBON, Roberto. **The Curse of Non-Investment Grade Countries**. Sloan School of Management, MIT and NBER, 2002.

SECURATO, José Roberto. **Cálculo Financeiro das Tesourarias. Bancos e Empresas**. 4a Ed, São Paulo: Saint-Paul Editora, 2008.

SIMON, Carl P. and BLUME, Lawrence. **Matemática para Economistas**. Bookman: São Porto Alegre, 2004.

TAYLOR, Stephen J. **Asset Price Dynamics, Volatility, and Prediction**. Princeton: London, 2007.

TSAY, R. S. **Analysis of Financial Time Series**. 1a Ed, EUA: John Wiley & Sons Inc, 2002
URIBE, Martin; YUE, Vivian Z. **Country Spreads and Emerging Countries: Who drives whom?** Published at 2004. Available at:
www.frbsf.org/publications/economics/papers/2004/wp04-32bk.pdf. Access date: 09/2009

ZIEGELMANN, Flávio Augusto. **Estimation of Volatility Functions: Non-parametric and Semi-Parametric Methods**. 2002. 191p. Thesis submitted to the University of Kent of Canterbury for The Degree of Doctor in the Subject of Statistics.

ZIEGELMANN, F. A., PEREIRA, P. L. V. **Modelos de volatilidade estocástica com deformação temporal: um estudo empírico para o índice Ibovespa**. P.P.E, v.27, n.2, p.353-376, 1997.

ANEXO A

Correlograma dos resíduos padronizados obtidos da série de retornos do índice Mexbol com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.035	0.035	6.3347	
		2	-0.011	-0.012	6.9403	0.008
		3	0.005	0.006	7.0640	0.029
		4	0.014	0.014	8.1120	0.044
		5	0.017	0.016	9.5551	0.049
		6	0.001	-0.000	9.5567	0.089
		7	0.010	0.011	10.115	0.120
		8	0.001	0.000	10.123	0.182
		9	0.001	0.001	10.127	0.256
		10	0.036	0.035	16.763	0.053
		11	0.009	0.006	17.178	0.071
		12	0.010	0.010	17.656	0.090
		13	0.021	0.020	20.008	0.067
		14	0.026	0.023	23.471	0.036
		15	0.023	0.021	26.262	0.024
		16	0.013	0.011	27.104	0.028
		17	0.015	0.013	28.350	0.029
		18	-0.019	-0.022	30.277	0.024
		19	-0.014	-0.014	31.272	0.027
		20	0.034	0.032	37.289	0.007
		21	-0.004	-0.008	37.373	0.011
		22	0.004	0.005	37.473	0.015
		23	0.003	0.001	37.508	0.021
		24	0.014	0.011	38.540	0.022
		25	-0.015	-0.019	39.780	0.023
		26	-0.018	-0.018	41.396	0.021
		27	0.019	0.017	43.377	0.018
		28	0.007	0.004	43.617	0.023
		29	-0.013	-0.014	44.511	0.025
		30	0.011	0.010	45.146	0.028
		31	0.014	0.013	46.249	0.029
		32	0.006	0.005	46.424	0.037
		33	0.022	0.023	49.069	0.027
		34	-0.001	-0.004	49.072	0.036
		35	-0.013	-0.012	49.925	0.038
		36	-0.005	-0.004	50.067	0.047

Correlograma dos resíduos padronizados ao quadrado obtidos da série de retornos do índice Mexbol com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.007	0.007	0.2800	
		2	0.017	0.017	1.7228	0.189
		3	0.009	0.008	2.1178	0.347
		4	-0.020	-0.021	4.2554	0.235
		5	-0.000	-0.000	4.2557	0.373
		6	-0.020	-0.019	6.2461	0.283
		7	-0.026	-0.026	9.8597	0.131
		8	-0.018	-0.018	11.600	0.115
		9	-0.022	-0.021	14.214	0.076
		10	0.004	0.004	14.286	0.113
		11	-0.023	-0.023	16.937	0.076
		12	0.003	0.003	16.989	0.108
		13	-0.006	-0.007	17.161	0.144
		14	0.015	0.014	18.298	0.147
		15	0.002	-0.001	18.312	0.193
		16	-0.008	-0.010	18.644	0.230
		17	-0.012	-0.014	19.356	0.251
		18	-0.009	-0.009	19.763	0.287
		19	-0.006	-0.006	19.941	0.336
		20	0.003	0.002	19.988	0.395
		21	0.007	0.007	20.219	0.444
		22	0.019	0.018	22.165	0.390
		23	-0.003	-0.004	22.217	0.447
		24	0.006	0.004	22.437	0.494
		25	0.003	0.003	22.500	0.549
		26	-0.008	-0.008	22.820	0.588
		27	0.010	0.010	23.380	0.611
		28	0.023	0.024	26.214	0.507
		29	0.007	0.007	26.440	0.549
		30	0.004	0.004	26.541	0.596
		31	0.011	0.012	27.148	0.615
		32	0.024	0.025	30.103	0.512
		33	0.011	0.012	30.736	0.530
		34	-0.013	-0.013	31.616	0.536
		35	-0.002	-0.001	31.647	0.583
		36	0.028	0.031	35.752	0.433

ANEXO B

Resultado da estimação do modelo TAR(1,1) aplicado aos resíduos obtidos da série de retornos do índice Mexbol.

Dependent Variable: LNMEXICO
 Method: ML - ARCH (Marquardt) - Student's t distribution
 Date: 03/26/09 Time: 16:49
 Sample (adjusted): 3 5218
 Included observations: 5216 after adjustments
 Convergence achieved after 14 iterations
 Variance backcast: ON
 GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0)
 + C(6)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000896	0.000217	4.128136	0.0000
AR(1)	0.150110	0.013985	10.73368	0.0000
Variance Equation				
C	1.13E-05	1.45E-06	7.757999	0.0000
RESID(-1)^2	0.035697	0.010456	3.413997	0.0006
RESID(-1)^2*(RESID(-1)<0)	0.168941	0.018484	9.139637	0.0000
GARCH(-1)	0.845840	0.012375	68.35201	0.0000
T-DIST. DOF	6.327304	0.557474	11.34995	0.0000
R-squared	0.005245	Mean dependent var		0.000552
Adjusted R-squared	0.004099	S.D. dependent var		0.019708
S.E. of regression	0.019668	Akaike info criterion		-5.519199
Sum squared resid	2.014939	Schwarz criterion		-5.510396
Log likelihood	14401.07	F-statistic		4.577384
Durbin-Watson stat	2.101489	Prob(F-statistic)		0.000122
Inverted AR Roots	.15			

ANEXO C

Correlograma dos resíduos padronizados obtidos da série de retornos do índice IPISA com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.028	0.028	3.8004	
		2	-0.014	-0.014	4.7184	0.030
		3	0.006	0.007	4.8858	0.087
		4	0.032	0.032	10.057	0.018
		5	0.034	0.032	15.794	0.003
		6	0.011	0.010	16.385	0.006
		7	-0.011	-0.011	16.957	0.009
		8	0.003	0.003	17.007	0.017
		9	0.034	0.032	22.896	0.004
		10	0.009	0.006	23.344	0.005
		11	0.015	0.016	24.534	0.006
		12	0.004	0.003	24.598	0.010
		13	0.016	0.014	25.878	0.011
		14	0.021	0.018	28.127	0.009
		15	0.047	0.044	39.081	0.000
		16	0.002	-0.000	39.111	0.001
		17	-0.021	-0.022	41.394	0.000
		18	0.006	0.003	41.548	0.001
		19	0.004	-0.001	41.642	0.001
		20	0.007	0.004	41.911	0.002
		21	0.029	0.030	46.218	0.001
		22	0.004	0.003	46.300	0.001
		23	0.021	0.020	48.457	0.001
		24	-0.017	-0.023	49.909	0.001
		25	-0.000	-0.002	49.910	0.001
		26	-0.016	-0.019	51.143	0.002
		27	-0.003	-0.004	51.180	0.002
		28	-0.007	-0.008	51.413	0.003
		29	0.007	0.007	51.690	0.004
		30	-0.004	-0.006	51.777	0.006
		31	0.012	0.013	52.502	0.007
		32	0.003	0.002	52.540	0.009
		33	-0.001	-0.001	52.547	0.012
		34	0.015	0.013	53.686	0.013
		35	-0.021	-0.022	55.795	0.011
		36	-0.015	-0.017	56.960	0.011

Correlograma dos resíduos padronizados elevados ao quadrado obtidos da série de retornos do índice IPSA com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.006	0.006	0.1513	
		2	0.013	0.013	1.0414	0.307
		3	-0.012	-0.012	1.7147	0.424
		4	-0.016	-0.016	2.9969	0.392
		5	0.009	0.010	3.4421	0.487
		6	-0.019	-0.019	5.2082	0.391
		7	-0.014	-0.014	6.1375	0.408
		8	0.004	0.005	6.2325	0.513
		9	0.010	0.011	6.7661	0.562
		10	0.006	0.005	6.9508	0.642
		11	0.010	0.010	7.4547	0.682
		12	-0.004	-0.004	7.5427	0.754
		13	-0.020	-0.021	9.6388	0.648
		14	-0.009	-0.008	10.032	0.691
		15	0.014	0.016	11.043	0.683
		16	-0.019	-0.020	12.932	0.608
		17	-0.008	-0.008	13.245	0.655
		18	0.016	0.017	14.532	0.629
		19	-0.013	-0.014	15.407	0.634
		20	0.001	-0.002	15.411	0.696
		21	0.018	0.020	17.123	0.645
		22	0.012	0.013	17.893	0.656
		23	-0.008	-0.011	18.251	0.691
		24	0.001	0.002	18.257	0.743
		25	-0.019	-0.018	20.067	0.693
		26	0.021	0.020	22.327	0.617
		27	-0.006	-0.006	22.516	0.660
		28	0.002	0.003	22.544	0.709
		29	0.010	0.009	23.020	0.732
		30	-0.007	-0.008	23.286	0.763
		31	0.005	0.004	23.394	0.799
		32	-0.018	-0.018	25.061	0.765
		33	0.028	0.027	28.928	0.623
		34	-0.001	0.001	28.935	0.670
		35	0.011	0.011	29.597	0.683
		36	0.016	0.015	30.896	0.667

ANEXO D

Resultado da estimação do modelo TAR(1,1) aplicado aos resíduos obtidos da série de retornos do índice Ipsi.

Dependent Variable: LNCHILE
Method: ML - ARCH (Marquardt) - Student's t distribution
Date: 03/30/09 Time: 16:43
Sample (adjusted): 3 4984
Included observations: 4982 after adjustments
Convergence achieved after 12 iterations
Variance backcast: ON
GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0)
+ C(6)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000590	0.000202	2.925642	0.0034
AR(1)	0.236710	0.014146	16.73377	0.0000
Variance Equation				
C	7.95E-06	1.22E-06	6.520386	0.0000
RESID(-1)^2	0.107452	0.015127	7.103533	0.0000
RESID(-1)^2*(RESID(-1)<0)	0.079542	0.019323	4.116363	0.0000
GARCH(-1)	0.809816	0.016148	50.15066	0.0000
T-DIST. DOF	9.814853	1.190904	8.241516	0.0000
R-squared	0.043608	Mean dependent var		0.000585
Adjusted R-squared	0.042455	S.D. dependent var		0.014031
S.E. of regression	0.013729	Akaike info criterion		-6.023956
Sum squared resid	0.937776	Schwarz criterion		-6.014804
Log likelihood	15012.67	F-statistic		37.80704
Durbin-Watson stat	2.040560	Prob(F-statistic)		0.000000
Inverted AR Roots	.24			

ANEXO E

Correlograma dos resíduos padronizados obtidos da série de retornos do índice BSE Sensex 30 com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.008	0.008	0.3122	
		2	-0.014	-0.014	1.4326	0.231
		3	0.015	0.016	2.7387	0.254
		4	0.025	0.025	6.3455	0.096
		5	-0.022	-0.022	9.1104	0.058
		6	-0.028	-0.027	13.410	0.020
		7	0.036	0.035	20.480	0.002
		8	0.021	0.020	23.035	0.002
		9	0.017	0.020	24.664	0.002
		10	0.014	0.014	25.777	0.002
		11	0.006	0.002	25.948	0.004
		12	0.008	0.007	26.292	0.006
		13	0.018	0.019	28.028	0.005
		14	0.002	0.002	28.052	0.009
		15	-0.022	-0.022	30.746	0.006
		16	0.018	0.017	32.548	0.005
		17	0.037	0.034	39.988	0.001
		18	-0.014	-0.013	41.010	0.001
		19	-0.007	-0.005	41.251	0.001
		20	-0.004	-0.009	41.353	0.002
		21	0.004	0.001	41.444	0.003
		22	-0.001	0.002	41.456	0.005
		23	0.005	0.006	41.570	0.007
		24	0.009	0.005	42.014	0.009
		25	0.001	-0.001	42.017	0.013
		26	-0.004	-0.005	42.115	0.017
		27	0.028	0.028	46.454	0.008
		28	-0.005	-0.005	46.577	0.011
		29	-0.029	-0.028	51.247	0.005
		30	-0.007	-0.009	51.531	0.006
		31	-0.007	-0.008	51.786	0.008
		32	0.009	0.012	52.214	0.010
		33	0.002	0.003	52.248	0.013
		34	-0.011	-0.015	52.919	0.015
		35	-0.010	-0.011	53.425	0.018
		36	0.001	0.001	53.432	0.024

Correlograma dos resíduos padronizados ao quadrado obtidos da série de retornos do índice BSE Sensex 30 com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.002	0.002	0.0314	
		2	-0.010	-0.010	0.5407	0.462
		3	-0.005	-0.005	0.6996	0.705
		4	-0.006	-0.006	0.8993	0.826
		5	-0.009	-0.009	1.3271	0.857
		6	-0.009	-0.009	1.7900	0.877
		7	-0.012	-0.012	2.5453	0.863
		8	-0.006	-0.007	2.7685	0.906
		9	-0.012	-0.013	3.6112	0.890
		10	0.020	0.019	5.8031	0.759
		11	0.003	0.002	5.8395	0.829
		12	-0.012	-0.012	6.5788	0.832
		13	-0.006	-0.006	6.7829	0.872
		14	0.024	0.024	10.041	0.691
		15	-0.010	-0.011	10.648	0.713
		16	-0.000	0.000	10.648	0.777
		17	-0.007	-0.007	10.943	0.813
		18	-0.015	-0.015	12.162	0.790
		19	0.009	0.009	12.605	0.814
		20	-0.004	-0.005	12.685	0.854
		21	0.014	0.014	13.733	0.844
		22	0.006	0.006	13.946	0.872
		23	-0.002	-0.001	13.965	0.903
		24	0.009	0.008	14.413	0.914
		25	-0.016	-0.016	15.863	0.893
		26	-0.009	-0.008	16.319	0.905
		27	-0.007	-0.007	16.588	0.921
		28	0.004	0.004	16.659	0.939
		29	0.008	0.008	17.006	0.948
		30	-0.000	-0.001	17.008	0.962
		31	-0.007	-0.007	17.266	0.969
		32	0.006	0.006	17.459	0.976
		33	-0.004	-0.004	17.529	0.982
		34	-0.003	-0.003	17.584	0.987
		35	0.011	0.011	18.297	0.987
		36	-0.008	-0.007	18.629	0.989

ANEXO F

Resultado da estimação do modelo TAR(1,1) aplicado aos resíduos obtidos da série de retornos do BSE Sensex 30.

Dependent Variable: LNINDIA
 Method: ML - ARCH (Marquardt) - Student's t distribution
 Date: 03/31/09 Time: 10:04
 Sample (adjusted): 3 5549
 Included observations: 5547 after adjustments
 Convergence achieved after 13 iterations
 Variance backcast: ON
 GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0)
 + C(6)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000725	0.000220	3.294182	0.0010
AR(1)	0.125789	0.013963	9.008596	0.0000
Variance Equation				
C	1.07E-05	1.71E-06	6.268681	0.0000
RESID(-1)^2	0.090989	0.012803	7.106669	0.0000
RESID(-1)^2*(RESID(-1)<0)	0.077079	0.017927	4.299509	0.0000
GARCH(-1)	0.845062	0.012914	65.43773	0.0000
T-DIST. DOF	6.715666	0.495376	13.55671	0.0000
R-squared	0.005163	Mean dependent var		0.000396
Adjusted R-squared	0.004086	S.D. dependent var		0.019179
S.E. of regression	0.019140	Akaike info criterion		-5.372960
Sum squared resid	2.029531	Schwarz criterion		-5.364604
Log likelihood	14908.90	F-statistic		4.792077
Durbin-Watson stat	2.075553	Prob(F-statistic)		0.000070
Inverted AR Roots	.13			

ANEXO G

Correlograma dos resíduos padronizados obtidos da série de retornos do índice RTS com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.059	0.059	11.590	
		2	0.029	0.025	14.327	0.000
		3	0.014	0.011	14.999	0.001
		4	0.023	0.021	16.801	0.001
		5	0.010	0.007	17.141	0.002
		6	0.024	0.021	19.002	0.002
		7	0.036	0.033	23.401	0.001
		8	0.017	0.012	24.392	0.001
		9	0.038	0.034	29.139	0.000
		10	0.028	0.022	31.714	0.000
		11	-0.018	-0.025	32.792	0.000
		12	0.023	0.022	34.542	0.000
		13	0.028	0.023	37.064	0.000
		14	-0.021	-0.028	38.519	0.000
		15	0.008	0.007	38.728	0.000
		16	-0.008	-0.012	38.944	0.001
		17	-0.016	-0.019	39.849	0.001
		18	-0.002	-0.001	39.866	0.001
		19	-0.005	-0.008	39.956	0.002
		20	0.013	0.014	40.541	0.003
		21	0.009	0.009	40.827	0.004
		22	0.037	0.033	45.311	0.002
		23	-0.008	-0.010	45.551	0.002
		24	-0.009	-0.008	45.833	0.003
		25	0.020	0.020	47.201	0.003
		26	-0.017	-0.018	48.134	0.004
		27	0.010	0.012	48.485	0.005
		28	0.019	0.016	49.648	0.005
		29	0.003	-0.002	49.669	0.007
		30	0.002	0.000	49.681	0.010
		31	0.021	0.018	51.142	0.009
		32	-0.007	-0.011	51.294	0.012
		33	-0.012	-0.011	51.771	0.015
		34	0.005	0.002	51.845	0.020
		35	0.010	0.007	52.200	0.024
		36	0.019	0.021	53.356	0.024

Correlograma dos resíduos padronizados ao quadrado obtidos da série de retornos do índice RTS com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.012	0.012	0.4914	
		2	0.006	0.006	0.5985	0.439
		3	0.033	0.033	4.1893	0.123
		4	-0.012	-0.013	4.6474	0.200
		5	-0.012	-0.012	5.0968	0.278
		6	-0.017	-0.018	6.1051	0.296
		7	-0.020	-0.019	7.4161	0.284
		8	-0.030	-0.029	10.441	0.165
		9	-0.005	-0.003	10.512	0.231
		10	-0.022	-0.021	12.125	0.206
		11	-0.017	-0.015	13.038	0.222
		12	-0.004	-0.005	13.094	0.287
		13	0.000	0.001	13.095	0.362
		14	-0.015	-0.016	13.803	0.388
		15	-0.008	-0.009	13.997	0.450
		16	0.000	-0.002	13.997	0.526
		17	0.009	0.008	14.264	0.579
		18	0.006	0.004	14.392	0.639
		19	-0.020	-0.022	15.794	0.607
		20	-0.008	-0.010	16.016	0.656
		21	-0.001	-0.002	16.019	0.715
		22	-0.006	-0.006	16.137	0.762
		23	-0.009	-0.009	16.387	0.796
		24	-0.014	-0.015	17.058	0.806
		25	-0.018	-0.019	18.141	0.796
		26	0.007	0.007	18.309	0.829
		27	-0.021	-0.022	19.811	0.800
		28	-0.006	-0.006	19.946	0.833
		29	-0.005	-0.008	20.032	0.863
		30	-0.010	-0.011	20.363	0.881
		31	0.020	0.018	21.689	0.865
		32	0.010	0.008	21.996	0.883
		33	-0.001	-0.004	22.000	0.907
		34	0.002	-0.003	22.008	0.927
		35	-0.012	-0.016	22.504	0.934
		36	-0.012	-0.013	23.016	0.940

ANEXO H

Resultado da estimação do modelo GARCH(1,1) aplicado aos resíduos obtidos da série de retornos do RTS.

Dependent Variable: LNRUSSIA
 Method: ML - ARCH (Marquardt) - Student's t distribution
 Date: 04/06/09 Time: 15:14
 Sample (adjusted): 3 3316
 Included observations: 3314 after adjustments
 Convergence achieved after 14 iterations
 Variance backcast: ON
 GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.001986	0.000352	5.636658	0.0000
AR(1)	0.121190	0.017849	6.789752	0.0000
Variance Equation				
C	1.26E-05	2.63E-06	4.811481	0.0000
RESID(-1)^2	0.163293	0.017225	9.480180	0.0000
GARCH(-1)	0.834654	0.014966	55.77093	0.0000
T-DIST. DOF	5.519371	0.535840	10.30042	0.0000
R-squared	0.018992	Mean dependent var		0.000557
Adjusted R-squared	0.017509	S.D. dependent var		0.028716
S.E. of regression	0.028464	Akaike info criterion		-4.786301
Sum squared resid	2.680111	Schwarz criterion		-4.775247
Log likelihood	7936.901	F-statistic		12.80855
Durbin-Watson stat	1.944206	Prob(F-statistic)		0.000000
Inverted AR Roots	.12			

ANEXO I

Correlograma dos resíduos padronizados obtidos da série de retornos do índice KOSPI com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.014	0.014	1.3146	
		2	-0.007	-0.007	1.6297	0.202
		3	0.033	0.033	8.6260	0.013
		4	0.009	0.008	9.1147	0.028
		5	-0.005	-0.005	9.2690	0.055
		6	-0.004	-0.005	9.3870	0.095
		7	-0.010	-0.010	9.9759	0.126
		8	0.015	0.015	11.410	0.122
		9	0.029	0.029	16.931	0.031
		10	0.013	0.013	18.012	0.035
		11	0.022	0.022	21.286	0.019
		12	0.015	0.012	22.753	0.019
		13	0.019	0.018	25.084	0.014
		14	0.018	0.017	27.270	0.011
		15	0.024	0.023	30.967	0.006
		16	0.012	0.011	31.954	0.007
		17	0.041	0.039	42.786	0.000
		18	0.009	0.006	43.271	0.000
		19	0.008	0.007	43.659	0.001
		20	0.000	-0.004	43.659	0.001
		21	-0.006	-0.008	43.893	0.002
		22	-0.009	-0.011	44.430	0.002
		23	0.003	0.001	44.481	0.003
		24	0.007	0.005	44.817	0.004
		25	-0.017	-0.020	46.691	0.004
		26	0.013	0.009	47.848	0.004
		27	0.007	0.002	48.130	0.005
		28	0.005	0.002	48.284	0.007
		29	0.013	0.010	49.438	0.007
		30	-0.019	-0.022	51.789	0.006
		31	0.010	0.009	52.430	0.007
		32	0.013	0.010	53.586	0.007
		33	0.002	0.003	53.621	0.010
		34	0.015	0.015	55.147	0.009
		35	0.002	0.000	55.180	0.012
		36	0.036	0.036	63.621	0.002

Correlograma dos resíduos padronizados ao quadrado obtidos da série de retornos do índice KOSPI com a utilização da estrutura AR(1) para modelar a média dos retornos.

Autocorrelation	Partial Correlation	AC	PAC	Q-Stat	Prob	
		1	0.003	0.003	0.0480	
		2	0.019	0.019	2.3785	0.123
		3	0.016	0.016	4.1096	0.128
		4	-0.003	-0.003	4.1534	0.245
		5	0.022	0.022	7.3661	0.118
		6	0.000	-0.000	7.3663	0.195
		7	-0.025	-0.026	11.364	0.078
		8	-0.005	-0.006	11.558	0.116
		9	-0.021	-0.020	14.552	0.068
		10	0.000	0.001	14.552	0.104
		11	-0.021	-0.020	17.479	0.064
		12	-0.002	-0.000	17.512	0.094
		13	-0.023	-0.022	20.843	0.053
		14	-0.025	-0.024	24.897	0.024
		15	-0.018	-0.018	27.074	0.019
		16	-0.017	-0.016	28.975	0.016
		17	-0.009	-0.008	29.498	0.021
		18	0.006	0.007	29.756	0.028
		19	-0.005	-0.003	29.901	0.038
		20	-0.014	-0.016	31.235	0.038
		21	-0.014	-0.015	32.545	0.038
		22	-0.005	-0.006	32.679	0.050
		23	0.011	0.010	33.544	0.055
		24	-0.020	-0.022	36.167	0.040
		25	-0.016	-0.017	37.867	0.036
		26	0.011	0.011	38.695	0.040
		27	-0.003	-0.004	38.753	0.051
		28	0.007	0.004	39.115	0.062
		29	0.010	0.008	39.794	0.069
		30	0.003	0.002	39.850	0.086
		31	0.002	-0.002	39.872	0.107
		32	-0.003	-0.005	39.924	0.131
		33	-0.012	-0.014	40.938	0.134
		34	-0.003	-0.005	40.996	0.160
		35	-0.024	-0.026	44.906	0.100
		36	0.001	0.001	44.918	0.122

ANEXO J

Resultado da estimação do modelo GARCH(1,1) aplicado aos resíduos obtidos da série de retornos do índice KOSPI.

Dependent Variable: LNCOREIA
 Method: ML - ARCH (Marquardt) - Student's t distribution
 Date: 04/06/09 Time: 16:44
 Sample (adjusted): 3 6517
 Included observations: 6515 after adjustments
 Convergence achieved after 14 iterations
 Variance backcast: ON
 GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*GARCH(-1)

	Coefficient	Std. Error	z-Statistic	Prob.
C	0.000427	0.000155	2.755908	0.0059
AR(1)	0.095871	0.012924	7.418067	0.0000
Variance Equation				
C	1.15E-06	3.19E-07	3.602428	0.0003
RESID(-1)^2	0.102981	0.007923	12.99816	0.0000
GARCH(-1)	0.901192	0.006926	130.1232	0.0000
T-DIST. DOF	8.626771	0.839904	10.27114	0.0000
R-squared	0.013108	Mean dependent var		0.000250
Adjusted R-squared	0.012350	S.D. dependent var		0.020015
S.E. of regression	0.019891	Akaike info criterion		-5.598880
Sum squared resid	2.575310	Schwarz criterion		-5.592634
Log likelihood	18244.35	F-statistic		17.29065
Durbin-Watson stat	1.950822	Prob(F-statistic)		0.000000
Inverted AR Roots	.10			