

UNIVERSIDADE DE BRASÍLIA
FACULDADE DE ECONOMIA, ADMINISTRAÇÃO, CONTABILIDADE E
CIÊNCIA DA INFORMAÇÃO E DOCUMENTAÇÃO
DEPARTAMENTO DE ECONOMIA

Regis Augusto Ely

Ensaio em Finanças

Brasília
2012

Regis Augusto Ely

Ensaaios em Finanças

Tese de doutorado submetida ao Departamento de Economia da Universidade de Brasília como requisito parcial para a obtenção do grau de Doutor em Economia.

Orientador: José Guilherme de Lara Resende

**Brasília
2012**

Regis Augusto Ely

Ensaaios em Finanças

Tese de doutorado submetida ao Departamento de Economia da Universidade de Brasília como requisito parcial para a obtenção do grau de Doutor em Economia.

Aprovado pela banca examinadora em: _____

Banca examinadora:

Prof. Dr. Benjamin Miranda Tabak
Universidade Católica de Brasília (UCB)
Banco Central do Brasil (Bacen)

Prof. Dr. José Carneiro da Cunha
Oliveira Neto
Universidade de Brasília (UnB)

Prof. Otávio Ribeiro de Medeiros, PhD
Universidade de Brasília (UnB)

Prof. Paulo César Coutinho, PhD
Universidade de Brasília (UnB)

Prof. José Guilherme de Lara Resende, PhD
Universidade de Brasília (UnB)

Agradecimentos

Agradeço às pessoas que contribuíram para a minha formação durante os cursos de mestrado e doutorado. Aos professores do Departamento de Economia da UnB, principalmente nos nomes de Daniel Oliveira Cajueiro, Gil Riella, José Guilherme de Lara Resende, Roberto de Góes Ellery Júnior e Victor Gomes. Aos colegas de curso e profissão que contribuíram para cada etapa de minha formação, que são muitos para citar nomes. Aos membros da banca examinadora pelas valiosas sugestões para a elaboração desta tese.

Um especial agradecimento aos amigos e colegas Daniel de Abreu Pereira Uhr, Frederico Hartmann de Souza, Julia Gallego Ziero Uhr e Thaís Figueiredo Pinto por serem imprescindíveis nesta etapa final do curso de doutorado.

À minha família, por me apoiarem durante todo o processo. Meus pais, Flavio Miguel Ely e Izolde Maria Ely. Minhas irmãs, Fabiane Ely e Fernanda Ely. Meus (futuros cunhados?) Roger Pires Muller e Christian Mollenhauer. Minha futura esposa, Cássia Luíse Boettcher, seus pais, Irineo Boettcher e Margrid Henriqueta Boettcher, e seu irmão, Pedro Augusto Boettcher.

Resumo

Esta tese é composta por três ensaios em finanças com o objetivo de investigar o comportamento dos mercados cambial e acionário brasileiro. O primeiro ensaio examina a transmissão na média e na volatilidade entre retornos acionários e variações da taxa de câmbio no Brasil. Utilizamos modelos multivariados autorregressivos e com heteroscedasticidade condicional, bem como matrizes de correlação condicional variantes no tempo para medir o tamanho, a direção e a simetria da transmissão de média e volatilidade de um mercado para o outro. Os resultados indicam que (i) o mercado acionário lidera a transmissão na média, entretanto (ii) a volatilidade do mercado cambial causa volatilidade no mercado acionário, sendo a transmissão intensificada pela crise do *subprime*, (iii) retornos negativos e depreciação cambial tendem a aumentar a volatilidade em ambos os mercados, e (iv) o processo de correlação condicional apresenta alta persistência e assimetria em relação à depreciação cambial. O segundo ensaio examina a relação entre correlação serial e volatilidade nos retornos do índice Ibovespa. Para a estimação da volatilidade utilizamos um modelo autorregressivo generalizado exponencial com heteroscedasticidade condicional e para o cálculo da correlação serial, uma estatística de razão de variância onde a defasagem é calculada endogenamente. Os resultados demonstram que (i) a volatilidade é negativamente relacionada à correlação serial para retornos semanais, (ii) essa relação negativa está presente nos retornos diários apenas se utilizarmos correlação serial de primeira ordem, (iii) momentos de maior volatilidade aumentam a ineficiência na precificação dos ativos que compõem o índice, e (iv) a crise do *subprime* não intensificou esse efeito para retornos semanais, mas produziu uma relação positiva entre volatilidade e correlação serial para retornos diários. O terceiro ensaio estuda a dinâmica dos saltos condicionais na taxa de câmbio Real/Dólar desde a introdução do regime de câmbio flutuante no Brasil. Utilizamos um modelo de saltos condicionais constantes e três especificações diferentes do modelo ARJI-GARCH proposto por Chan e Maheu (2002) para modelar a dinâmica dos saltos. Os resultados sugerem que (i) os saltos condicionais da taxa de câmbio são variantes no tempo e sensíveis a choques passados, (ii) depreciações cambiais no período anterior tendem a mudar a direção dos saltos no próximo período, e (iii) a intensidade dos saltos é persistente, podendo ser modelada por um processo autorregressivo de médias móveis.

Palavras-chave: Transmissão de volatilidade, Correlação serial, Saltos condicionais dinâmicos.

Abstract

This thesis is comprised of three papers on financial econometrics with the main goal of updating the knowledge on the behavior of the foreign exchange and stock markets in Brazil. The first essay searches for evidence of mean and volatility spillovers between stock and exchange markets in Brazil. We employ multivariate generalized autorregressive conditional heteroscedasticity models with dynamic conditional correlation to measure the size and sign effects of volatility spillovers from one market to another. The results indicate that (i) the stock market leads the exchange market in the mean, (ii) exchange market volatility spillovers to the stock market, and this effect is intensified during the subprime crisis, (iii) negative shocks in returns and currency depreciation tends to increase volatility in both markets, and (iv) the conditional correlation process between the markets is highly persistent and asymmetric. The second essay examines the relation between serial correlation and volatility in the Ibovespa index returns. We employ an exponential general autorregressive conditional heteroskedastic model to estimate volatility and a variance ratio statistic to calculate serial correlation, where the holding period is selected endogenously. The results show that (i) volatility is negatively related with serial correlations for weekly returns, (ii) this negative relation is found in daily returns only if we use first order serial correlation, (iii) higher volatility induces inefficiency, and (iv) the subprime crisis has not intensified the effect for weekly returns, but produced a positive relation between volatility and serial correlation for daily returns. The third essay studies the conditional jump dynamics of the exchange rate between Real and U.S Dollar since the introduction of the floating regime in Brazil. We use a constant conditional jump model and three different specifications of the ARJI-GARCH model of Chan e Maheu (2002) to model jump dynamics. The results suggest that (i) conditional jumps of the exchange rate are time-varying and sensitive to past shocks, (ii) after currency depreciation, the direction of a jump in the next period is more likely to change, and (iii) the jump intensity is highly persistent and behaves like an autorregressive moving average model.

Keywords: Volatility spillovers, Serial correlation, Dynamic conditional jumps.

Lista de Figuras

3.1	Razões de variância diárias com 100 observações sobrepostas.	42
3.2	Razões de variância semanais com 100 observações sobrepostas.	43
3.3	Volatilidade dos retornos diários.	45
3.4	Volatilidade dos retornos semanais.	46
3.5	Correlograma cruzado entre volatilidade e resíduos	52
4.1	Logaritmo das variações diárias na taxa de câmbio Real/Dólar	58
4.2	Intensidade dos saltos nas variações da taxa de câmbio	66
4.3	Probabilidade de pelo menos um salto no câmbio durante o mês de outubro de 2008.	67

Lista de Tabelas

2.1	Estatísticas descritivas da taxa de câmbio e do IBrX	17
2.2	Testes de Phillips-Perron e Johansen	17
2.3	Modelo VAR(3) entre variações na taxa de câmbio e retornos do IBrX	22
2.4	Modelo DCC-GARCH(1,1) bivariado	23
2.5	Modelo VAR(3) com dois subperíodos	25
2.6	Modelo DCC-GARCH(1,1) bivariado com dois subperíodos	26
2.7	Modelo DCC-EGARCH(1,1) bivariado	27
2.8	Modelo ADCC-EGARCH(1,1) bivariado	28
3.1	Estatísticas descritivas dos retornos do Ibovespa	36
3.2	Estatísticas descritivas das razões de variância	43
3.3	Estimação da volatilidade para retornos diários e semanais	44
3.4	Regressões da razão de variância com a volatilidade para retornos diários	46
3.5	Regressões da razão de variância com a volatilidade para retornos semanais	47
3.6	Relações entre eficiência e volatilidade	49
3.7	Modelo AR(1)-EGARCH(1,1) com efeito autocorrelação	50
4.1	Estatísticas descritivas das variações na taxa de câmbio	59
4.2	Resultados do modelo dinâmico de saltos condicionais	64

Sumário

1	Introdução	10
2	Transmissão de volatilidade entre o mercado cambial e acionário no Brasil	12
2.1	Introdução	13
2.2	Revisão de literatura	14
2.3	Metodologia	16
2.3.1	Dados	16
2.3.2	Modelo vetorial autorregressivo (VAR)	18
2.3.3	Modelo GARCH com correlação condicional dinâmica (DCC-GARCH)	18
2.3.4	Modelo com volatilidade assimétrica (DCC-EGARCH)	20
2.3.5	Modelo com correlação condicional dinâmica assimétrica (ADCC-EGARCH)	21
2.4	Resultados	22
2.4.1	Impactos da crise do subprime	24
2.4.2	Assimetria na transmissão de volatilidade	27
2.4.3	Assimetria na correlação condicional	28
2.4.4	Causalidade não linear	28
2.5	Conclusão	29
3	Relações entre correlação serial e volatilidade: existe o efeito Le-Baron no Brasil?	31
3.1	Introdução	32
3.2	Revisão de literatura	33
3.3	Metodologia	35
3.3.1	Dados	35
3.3.2	Razão de variância	36
3.3.3	Volatilidade	38

3.3.4	Modelo autorregressivo com variável exógena	39
3.3.5	Modelo com inclusão de <i>dummy</i> para a crise	41
3.3.6	Modelo EGARCH com efeito autocorrelação	41
3.4	Resultados	42
3.4.1	Relação entre volatilidade e eficiência	48
3.4.2	Efeito LeBaron	49
3.4.3	Testes de robustez	51
3.5	Conclusão	52
4	Dinâmica dos saltos condicionais na taxa de câmbio brasileira	55
4.1	Introdução	56
4.2	Revisão de literatura	57
4.3	Metodologia	58
4.3.1	Dados	58
4.3.2	Modelos dinâmicos de saltos condicionais	59
4.3.3	Interpretação dos modelos	63
4.4	Resultados	64
4.5	Conclusão	67
5	Considerações Finais	69

Capítulo 1

Introdução

Países emergentes têm sido tema de pesquisas recentes sobre o comportamento das séries de preços e retornos de seus mercados financeiros devido à maior existência de possibilidades de arbitragem nesses mercados, dado o menor nível de eficiência na precificação. O interesse nesses mercados tem aumentado com o maior fluxo de investimentos e a maior procura por diversificação dos investidores estrangeiros. O Brasil se enquadra nesse seletivo grupo de mercados emergentes que tendem a apresentar altos retornos esperados com graus mais elevados de risco.

Ao lado do crescente interesse em mercados emergentes está o avanço teórico da modelagem econométrica para séries temporais, impulsionado pelo aumento do poder computacional em anos recentes, além da disponibilização de dados com frequências mais altas, incluindo países que antes careciam de dados amostrais suficientes. Esse instrumental abre possibilidades de identificação e modelagem de regularidades nas dinâmicas de preços e retornos em vários mercados.

Os principais mercados que atraem o interesse dos investidores externos são o mercado cambial e o acionário. Ambos os mercados foram objeto de estudos recentes de diversos autores em países desenvolvidos (Corradi et al., 2012; Ferreira e Santa-Clara, 2011; Moskowitz et al., 2012). Porém as séries de preços e retornos para países emergentes apresentam algumas peculiaridades características de cada mercado analisado, devido à maior presença de ineficiências na precificação de ativos, entre outros fatores.

O principal objetivo desta tese é coletar evidências sobre tópicos ainda não abordados nos mercados cambial e acionário brasileiro utilizando métodos econométricos avançados e desenvolvimentos recentes em econometria financeira, bem como contribuir metodologicamente para a abordagem dos problemas analisados. Para isso, esta tese divide-se em três ensaios, expostos nos capítulos 2, 3 e 4, cada um com objetivos específicos.

No capítulo 2, o primeiro ensaio examina a transmissão na média e na volatilidade entre retornos do mercado acionário e variações da taxa de câmbio no Brasil utilizando modelos multivariados autorregressivos e com heteroscedasticidade condicional. O principal objetivo é identificar o sentido da causalidade existente entre os mercados cambial e acionário brasileiros, respondendo as seguintes questões: 1) Existem transmissões na média e na volatilidade entre o mercado cambial e acionário brasileiro? 2) Qual o impacto da crise do *subprime* nestas transmissões? 3) Qual mercado lidera a formação de preços e volatilidade no caso brasileiro? 4) A transmissão da volatilidade entre esses mercados é simétrica? 5) Qual a dinâmica da correlação condicional entre esses mercados?

No capítulo 3, o segundo ensaio examina a relação entre correlação serial e volatilidade no mercado acionário brasileiro através da estimação dessas duas estatísticas para retornos diários e semanais do Ibovespa. O principal objetivo é verificar se momentos de maior volatilidade induzem maior ou menor correlação serial dos retornos, relação que ainda não foi abordada na literatura para o Brasil. Isso permite responder as seguintes perguntas: 1) A volatilidade afeta significativamente a correlação serial dos retornos do Ibovespa? 2) Há alguma relação entre volatilidade e eficiência no mercado acionário brasileiro? 3) Quais os efeitos da crise do *subprime* nessas relações?

No capítulo 4, o terceiro ensaio examina a dinâmica dos saltos condicionais na taxa de câmbio Real/Dólar desde a introdução do regime de câmbio flutuante no Brasil. Para isso, utilizamos um modelo de saltos condicionais constantes e três especificações diferentes do modelo ARJI-GARCH proposto por Chan e Maheu (2002). O objetivo deste capítulo é verificar se saltos na variação da taxa de câmbio são significantes e qual o comportamento deles no tempo. Para isso, respondemos as seguintes perguntas: 1) Qual a intensidade dos saltos condicionais na taxa de câmbio ao longo do tempo? 2) Os saltos aparecem de maneira persistente ou se comportam como ruído branco? 3) Existe assimetria no comportamento dos saltos, ou seja, depreciações cambiais têm maiores efeitos na direção dos saltos do que apreciações do câmbio?

Capítulo 2

Transmissão de volatilidade entre o mercado cambial e acionário no Brasil

Este capítulo examina a transmissão na média e na volatilidade entre retornos acionários e variações da taxa de câmbio no Brasil. Utilizamos modelos multivariados autorregressivos e com heteroscedasticidade condicional, bem como matrizes de correlação condicional variantes no tempo para medir o tamanho, a direção e a simetria da transmissão na média e na volatilidade de um mercado para o outro. Os resultados indicam que (i) o mercado acionário lidera a transmissão na média, entretanto (ii) a volatilidade do mercado cambial causa volatilidade no mercado acionário, sendo a transmissão intensificada pela crise do *subprime*, (iii) retornos negativos e depreciação cambial tendem a aumentar a volatilidade em ambos os mercados, e (iv) o processo de correlação condicional apresenta alta persistência e assimetria em relação à depreciação cambial.

2.1 Introdução

As relações dinâmicas entre os mercados acionário e cambial têm importantes implicações práticas e teóricas. Apesar de retornos acionários e variações da taxa de câmbio na frequência diária serem praticamente imprevisíveis quando utilizamos apenas observações passadas (Engle, 2004; Baillie e Bollerslev, 2002), as suas volatilidades, medidas através das variâncias condicionais, apresentam uma grande evidência de persistência ao longo do tempo (Nelson, 1991), sendo passíveis de previsão. A existência de transmissão de volatilidade entre os dois mercados impacta as decisões de portfólio e o gerenciamento de risco de carteiras. Do ponto de vista teórico, temos dois grupos de modelos distintos que explicam as relações entre esses mercados, os modelos *flow-oriented* e *stock-oriented*, podendo a análise empírica dos dados corroborar ou não os resultados desses modelos.

Este capítulo procura elucidar a relação de causalidade entre retornos e volatilidades existente entre os mercados acionário e cambial no Brasil. Para a análise dos primeiros momentos, estimamos um modelo vetorial autorregressivo com o intuito de verificar a existência de causalidade em ambos os sentidos. Para a análise dos segundos momentos, utilizamos primeiramente um modelo generalizado autorregressivo com heteroscedasticidade condicional (GARCH) multivariado com a especificação da matriz de correlação condicional dinâmica (DCC) dada por Engle (2002). Para considerar a transmissão assimétrica de volatilidade, estimamos um modelo exponencial (EGARCH) multivariado com a correlação condicional dinâmica (DCC) e assimétrica (ADCC), proposta por Cappiello et al. (2006). As principais perguntas a serem respondidas são: 1) Existem transmissões na média e na volatilidade entre o mercado cambial e acionário brasileiro? 2) Qual o impacto da crise do *subprime* nestas transmissões? 3) Qual mercado lidera a formação de preços e volatilidade no caso brasileiro? 4) A transmissão da volatilidade entre esses mercados é simétrica? 5) Qual a dinâmica da correlação condicional entre esses mercados?

O capítulo contribui para a literatura de diversas maneiras. Do ponto de vista empírico, ele atualiza o conhecimento sobre a relação entre os mercados acionário e cambial brasileiros, que carecem de análises mais profundas sobre a interação não apenas na média, mas também na volatilidade de seus retornos. Os resultados contribuem para o entendimento dos mercados de países emergentes, que apresentam características distintas dos países desenvolvidos. Do ponto de vista metodológico, para a análise de transmissão na volatilidade entre os mercados, a quase totalidade dos trabalhos utilizam modelos multivariados baseados em generalizações ou combinações lineares de modelos univariados GARCH (Zhao, 2010; Hassan e Malik,

2007), ou então combinações não lineares com a matriz de correlação condicional constante (Yang e Doong, 2004), uma hipótese muito restritiva. Neste capítulo utilizamos um modelo que pode ser visto como uma combinação não linear de modelos GARCH e EGARCH univariados em que a correlação condicional varia no tempo de acordo com a estrutura proposta por Engle (2002) e contém assimetrias, conforme Cappiello et al. (2006). Assim, pretendemos capturar a transmissão simétrica e assimétrica de volatilidade entre esses mercados e permitir uma especificação mais flexível e realista para a matriz de correlação condicional.

2.2 Revisão de literatura

A teoria contém dois tipos distintos de modelos que explicam a relação entre taxa de câmbio e retornos acionários. A diferença entre esses modelos é a relação de liderança que um mercado exerce sobre o outro na especificação dos preços e volatilidades.

Os modelos do tipo *flow-oriented* (Dornbusch e Fischer, 1980) postulam que mudanças na taxa de câmbio afetam a concorrência internacional e as balanças comerciais, influenciando as variáveis reais. Assim, os preços das ações, interpretados como o valor presente dos fluxos de caixa futuros das firmas, possuem uma relação positiva com a taxa de câmbio. Quando a moeda local deprecia, as exportações do país ficam mais baratas, aumentando a competitividade e a renda doméstica, bem como os preços das ações das firmas. Alguns trabalhos mais recentes postulam que para países importadores de bens, a apreciação da taxa de câmbio pode ter um impacto positivo no mercado acionário devido à diminuição de custos (Adjasi et al., 2008).

Os modelos do tipo *stock-oriented* postulam que as taxas de câmbio são determinadas pela oferta e demanda de ativos financeiros. Dois grupos distintos explicam essa relação: modelos de portfólios balanceados e modelos monetários.

O primeiro grupo (Branson, 1983; Frankel, 1983) defende a existência de uma relação negativa entre preços de ações e taxas de câmbio, pois um aumento nos retornos acionários gera apreciação da moeda local devido ao maior fluxo de investimentos internacionais no país, e indiretamente, devido ao aumento da riqueza e da taxa de juros do país, impulsionando também a demanda por moeda doméstica.

O segundo grupo considera as taxas de câmbio como ativos financeiros, sendo determinadas pelo valor presente esperado dos fluxos de caixa futuros. Assim, a taxa

de câmbio é reflexo de todos os fatores macroeconômicos que afetam esses fluxos. Se há fatores em comum influenciando as duas variáveis, então os retornos acionários podem impactar ou serem impactados pelas taxas de câmbio.

Do ponto de vista empírico, as evidências de transmissão na média indicam que o mercado acionário lidera o mercado cambial devido à existência de causalidade dos preços das ações para as taxas de câmbio, tanto em mercados desenvolvidos (Yang e Doong, 2004; Nieh e Lee, 2001), quanto no caso brasileiro (Tabak, 2006). Esses resultados são consistentes com os modelos *stock-oriented*, onde as mudanças da taxa de câmbio são determinadas pela oferta e demanda de ativos financeiros.

Já as evidências de transmissão de volatilidade são mais conflitantes. Kanas (2000) e Yang e Doong (2004), usando modelos EGARCH multivariados para investigar essa relação nos mercados de países desenvolvidos, chegaram a conclusão de que há transmissão de volatilidade simétrica (Kanas, 2000) e assimétrica (Yang e Doong, 2004) do mercado acionário para o mercado cambial. Wu (2005) investigou o mesmo fenômeno para países desenvolvidos e emergentes da Ásia, encontrando transmissão bidirecional entre as volatilidades. Choi et al. (2009) encontraram transmissão de volatilidade unidirecional do mercado acionário para o cambial na Nova Zelândia.

Em países emergentes, Eissa et al. (2010) descobriram evidências de transmissão de choques e volatilidade do mercado cambial para o mercado acionário, bem como transmissão bidirecional em Marrocos, Egito e Turquia. Zhao (2010) concluiu que há causalidade bidirecional na volatilidade entre estes dois mercados na China. Walid et al. (2011) demonstraram que o mercado cambial exerce importante impacto na mudança de regime do mercado acionário em quatro países emergentes, Hong Kong, Singapura, Malásia e México. No Brasil, Tabak (2006) encontrou evidências de causalidade não linear das taxas de câmbio para os preços de ações.

Aparentemente, os estudos para mercados emergentes demonstraram maior influência da volatilidade cambial no mercado acionário, em desacordo com os resultados para países desenvolvidos. As possíveis razões para isso vão desde a maior influência do investimento externo bem como a existência de políticas cambiais mais ativas nesses países. No caso brasileiro, não há evidências suficientes que indiquem o sentido da causalidade entre as volatilidade destes mercados.

2.3 Metodologia

Na primeira parte desta seção analisamos os dados amostrais utilizados, bem como desenvolvemos alguns diagnósticos para investigar uma possível cointegração entre as séries. A segunda parte expõe o modelo utilizado para medir a transmissão na média entre as variáveis. A terceira, quarta e quinta partes desenvolvem os três modelos utilizados para mensurar a transmissão de volatilidade existente entre os mercados cambial e acionário.

2.3.1 Dados

Os dados consistem no fechamento diário do Índice Brasil (IBrX) nominal e da taxa de câmbio diária nominal Real/Dólar entre o período de fevereiro de 1999 a dezembro de 2011. A escolha do IBrX reflete o fato deste índice ser o que melhor representa a totalidade do mercado acionário brasileiro, sendo composto pelas 100 ações mais negociadas da Bolsa de Valores de São Paulo. O período amostral começa em fevereiro de 1999 para excluir períodos anteriores a flexibilização do câmbio no Brasil. A periodicidade diária é necessária para obter uma amostra de tamanho razoável para a grande quantidade de parâmetros a serem estimados na regressão multivariada, bem como incorporar as relações de curto prazo entre os mercados analisados. Ao todo temos 3174 observações.

As variações na taxa de câmbio e retornos acionários são calculados como:

$$R_{i,t} = \ln(P_{i,t}/P_{i,t-1}), \quad (2.1)$$

onde $P_{i,t}$ é a taxa de câmbio para $i = 1$, e o valor do índice IBrX para $i = 2$, no tempo t , enquanto \ln é o logaritmo natural. A Tabela 2.1 apresenta as estatísticas descritivas para as séries.

As duas séries apresentam média estatisticamente igual a zero. As variações da taxa de câmbio e os retornos do IBrX são altamente leptocúrticos em relação à distribuição normal, sendo ambos negativamente enviesados. A hipótese nula de normalidade no teste de Jarque-Bera é rejeitada a 1% de significância para ambas as variáveis. Por fim, o teste de Ljung-Box mostra que as séries são autocorrelacionadas, bem como seus quadrados, indicando a presença de heteroscedasticidade condicional.

Antes da estimação dos modelos é necessário checar a estacionariedade das

Tabela 2.1: Estatísticas descritivas da taxa de câmbio e do IBrX

	Variações da taxa de câmbio	Retornos do IBrX
Média	-0,000017	0,000813
Desvio-padrão	0,010259	0,017776
$LB(10)$	33,1288 [‡]	29,1985 [‡]
$LB^2(10)$	2204,7337 [‡]	2258,79 [‡]
Assimetria	-0,11398	-0,08995
Curtose (Exc.)	11,843	4,788
Jarque-Bera	18848,5 [‡]	3036,4 [‡]

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

variáveis e uma possível cointegração entre a taxa de câmbio e o IBrX. Para isso, utilizamos os testes de Phillips-Perron e de Johansen, ambos robustos na presença de autocorrelação e heteroscedasticidade. A Tabela 2.2 mostra os resultados.

Tabela 2.2: Testes de Phillips-Perron e Johansen

Painel A: Teste de Phillips-Perron				
Variáveis	Série de preços		Série de retornos	
	Valor do teste	P-valor	Valor do teste	P-valor
Taxa de câmbio	-1,6726	0,7169	-52,0978	0,01 [‡]
IBrX	-1,7476	0,6852	-54,5719	0,01 [‡]
Painel B: Teste de Johansen				
Hipótese nula	Teste Traço	P-valor	Teste Lmax	P-valor
$r \leq 0$	13,799	0,1981	9,6462	0,4382
$r \leq 1$	4,1531	0,0416 [†]	4,1531	0,0416 [†]

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

O teste de Phillips-Perron contém constante e tendência. O teste de Johansen contém constante e tendência sem restrições e a defasagem escolhida pelo critério de Akaike.

O teste de Phillips-Perron não rejeita a hipótese de raiz unitária para ambas as séries de preços, enquanto os retornos têm comportamento estacionário. Como as séries de preços possuem raiz unitária, é necessário checar uma possível cointegração entre as variáveis através do teste de Johansen. Ambos os testes do traço e autovalor máximo não rejeitam a hipótese de que o número de vetores de cointegração é igual ou menor que zero, logo podemos inferir que as séries não são cointegradas, e por isso não é necessário a inclusão de termos para correção dos erros. Esse resultado é consistente com Granger et al. (2000) e Nieh e Lee (2001).

2.3.2 Modelo vetorial autorregressivo (VAR)

A análise de transmissão na média entre retornos acionários e variações da taxa de câmbio é estimada a partir de um modelo vetorial autorregressivo de ordem p , VAR(p), dado por:

$$R_{i,t} = \beta_{i,0} + \sum_{j=1}^2 \beta_{ij,t-1} R_{j,t-1} + \cdots + \sum_{j=1}^2 \beta_{ij,t-p} R_{j,t-p} + \varepsilon_{i,t} \quad \text{para } i = 1, 2, \quad (2.2)$$

onde $\beta_{i,0}, \beta_{ij,t-1}, \dots, \beta_{ij,t-p}$ são os parâmetros a serem estimados e $\varepsilon_{i,t}$ são os resíduos do modelo. Os coeficientes β_{ij} para $i \neq j$, se estatisticamente significantes, medem o tamanho do efeito de transmissão na média entre os mercados.

A ordem p do modelo é determinada de acordo com os critérios de Akaike (AIC) e Hannan-Quinn (HQC), amplamente utilizados para seleção de defasagem de modelos VAR em séries temporais financeiras. Ambos os critérios indicam o mesmo grau de defasagem para os modelos estimados. O critério de informação Bayesiano (BIC) não foi utilizado, pois tende a selecionar modelos com poucas defasagens devido a inclusão de um termo de penalização para o número de coeficientes no modelo. Isso pode fazer com que a autocorrelação dos retornos não seja completamente eliminada no modelo VAR, condição necessária para a estimação dos modelos GARCH multivariados propostos na seção seguinte. Para contornar o problema do excesso de parâmetros, definimos o grau máximo de defasagens como cinco. Para os dados utilizados, os critérios apontaram um VAR(3) como sendo o modelo mais apropriado.

A Tabela 2.1 fornece fortes evidências da presença de heteroscedasticidade condicional em ambas as séries. Logo, utilizamos um modelo GARCH multivariado para estimar as variâncias condicionais. O modelo é descrito na seção seguinte.

2.3.3 Modelo GARCH com correlação condicional dinâmica (DCC-GARCH)

A transmissão de volatilidade entre os mercados cambial e acionário é primeiramente estudada através de um modelo GARCH multivariado com a matriz de correlação condicional variante no tempo proposta por Engle (2002). Testes desenvolvidos por Tse (2000) e Bera e Kim (2002) normalmente rejeitam a hipótese de constância das correlações condicionais entre mercados financeiros. O modelo

DCC-GARCH(1,1) descrito a seguir é aplicado aos resíduos da estimação do modelo VAR(p) proposto na seção anterior.

Considere o seguinte processo estocástico vetorial:

$$\mathbf{y}_t = \mu + \varepsilon_t \quad (2.3)$$

$$\varepsilon_t = \mathbf{D}_t \mathbf{z}_t, \quad (2.4)$$

onde $\mathbf{D}_t = \text{diag}(h_{1,t}^{1/2}, \dots, h_{N,t}^{1/2})$, $\mathbf{z}_t = [z_{1,t}, \dots, z_{N,t}]'$ é um vetor estocástico independentemente distribuído, com $E[\mathbf{z}_t | F_{t-1}] = \mathbf{0}$ e $E[\mathbf{z}_t' \mathbf{z}_t | F_{t-1}] = \mathbf{P}_t = [\rho_{ij,t}]$, onde F_t é o conjunto de informações até o tempo t , e $\mathbf{P}_t \in F_{t-1}$. Note que $E[\varepsilon_t | F_{t-1}] = \mathbf{0}$ e $E[\varepsilon_t \varepsilon_t' | F_{t-1}] = \mathbf{D}_t \mathbf{P}_t \mathbf{D}_t = \mathbf{H}_t$, sendo \mathbf{H}_t e \mathbf{P}_t a matriz de covariância condicional e a matriz positiva definida de correlação condicional do processo ε_t , respectivamente. A matriz \mathbf{H}_t tem seu elemento (i,j) dado por $h_{i,t}$ se $i = j$, e $h_{i,t}^{1/2} h_{j,t}^{1/2} \rho_{ij,t}$ caso contrário. O vetor $\mathbf{h}_t = (h_{1,t}, \dots, h_{N,t})'$ segue a dinâmica:

$$\mathbf{h}_t = \mathbf{a}_0 + \mathbf{A} \varepsilon_{t-1}^{(2)} + \mathbf{B} \mathbf{h}_{t-1}, \quad (2.5)$$

onde $\varepsilon_t^{(2)} = [\varepsilon_{1,t}^2, \dots, \varepsilon_{N,t}^2]'$, \mathbf{a}_0 é um vetor $(N \times 1)$ de constantes positivas, e \mathbf{A} e \mathbf{B} são matrizes $(N \times N)$ com elementos tais que os elementos de $\mathbf{h}_t = (h_{1,t}, \dots, h_{N,t})'$ são positivos para todo t . Uma condição suficiente adotada na estimação para \mathbf{h}_t ser positivo para todo t , apesar de não ser necessária, é que todos os elementos de \mathbf{A} e \mathbf{B} sejam positivos.

A dinâmica da matriz de correlação condicional é definida de acordo com Engle (2002), sendo:

$$\mathbf{P}_t = (\mathbf{Q}_t \odot \mathbf{I}_N)^{-1/2} \mathbf{Q}_t (\mathbf{Q}_t \odot \mathbf{I}_N)^{-1/2} \quad (2.6)$$

$$\mathbf{Q}_t = (1 - \alpha - \beta) \mathbf{Q} + \alpha \mathbf{z}_{t-1} \mathbf{z}_{t-1}' + \beta \mathbf{Q}_{t-1}, \quad (2.7)$$

onde \odot é o operador de Hadamard, \mathbf{Q} é a matriz de covariância amostral de \mathbf{z}_t , e \mathbf{I}_N é a matriz identidade $(N \times N)$. Uma das vantagens dessa formulação é que o processo de correlação depende apenas de dois parâmetros, α e β , não dependendo do número de variáveis do modelo. Isso diminui o custo computacional, mas por outro lado, impõe a hipótese restritiva de que todos os processos de correlação apresentam o mesmo comportamento dinâmico. A restrição nos parâmetros adotada para que o processo seja estacionário é $\alpha + \beta < 1$ e $\alpha, \beta > 0$.

Assumindo que o vetor estocástico \mathbf{z}_t segue uma distribuição normal, a função de log-verossimilhança desse modelo pode ser decomposta em duas partes, o componente de volatilidade e o componente de correlação. A função log-verossimilhança

do componente de volatilidade é dada por:

$$\ell_{v,t}(\omega) = -\frac{N}{2}\ln(2\pi) - \frac{1}{2}\ln|\mathbf{V}_t| - \frac{1}{2}\varepsilon_t'\mathbf{V}_t^{-1}\varepsilon_t, \quad (2.8)$$

onde $\mathbf{V}_t = \mathbf{D}_t^2$. Já a função log-verossimilhança do componente de correlação é dada por:

$$\ell_{c,t}(\omega, \phi) = -\frac{1}{2}\ln|\mathbf{P}_t| - \frac{1}{2}\mathbf{z}_t'\mathbf{P}_t^{-1}\mathbf{z}_t + \frac{1}{2}\mathbf{z}_t'\mathbf{z}_t. \quad (2.9)$$

Assim, a estimação do modelo pode ser feita em dois estágios. Primeiro maximizando (2.8) com respeito a ω (vetor de parâmetros do componente de volatilidade), e depois maximizando (2.9) com respeito a ϕ (vetor de parâmetros do componente de correlação), dadas as estimativas do estágio anterior.

2.3.4 Modelo com volatilidade assimétrica (DCC-EGARCH)

Para medir o impacto da assimetria na transmissão de volatilidade entre os mercados, estimamos um modelo DCC-EGARCH(1,1), onde a variância condicional tem a seguinte dinâmica para ambos os mercados ($i = 1,2$):

$$h_{i,t} = \exp\left\{\omega_i + \sum_{j=1}^2 \alpha_{ij}(|z_{j,t-1}| - E(|z_{j,t-1}|)) + \delta_j z_{j,t-1} + \gamma_i \ln(h_{i,t-1})\right\}, \quad (2.10)$$

onde $z_{i,t} = \varepsilon_{i,t}/\sqrt{h_{i,t}}$ é o resíduo padronizado. O coeficiente γ_i mede a persistência da volatilidade no mercado i , sendo que $|\gamma_i| < 1$ garante que o processo tenha variância incondicional finita. Os coeficientes α_{ij} , para $i \neq j$, capturam a transmissão de volatilidade de um mercado para o outro, enquanto que para $i = j$, medem a persistência dos choques do próprio mercado. Por exemplo, se α_{21} for significativamente diferente de zero, então existirá transmissão de volatilidade do mercado cambial para o mercado acionário. O parâmetro δ_j mede a assimetria dessa transmissão, sendo que se ele for estatisticamente significativo e menor que zero existirá assimetria, ou seja, um choque negativo no mercado i aumentará a volatilidade no mercado j mais do que um choque positivo de igual magnitude. O termo $E(|z_{i,t}|)$ é a esperança do valor absoluto de $z_{i,t}$, sendo igual a $\sqrt{2/\pi}$ se $z_{i,t}$ for normalmente distribuído.

O termo $[|z_{i,t}| - E(|z_{i,t}|)]$ mede o efeito tamanho do choque, enquanto que $\delta_i z_{i,t}$ mede o efeito sinal. A importância relativa da assimetria pode ser mensurada através da razão $|-1 + \delta_j|/(1 + \delta_j)$. Assim, um valor negativo de δ_i aumenta a razão,

indicando que choques negativos têm impactos maiores que choques positivos na variância condicional.

A dinâmica da matriz de correlação condicional, bem como as funções de log-verossimilhança, são iguais às definidas na seção anterior, sendo a estimação do modelo realizada em dois estágios. Como choques negativos podem afetar mais as variâncias condicionais do que choques positivos, é interessante permitir que as covariâncias e correlações também reajam de modo diferente a choques negativos. Por isso, utilizamos um modelo assimétrico de correlação condicional dinâmica na seção seguinte.

2.3.5 Modelo com correlação condicional dinâmica assimétrica (ADCC-EGARCH)

Para investigar a existência de assimetria nas correlações entre os mercados analisados, estimamos um modelo ADCC-EGARCH(1,1) com a correlação condicional dinâmica assimétrica proposta por Cappiello et al. (2006):

$$\mathbf{P}_t = (\mathbf{Q}_t \odot \mathbf{I}_N)^{-1/2} \mathbf{Q}_t (\mathbf{Q}_t \odot \mathbf{I}_N)^{-1/2} \quad (2.11)$$

$$\mathbf{Q}_t = (1 - \alpha - \beta) \mathbf{Q} - \gamma \mathbf{N} + \alpha \mathbf{z}_{t-1} \mathbf{z}'_{t-1} + \gamma \mathbf{n}_{t-1} \mathbf{n}'_{t-1} + \beta \mathbf{Q}_{t-1}, \quad (2.12)$$

sendo $n_t = I[z_t < 0] \odot z_t$, onde $I[x < 0]$ é a função indicadora (igual a um quando a condição entre chaves é verdadeira e zero se falsa), e $\mathbf{N} = E[n_t n'_t]$. Os demais parâmetros são definidos conforme as seções 2.3.3 e 2.3.4, e a condição necessária e suficiente para \mathbf{Q}_t ser positiva definida é $\alpha + \beta + \delta\gamma < 1$, onde δ é o máximo autovalor de $\mathbf{Q}^{-1/2} \mathbf{N} \mathbf{Q}^{-1/2}$.

Se \mathbf{Q}_t é positiva definida, então \mathbf{P}_t também será. Note que a idéia do modelo ADCC é estimar o processo de correlação condicional como se fosse um GJR-GARCH univariado (Glosten et al., 1993). Se fizermos $\gamma = 0$, então obtemos o modelo DCC da seção 2.3.3, e se $\gamma = \alpha = \beta = 0$, obtemos o modelo de correlação condicional constante proposto por Bollerslev (1990).

2.4 Resultados

A Tabela 2.3 mostra as estimativas do modelo VAR(3) com a defasagem selecionada conforme os critérios de Akaike e Hannan-Quinn. Os coeficientes $\beta_{ii,t-1}$, $\beta_{ii,t-2}$ e $\beta_{ii,t-3}$, para $i = 1,2$, medem a persistência das variações na taxa de câmbio e nos retornos acionários, enquanto os coeficientes $\beta_{ij,t-1}$, $\beta_{ij,t-2}$ e $\beta_{ij,t-3}$ medem a transmissão na média entre os mercados. São utilizados erros padrão de Newey-West por serem robustos na presença de heteroscedasticidade, propriedade característica de dados financeiros.

Tabela 2.3: Modelo VAR(3) entre variações na taxa de câmbio e retornos do IBrX

Painel A: Estimativa dos parâmetros						
Coeficientes	Valor		Erro padrão		P-valor	
	Câmbio	IBrX	Câmbio	IBrX	Câmbio	IBrX
$\beta_{i,0}$	0,000102	0,000875	0,000181	0,000327	0,5720	0,0074 [‡]
$\beta_{ii,t-1}$	0,006792	0,027268	0,048604	0,028024	0,8889	0,3306
$\beta_{ii,t-2}$	-0,029445	-0,052895	0,048886	0,036480	0,5470	0,1472
$\beta_{ii,t-3}$	-0,016030	-0,075687	0,042107	0,029555	0,7035	0,0105 [†]
$\beta_{ij,t-1}$	-0,122785	-0,034868	0,016499	0,056248	0 [‡]	0,5354
$\beta_{ij,t-2}$	0,028584	-0,067441	0,020116	0,070037	0,1554	0,3357
$\beta_{ij,t-3}$	-0,012667	-0,084317	0,015932	0,060270	0,4266	0,1619
Painel B: Diagnósticos do modelo						
Estatísticas	Regressão 1		Regressão 2			
	Valor	P-valor	Valor	P-valor	P-valor	
$LB(10)$	10,4418	0,403	12,0963	0,279		
$LB^2(10)$	2496,9860	0 [‡]	2058,2483	0 [‡]		
Efeito ARCH	764,814	0 [‡]	604,794	0 [‡]		

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os p-valores são calculados com erros padrão robustos de Newey-West (HAC).

Podemos notar que apenas os coeficientes $\beta_{12,t-1}$, $\beta_{2,0}$ e $\beta_{22,t-3}$ são significantes, indicando que as variações da taxa de câmbio são influenciadas pelos retornos do mercado acionário na primeira defasagem, e estes apresentam persistência na terceira defasagem, bem como um termo constante positivo.

Os resultados corroboram o fato de que o mercado acionário lidera o mercado cambial na média, pelo menos no curto prazo, devido a significância do coeficiente $\beta_{12,t-1}$. Como seu valor é negativo e de considerável magnitude ($-0,122785$), um aumento nos retornos acionários acaba apreciando a moeda local. Isso pode ser reflexo do maior fluxo de investimentos internacionais no país induzidos pela valorização das

ações, aumentando a demanda por moeda doméstica. Esse resultado é consistente com os modelos *stock-oriented* (Branson, 1983; Frankel, 1983). A persistência dos retornos acionários na terceira defasagem reflete a presença de autocorrelação indicada na Tabela 2.1, e seu valor negativo ($-0,075687$) é evidência de uma tendência de reversão à média em defasagens maiores do que a diária.

Alguns trabalhos chegaram a conclusões semelhantes para outros países. Yang e Doong (2004) encontraram evidências de transmissão na média do mercado acionário para o mercado cambial na França, Alemanha, Itália, Canadá e Inglaterra. Para países emergentes, Eissa et al. (2010) concluíram que retornos no mercado acionário afetam a taxa de câmbio na Turquia. No Brasil, Tabak (2006) relatou resultados semelhantes para o índice Ibovespa utilizando dados de 1994 a 2002.

O painel B da Tabela 2.3 apresenta as estatísticas de diagnóstico do modelo. O teste de Ljung-Box não rejeita a hipótese de que os resíduos são estacionários, entretanto os quadrados dos resíduos mostram forte evidência de autocorrelação, um indicativo de efeitos ARCH presentes na regressão. Para considerar a heteroscedasticidade condicional, estimamos o modelo DCC-GARCH(1,1) proposto na seção 2.3.3. A Tabela 2.4 apresenta os resultados.

Tabela 2.4: Modelo DCC-GARCH(1,1) bivariado

Coefficientes	Valor estimado	Erro padrão	Razão-t
$\mathbf{a}_{0,11}$	0,000001	0,000003	0,0017
$\mathbf{a}_{0,21}$	0,000013	0,031337	0,0004
\mathbf{A}_{11}	0,237315	0,004288	55,3408 [‡]
\mathbf{A}_{12}	0,001564	0,042501	0,0368
\mathbf{A}_{21}	0,137953	0,156475	0,8816
\mathbf{A}_{22}	0,084694	0,000005	16024,57 [‡]
\mathbf{B}_{11}	0,241921	0,068242	3,5450 [‡]
\mathbf{B}_{12}	0,137856	0,333636	0,4132
\mathbf{B}_{21}	0,474135	0,018908	25,0760 [‡]
\mathbf{B}_{22}	0,711658	0,094397	7,5389 [‡]
α	0,010952	0,010212	1,0724
β	0,984576	0,015482	63,5930 [‡]

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

A significância dos coeficientes \mathbf{A}_{11} , \mathbf{A}_{22} , \mathbf{B}_{11} e \mathbf{B}_{22} é esperada e reflete a principal característica das séries financeiras, a persistência da variância condicional. Isso nos indica que ambas as séries podem ser modeladas através de processos GARCH.

Nos coeficientes cruzados temos significância apenas em \mathbf{B}_{21} , ao nível de 1%. Assim, a volatilidade do mercado cambial explica a volatilidade do mercado acionário.

Os valores dos coeficientes \mathbf{B}_{21} e \mathbf{B}_{22} são 0,474135 e 0,711658, respectivamente, indicando que apesar da volatilidade do mercado acionário ser explicada em grande parte pela persistência deste processo, uma parcela significativa é explicada pela volatilidade passada do mercado cambial.

Por fim, o coeficiente β é significativo ao nível de 1%, mostrando persistência do processo de correlação condicional entre os mercados ao longo do tempo. A magnitude do coeficiente é 0,984576, ou seja, a correlação condicional entre os dois mercados é explicada quase que em sua totalidade pela correlação existente no período anterior.

Os resultados divergem da literatura para mercados desenvolvidos, mas são semelhantes aos encontrados para mercados emergentes, como por exemplo os descritos em Eissa et al. (2010), Zhao (2010) e Walid et al. (2011).

O fato de que movimentos no mercado cambial afetam a volatilidade do mercado acionário é intuitivo para os mercados emergentes, devido ao maior peso relativo do investimento externo na demanda de ativos nesses países. As variações do câmbio, além de afetarem custos de empresas importadoras de bens, aumentam o grau de incerteza no país, impactando o valor das ações através do investimento externo.

A relação inversa, transmissão de volatilidade do mercado acionário para o cambial, apesar de bastante documentada na literatura, não ocorre no caso brasileiro. Isso pode ser resultado da tendência dos investidores externos de permanecerem no mercado de renda fixa brasileiro após resgates no mercado de ações, não ocasionando entrada e saída de divisas.

2.4.1 Impactos da crise do subprime

Para avaliar a influência da crise do *subprime* nas evidências de transmissão na média e na volatilidade entre retornos acionários e variações da taxa de câmbio, dividimos a amostra em dois subperíodos. O primeiro é composto de 1701 observações diárias entre 1999 a 2005 e o segundo de 1473 observações diárias entre 2006 e 2011. Caso a crise tenha aumentado o nível das transmissões entre os mercados, os coeficientes cruzados terão maior magnitude para o segundo subperíodo amostral. Os resultados do modelo VAR(3) estão descritos na Tabela 2.5.

Quanto a série das variações da taxa de câmbio, observamos persistência na primeira e segunda defasagens apenas no subperíodo de 1999 a 2005, dada a significância dos coeficientes $\beta_{11,t-1}$ e $\beta_{11,t-2}$. Nos dois subperíodos vemos que são os retornos acionários que causam no sentido de Granger as variações na taxa de

Tabela 2.5: Modelo VAR(3) com dois subperíodos

Coeficientes	Subperíodo de 1999 a 2005			Subperíodo de 2006 a 2011		
	Valor	P-valor	Valor	P-valor	Valor	P-valor
	Câmbio	IBrX	Câmbio	IBrX	Câmbio	IBrX
$\beta_{i,0}$	0,000309	0,001103	0,1770	0,0053 [‡]	-0,000126	0,000420
$\beta_{ii,t-1}$	0,129046	0,092213	0,0064 [‡]	0,0010 [‡]	-0,095978	-0,038278
$\beta_{ii,t-2}$	-0,131728	-0,044310	0,0144 [†]	0,1649	0,067235	-0,090809
$\beta_{ii,t-3}$	0,039436	-0,022236	0,3981	0,4522	-0,029216	-0,132008
$\beta_{ij,t-1}$	-0,120865	0,011882	0 [‡]	0,7953	-0,129982	-0,108712
$\beta_{ij,t-2}$	-0,007148	-0,026136	0,7397	0,5733	0,066976	-0,161348
$\beta_{ij,t-3}$	-0,009411	-0,035234	0,6064	0,4176	-0,003156	-0,167685

Os símbolos †, ‡ e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os p-valores são calculados com erros padrão robustos de Newey-West (HAC).

câmbio, embora a magnitude dessa transmissão seja aproximadamente igual para ambos os subperíodos.

Quanto aos retornos do IBrX, apontamos duas observações interessantes. Embora não haja transmissão na média do câmbio para o mercado acionário, o primeiro subperíodo apresenta correlação de primeira ordem positiva e significativa nos retornos, indicando a presença de um efeito *momentum*. Por outro lado, o segundo subperíodo apresenta correlação de terceira ordem significativa e negativa, indicando uma tendência de reversão à média. Esse resultado pode ser um efeito da crise nas observações, que induz a uma reação exagerada dos agentes em um primeiro momento, mas uma tendência de reversão à média após alguns períodos.

A Tabela 2.6 apresenta os resultados da estimação do modelo $DCC-GARCH(1,1)$ para os dois subperíodos considerados. Os resultados são semelhantes aos reportados na Tabela 2.4, onde apenas o coeficiente cruzado \mathbf{B}_{21} é significativo. Para o primeiro subperíodo, os valores dos coeficientes \mathbf{B}_{21} e \mathbf{B}_{22} são 0,156083 e 0,538147, respectivamente, indicando que menor parcela da volatilidade do mercado acionário é explicada pela volatilidade passada do câmbio. Para o segundo subperíodo, \mathbf{B}_{21} e \mathbf{B}_{22} são respectivamente 0,786044 e 0,661369, ou seja, no período que inclui a crise do *subprime*, a persistência da volatilidade do mercado acionário explica menos este processo do que as transmissões de volatilidade do mercado cambial para o acionário.

Tabela 2.6: Modelo DCC-GARCH(1,1) bivariado com dois subperíodos

Coeficientes	Subperíodo de 1999 a 2005		Subperíodo de 2006 a 2011	
	Valor estimado	Razão-t	Valor estimado	Razão-t
$\mathbf{a}_{0,11}$	0,000001	0,0004	0,000001	0,0016
$\mathbf{a}_{0,21}$	0,000074	0,0027	0,000013	0,0003
\mathbf{A}_{11}	0,184911	34,5123 [†]	0,159878	34,1214 [†]
\mathbf{A}_{12}	0,002085	0,0942	0,002478	0,9413
\mathbf{A}_{21}	0,000282	0,0096	0,005458	0,9706
\mathbf{A}_{22}	0,108556	3855,24 [‡]	0,114826	14848,80 [‡]
\mathbf{B}_{11}	0,783393	16,5132 [‡]	0,634222	7,2399 [‡]
\mathbf{B}_{12}	0,008988	0,0882	0,047925	0,1121
\mathbf{B}_{21}	0,156083	4,1542 [‡]	0,786044	21,2097 [‡]
\mathbf{B}_{22}	0,538147	3,4852 [‡]	0,661369	5,9602 [‡]
α	0,004570	0,5544	0,014930	0,9026
β	0,961201	10,1723 [‡]	0,961912	20,29970 [‡]

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Estes resultados nos indicam que a crise do *subprime* aumentou as transmissões entre os dois mercados, a ponto da volatilidade passada do mercado cambial explicar a maior parte da volatilidade no mercado acionário. Duas são as possíveis causas

para este efeito. Primeiro, a amostra do segundo subperíodo possui volatilidades consideravelmente maiores em ambos os mercados, potencializando as transmissões. Segundo, este fato pode refletir o grau de incerteza em relação ao país durante a época, aumentando a entrada e saída de divisas.

2.4.2 Assimetria na transmissão de volatilidade

Para verificar se choques negativos possuem maior influência do que choques positivos na transmissão da volatilidade, apresentamos os resultados da estimação do modelo DCC-EGARCH(1,1) na Tabela 2.7. Novamente observamos a persistência do processo de correlação entre os mercados devido à significância do coeficiente β . Os coeficientes α_{11} e α_{22} indicam persistência dos choques em ambos os mercados, enquanto a significância de γ_1 e γ_2 indicam a persistência da volatilidade. O coeficiente cruzado α_{21} é significativo ao nível de 1%, enquanto que α_{12} é significativo apenas ao nível de 10%, sendo baixo em magnitude (0,030077). Estes fatos corroboram os resultados do modelo anterior, de que apenas os choques do mercado cambial influenciam a volatilidade no mercado acionário.

Tabela 2.7: Modelo DCC-EGARCH(1,1) bivariado

Coeficientes	Valor estimado	Erro padrão	Razão-t
ω_1	-0,430709	0,058197	-7,4009 [‡]
ω_2	-0,402231	0,060554	-6,6425 [‡]
α_{11}	0,248524	0,019930	12,4700 [‡]
α_{12}	0,030077	0,016409	1,8329*
α_{21}	0,060019	0,016074	3,7340 [‡]
α_{22}	0,154889	0,017112	9,0513 [‡]
γ_1	0,955109	0,005984	159,5979 [‡]
γ_2	0,951014	0,007319	129,9355 [‡]
δ_1	0,373961	0,049736	7,5190 [‡]
δ_2	-0,497488	0,084455	-5,8905 [‡]
α	0,008934	0,012813	0,6973
β	0,986768	0,021894	45,0702 [‡]

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Quanto à assimetria, ambos os coeficientes δ_1 e δ_2 são significativos, mas apenas δ_2 é negativo, ou seja, choques negativos no mercado acionário têm maior influência na volatilidade do que choques positivos. Por outro lado, como δ_1 é positivo, depreciações do Real afetam mais a volatilidade tanto no mercado cambial quanto

no mercado acionário. A importância relativa da assimetria é de 0,46 no mercado cambial e 2,98 no acionário, indicando que retornos se comportam de maneira mais assimétrica do que variações da taxa de câmbio.

2.4.3 Assimetria na correlação condicional

Como podemos observar nas Tabelas 2.4 e 2.7, o processo de correlação entre variações da taxa de câmbio e retornos acionários é altamente persistente. Resta verificar se este processo é assimétrico, ou seja, se a correlação entre os mercados é maior quando ambos os choques são negativos. Para isso, estimamos o modelo ADCC-EGARCH(1,1), onde os valores da variância condicional do modelo da seção anterior são carregados na função log-verossimilhança do componente de correlação, dada pela equação (2.9). A Tabela 2.8 mostra os resultados para a dinâmica da correlação condicional.

Tabela 2.8: Modelo ADCC-EGARCH(1,1) bivariado

Coeficientes	Valor estimado	Erro padrão	Razão-t
α	0,097730	0,018992	5,1457 [‡]
β	0,993166	0,003081	322,3051 [‡]
γ	-0,070078	0,029515	-2,3743 [†]

Os símbolos [‡], [†] e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

O coeficiente γ é negativo e significativo ao nível de 5%, indicando que choques positivos em ambos os mercados afetam mais a correlação entre as variáveis. Assim, apesar de retornos acionários negativos potencializarem as transmissões de volatilidade devido ao valor negativo do coeficiente δ_2 na Tabela 2.7, depreciações do câmbio tendem a aumentar a correlação entre esses mercados mais do que retornos acionários negativos. Esse resultado é coerente com o fato de que o mercado cambial impacta mais nas transmissões de volatilidade.

2.4.4 Causalidade não linear

Alguns artigos exploraram a causalidade não linear entre mercados cambiais e o setor real da economia (Ma e Kanas, 2000; Kumar, 2009). No Brasil, utilizando

dados do Ibovespa de 1994 a 2002, Tabak (2006) encontrou evidências de causalidade não linear do mercado cambial para o acionário que não derivam de transmissões de volatilidade. Logo, as evidências mostram que apenas parte da causalidade entre o mercado cambial e acionário brasileiro é explicada neste capítulo.

Alguns trabalhos mais recentes desenvolveram métodos econométricos para estimar a relação de causalidade não linear entre mercados. Corradi et al. (2012) desenvolveram testes não paramétricos de independência condicional sobre a hipótese de que os preços de ativos seguem um processo de volatilidade estocástica multivariado com saltos para investigar a não linearidade nas transmissões de volatilidade entre mercados acionários. No terceiro capítulo aplicamos um modelo univariado de heteroscedasticidade condicional com saltos para modelar a dinâmica da não linearidade no mercado cambial.

2.5 Conclusão

Este capítulo estudou a relação de causalidade na média e na volatilidade existente entre os mercados cambial e acionário brasileiros. Para a análise dos primeiros momentos foi estimado um modelo vetorial autorregressivo com o intuito de verificar a existência de causalidade em ambos os sentidos. Concluimos que as variações da taxa de câmbio são influenciadas pelos retornos no mercado acionário na primeira defasagem, e estes apresentam persistência na terceira defasagem. Esses resultados indicam que o mercado acionário lidera o mercado cambial nos primeiros momentos, corroborando os modelos do tipo *stock-oriented*.

Para a análise dos segundos momentos foram estimados modelos bivariados com heteroscedasticidade condicional, DCC-GARCH(1,1), DCC-EGARCH(1,1) e ADCC-EGARCH(1,1), onde a matriz de correlação condicional segue a especificação de Engle (2002) (DCC) e Cappiello et al. (2006) (ADCC). Há evidências de transmissão de volatilidade do mercado cambial para o mercado acionário, sendo que depreciações no câmbio e retornos negativos impactam mais as volatilidades. Por fim, o processo de correlação condicional entre os mercados apresenta forte persistência, sendo maior quando há depreciações no câmbio.

Esses resultados diferem dos encontrados para países desenvolvidos, mas são semelhantes às evidências para países emergentes. Aparentemente, o mercado cambial acaba liderando a transmissão de volatilidade, devido ao peso do investimento externo e a influência da volatilidade cambial nos resultados das empresas de capital

aberto. Por outro lado, a relação inversa de causalidade não ocorre, pois investidores externos tendem a permanecer no mercado de renda fixa após resgates de ativos em renda variável, não ocasionando movimentos no mercado de divisas.

Analisamos também os impactos da crise do *subprime* nas transmissões entre os dois mercados. Nos primeiros momentos não houve significativas mudanças nos parâmetros para os dois subperíodos analisados, com exceção do fato de os retornos diários do IBrX apresentarem tendência de aversão à média no período de 1999 a 2005 e reversão à média no período de 2006 a 2011. Para a transmissão de volatilidade, observamos um aumento significativo da importância dos movimentos do mercado cambial no mercado acionário durante o subperíodo que inclui a crise. Isso pode ser resultado da maior volatilidade em ambos os mercados neste período, ou do aumento do grau de incerteza no país, impactando na entrada e saída de divisas.

O estudo contribui para a literatura empírica de finanças trazendo importantes resultados sobre a interação entre os mercados cambial e acionário brasileiros. Em modelos de previsão de volatilidade de ações, há de se levar em consideração a volatilidade do mercado cambial, podendo assim potencializar os resultados obtidos. Tais modelos dão subsídio para a tomada de decisões e administração de risco de portfólios. Por outro lado, as interligações entre os dois mercados devem ser levadas em conta por formuladores de políticas, visto que interferências no câmbio podem levar a consequências no mercado acionário.

Como discutido na seção 2.4.4, uma das limitações dos resultados apresentados é que os modelos utilizados neste capítulo não captam outras relações não lineares entre os dois mercados que não são resultado de transmissão de volatilidade. Algumas dessas relações serão modeladas para a taxa de câmbio no terceiro capítulo através de um modelo com saltos. Um tópico interessante para futura pesquisa seria estimar um modelo multivariado com saltos para captar uma maior parte dessa causalidade não linear entre os mercados cambial e acionário.

Capítulo 3

Relações entre correlação serial e volatilidade: existe o efeito LeBaron no Brasil?

Este capítulo examina a relação entre correlação serial e volatilidade nos retornos do índice Ibovespa. Para a estimação da volatilidade, utilizamos um modelo autor-regressivo generalizado exponencial com heteroscedasticidade condicional, e para o cálculo da correlação serial, uma estatística de razão de variância onde a defasagem é calculada endogenamente. Os resultados demonstram que (i) a volatilidade é negativamente relacionada à correlação serial para retornos semanais, (ii) essa relação negativa está presente nos retornos diários apenas se utilizarmos correlação serial de primeira ordem, (iii) momentos de maior volatilidade aumentam a ineficiência na precificação dos ativos que compõem o índice, e (iv) a crise do *subprime* não intensificou esse efeito para retornos semanais, mas produziu uma relação positiva entre volatilidade e correlação serial para retornos diários.

3.1 Introdução

O estudo das propriedades estatísticas das séries temporais financeiras leva à conclusão de que entre as principais variáveis que definem o comportamento dos retornos acionários estão a correlação serial e a volatilidade, sendo ambas extensivamente examinadas na literatura (Fama e French, 1988; Chordia et al., 2008; Campbell e Hentschel, 1992; Ang et al., 2006).

Em um mercado com eficiência informacional, as mudanças de preços não podem ser previstas, sendo que os preços dos ativos comportam-se como um passeio aleatório, onde a melhor previsão possível é a observação imediatamente anterior (Samuelson, 1965). Nesse caso, podemos demonstrar que os retornos são serialmente não correlacionados. Logo, a correlação serial é uma medida de extrema importância para mensurar a eficiência e a possibilidade de arbitragem em mercados financeiros.

Como a literatura tem demonstrado, retornos acionários tendem a ser pouco previsíveis devido ao fato de apresentarem baixo grau de correlação serial (Pesaran e Timmermann, 1995). Entretanto, a variância condicional dos retornos, ou volatilidade, é altamente previsível, sendo caracterizada pela persistência e por sua distribuição apresentar caudas longas (Engle, 1982; Liu et al., 1999). Esse fato faz com que a estimação e a previsão da volatilidade sejam instrumentos essenciais para o gerenciamento de risco de portfólios de ativos.

O estudo da relação entre correlação serial e volatilidade pode iluminar a questão da influência da volatilidade no mecanismo de formação de preços. A estimação da correlação serial impõe dificuldades para essa análise devido ao fato de necessitarmos de observações com a mesma frequência da estimativa da volatilidade. Por isso talvez esse tema não tenha sido tão frequente na literatura, sendo LeBaron (1992) quem primeiramente encontrou uma relação sólida entre essas variáveis, concluindo que as previsões de volatilidade são negativamente relacionadas à correlação serial.

Este capítulo investiga a ligação entre essas variáveis para o mercado acionário brasileiro utilizando retornos do índice Ibovespa. Para a estimação da volatilidade utilizamos um modelo autorregressivo generalizado exponencial com heteroscedasticidade condicional, amplamente aplicado para modelar a variância condicional de ativos financeiros (Nelson, 1991). Para construir uma medida de correlação serial utilizamos uma estatística de razão de variância onde a defasagem é calculada endogenamente. Uma vez obtidas as estimativas, analisamos a relação entre elas com o intuito de responder as seguintes perguntas: 1) A volatilidade afeta significativamente a correlação serial dos retornos do Ibovespa? 2) Há alguma relação entre volatilidade e eficiência no mercado acionário brasileiro? 3) Quais os efeitos da crise

do *subprime* nessas relações?

O capítulo aborda um tema ainda não estudado pela literatura no Brasil, contribuindo para o entendimento do mecanismo de formação de preços no mercado acionário. Os resultados têm importantes implicações práticas para o gerenciamento de risco de carteiras de ativos, podendo auxiliar na identificação de padrões de previsibilidade através de estratégias que explorem a relação entre as duas medidas estatísticas estudadas. Do ponto de vista metodológico, propomos novos métodos para estimar a correlação serial, além de modelos econométricos para estudar a relação dessa variável com a volatilidade.

3.2 Revisão de literatura

A literatura sobre o comportamento de retornos de ativos em mercados financeiros tem explorado tópicos como reversão à média (Lehmann, 1990; Ferreira e Santa-Clara, 2011), efeito calendário (French, 1980; Doyle e Chen, 2009), heteroscedasticidade condicional (Nelson, 1991; Silvennoinen e Teräsvirta, 2009), estatísticas de razão de variância (Lo e MacKinlay, 1988; Kim, 2009), não-linearidades (Scheinkman e LeBaron, 1989; Corradi et al., 2012), entre outros. Em geral, mercados emergentes tendem a apresentar possibilidades de arbitragem de ganhos maiores do que em mercados desenvolvidos, podendo ser encontradas algumas evidências mais fortes de previsibilidade (Chang et al., 2004).

O principal indicativo da possibilidade de previsão é a existência de correlação serial dos retornos. Para testar essa hipótese, foram construídas estatísticas que exploram algumas propriedades básicas de um passeio aleatório, como razões de variância e testes de Portmanteau. O teste de razão de variância inicialmente proposto por Lo e MacKinlay (1988) e Cochrane (1988) sofreu diversas mudanças com o intuito de melhorar sua potência e poder perante amostras pequenas (Chen e Deo, 2006) e automatizar o processo de escolha das defasagens (Choi, 1999). O mesmo ocorreu com testes de Portmanteau, mais especificamente o teste de autocorrelação de Ljung-Box (Escanciano e Lobato, 2009).

Modelos com heteroscedasticidade condicional surgiram com os trabalhos de Engle (1982) e Bollerslev (1986) com o intuito de explicar a aglomeração dos retornos em torno de algumas poucas observações mais significativas. Uma série de aprimoramentos nos modelos iniciais foram propostos, como os modelos EGARCH (Nelson, 1991), GJR-GARCH (Glosten et al., 1993), TGARCH (Zakoian, 1994), modelos de

mudança de regime (Cai, 1994; Hamilton e Susmel, 1994), entre outros. A volatilidade, medida como a variância condicional, passou a ser vista como um processo altamente autorregressivo e com aglomerações.

A relação entre volatilidade e retornos acionários tem sido objeto de investigação na literatura especializada (Ang et al., 2006), sendo a ligação com a correlação serial primeiramente abordada no modelo de *feedback trading* proposto por Sentana e Wadhvani (1992). Nesse modelo existem dois tipos de investidores: *mean-variance traders* e *feedback traders*. A função de demanda do segundo tipo de investidor é relacionada a retornos passados, sendo ela crescente se os investidores seguem uma estratégia de *feedback* positivo, ou *momentum* (investindo em ações com bons rendimentos passados), e decrescente se eles adotam uma estratégia de *feedback* negativo, ou *contrarian* (investem em ações com baixos retornos no passado). Sentana e Wadhvani (1992) mostraram que no equilíbrio, a correlação serial é uma função decrescente (crescente) da volatilidade se os investidores seguem uma estratégia de *momentum* (*contrarian*).

Na literatura empírica, LeBaron (1992) foi quem primeiro estudou a ligação entre essas variáveis para retornos diários e semanais do mercado acionário nos Estados Unidos. Ele encontrou uma relação negativa entre correlação serial e volatilidade utilizando um modelo autorregressivo exponencial em conjunto com um modelo GARCH para estimação dos retornos (EAR-GARCH), dando suporte empírico ao modelo de *feedback trading*. Sentana e Wadhvani (1992) encontraram resultados semelhantes para dados diários de índices agregados nos Estados Unidos. Koutmos (1997) estendeu esses resultados para outros mercados de países desenvolvidos utilizando uma metodologia similar a de LeBaron. Em trabalhos mais recentes, Venetis e Peel (2005) encontraram relação negativa entre volatilidade e correlação serial em três mercados internacionais, enquanto Chang (2009), utilizando dados a partir de 1998, observou o mesmo resultado entre essas variáveis em Taiwan. Para dados intradiários, Bianco et al. (2009) confirmaram o efeito encontrado por LeBaron, apesar de relatarem uma relação positiva da correlação serial com a volatilidade não esperada.

A literatura brasileira ainda carece de estudos que complementem o conhecimento sobre as relações existentes nas variáveis do mercado financeiro. Mais especificamente, a relação entre volatilidade e correlação serial no mercado acionário brasileiro é ainda desconhecida, motivando a pesquisa na área.

3.3 Metodologia

Na primeira parte desta seção descrevemos os dados amostrais utilizados em ambas as frequências diária e semanal. Na segunda e terceira parte desenvolvemos as estatísticas utilizadas para estimar a correlação serial e a volatilidade dos retornos. Na quarta, quinta e sexta partes apresentamos os modelos utilizados para mensurar a relação existente entre essas variáveis.

3.3.1 Dados

Utilizamos o índice Ibovespa nominal nas frequências diária e semanal durante o período de fevereiro de 1999 a dezembro de 2011. A escolha do Ibovespa deve-se ao fato de ele ser o mais importante indicador do desempenho médio das cotações do mercado de ações brasileiro. O período de janeiro de 1999 coincide com a flexibilização da política cambial no Brasil, causando distorções no comportamento do mercado acionário. Por isso foram retirados períodos anteriores a fevereiro de 1999. A inclusão da frequência semanal deve-se ao fato de retornos diários muitas vezes apresentarem altos níveis de ruídos que podem influenciar na análise dos dados. Ao todo são 3.184 observações diárias e 674 semanais.

Os retornos acionários são calculados como:

$$R_t = \ln(P_t/P_{t-1}) = \ln(P_t) - \ln(P_{t-1}), \quad (3.1)$$

onde P_t é o valor do índice Ibovespa no tempo t e \ln é o logaritmo natural. Na Tabela 3.1 apresentamos as estatísticas descritivas para os retornos diários e semanais do Ibovespa.

Os retornos nas frequências diária e semanal apresentam média positiva mas próxima de zero. A distribuição dos retornos observados é diferente da normal, sendo negativamente enviesada e leptocúrtica, devido à assimetria negativa e ao excesso de curtose. O teste de Ljung-Box não rejeita a hipótese nula de que os retornos diários não são autocorrelacionados ao nível de 5% de significância, enquanto que para os retornos semanais a hipótese nula é rejeitada ao nível de 1% de significância. Ambas as séries têm comportamento estacionário, pois o teste de Phillips-Perron rejeita a hipótese nula de raiz unitária para retornos diários e semanais. Como indicativo da presença de heteroscedasticidade condicional, os quadrados dos retornos rejeitam a

Tabela 3.1: Estatísticas descritivas dos retornos do Ibovespa

	Retornos diários	Retornos semanais
Média	0,00061	0,00287
Desvio-padrão	0,01962	0,04186
$LB(10)$	18,32*	22,57 [†]
$LB^2(10)$	1499,01 [‡]	129,02 [‡]
Phillips-Perron	-56,9382 [‡]	-28,3772 [‡]
Assimetria	-0,099	-0,535
Curtose (Exc.)	3,657	2,842
Jarque-Bera	1780,07 [‡]	259,07 [‡]

Os símbolos [‡], [†] e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

hipótese nula do teste de Ljung-Box em ambas as frequências.

3.3.2 Razão de variância

Um mercado é eficiente na forma fraca se mudanças de preços não podem ser previstas utilizando-se os preços passados. Estatisticamente, essa definição é incorporada em modelos de passeio aleatório, onde a série temporal $\{p_t\}_{t=1}^T$ segue a dinâmica:

$$p_t = \mu + p_{t-1} + \varepsilon_t, \quad (3.2)$$

onde μ é a média do processo e ε_t um ruído branco não necessariamente normal, que satisfaz $E[\varepsilon_t] = 0$, $E[\varepsilon_t^2] = \sigma^2$ e $E[\varepsilon_t \varepsilon_\tau] = 0$ para todo $t \neq \tau$.

Logo, se o logaritmo natural dos preços seguir um passeio aleatório, os retornos definidos em (3.1) serão serialmente não correlacionados. Lo e MacKinlay (1988) e Cochrane (1988) demonstraram que nesse caso, a variância dos retornos deve ser uma função linear da defasagem em que eles são calculados, de modo que $Var(p_t - p_{t-k}) = k \times Var(p_t - p_{t-1})$. Com isso, define-se a razão de variância de um passeio aleatório como:

$$VR(k) = \frac{var(r_t(k))/k}{var(r_t)} = 1, \quad \forall k = 1, 2, \dots, T-1. \quad (3.3)$$

Quando a razão de variância for menor (maior) que um, o processo apresenta reversão (aversão) à média. Por outro lado, quanto maior for o valor de $|VR(k) - 1|$, mais serialmente correlacionado será o processo.

O valor da estimativa de $VR(k)$ depende da defasagem k utilizada, sendo co-

num na literatura a escolha arbitrária desse coeficiente. Com o intuito de facilitar o cálculo das razões de variância, optamos por uma estimação que escolhe endogenamente o valor da defasagem de acordo com o método para escolha ótima de valores de truncagem desenvolvido por Andrews (1991).

Para a construção desta estatística, utilizamos o fato demonstrado por Cochrane (1988) de que o estimador usual de razão de variância é assintoticamente equivalente a 2π vezes o estimador da densidade espectral normalizada na frequência zero, que usa o núcleo de Bartlett. Assim,

$$\hat{V}R(k) \cong 1 + 2 \sum_{i=1}^{k-1} \frac{(k-i)}{k} \hat{\rho}_i \sim 2\pi \frac{f_{\Delta y}(0)}{\hat{\sigma}^2}. \quad (3.4)$$

Conforme Choi (1999), utilizamos o núcleo espectral quadrático na estimação por apresentar propriedades ótimas¹. Obtem-se então a seguinte estimativa da razão de variância:

$$\hat{V}R(k) = 1 + 2 \sum_{i=1}^{T-1} m(i/k) \hat{\rho}(i), \text{ onde} \quad (3.5)$$

$$m(x) = \frac{25}{12\pi^2 x^2} \left[\frac{\sin(6\pi/5)}{6\pi x/5} - \cos(6\pi x/5) \right], \text{ e} \quad (3.6)$$

$$\hat{\rho}(i) = \frac{\sum_{t=1}^{T-i} (r_t - \hat{\mu})(r_{t+i} - \hat{\mu})}{\sum_{t=1}^T (r_t - \hat{\mu})^2}, \quad (3.7)$$

onde $\hat{\mu} = T^{-1} \sum_{t=1}^T r_t$ é a média amostral de r_t , $\hat{\rho}(i)$ é o i -ésimo coeficiente de correlação amostral de r_t , e $m(x)$ é o núcleo espectral quadrático. O valor do coeficiente de defasagem k é escolhido conforme Andrews (1991):

$$\hat{k} = 1.3221(\hat{\alpha}(2)T)^{1/5}, \quad (3.8)$$

onde $\hat{\alpha}(2)$, no caso de um passeio aleatório, é reduzido a²:

$$\hat{\alpha}(2) = \frac{4\hat{\rho}(1)^2}{(1 - \hat{\rho}(1))^4}, \quad (3.9)$$

onde $\hat{\rho}(1)$ é o coeficiente de autocorrelação de primeira ordem de r_t .

A razão de variância descrita em (3.5) apresenta propriedades ótimas para estimação de dados com heteroscedasticidade condicional e não normalidade, sendo

¹ Andrews (1991) demonstra que o núcleo espectral quadrático é ótimo para estimar a densidade espectral na frequência zero.

²Para maiores detalhes, ver equação 6.4 de Andrews (1991).

utilizada para testar a correlação serial de ativos financeiros em artigos recentes (Kim, 2009).

A dificuldade em investigar a relação entre correlação serial e volatilidade consiste em construir uma medida de correlação serial para cada instante t . Alguns trabalhos utilizaram dados intradiários para obter estimativas da correlação serial na frequência diária (Bianco et al., 2009). Para dados do mercado acionário brasileiro, essa solução não é viável dada a dificuldade em se obter dados intradiários confiáveis que abranjam o período de fevereiro de 1999 a dezembro de 2011. Uma das razões para a adoção da razão de variância como estimativa de correlação serial é contornar esse problema, dada a possibilidade de utilizarmos observações sobrepostas na estimativa.

Tendo isso em vista, construímos estimativas da razão de variância dada em (3.5) para cada bloco sobreposto de 100 observações. A perda das observações iniciais para a construção da primeira estimativa da razão de variância não é significativa para a totalidade da amostra. Por outro lado, 100 é um número razoável de observações para estimação dessa estatística (Kim, 2009), fazendo com que a influência exercida pela observação atual no tempo t seja ainda relevante.

3.3.3 Volatilidade

Para estimação da volatilidade utilizamos um modelo exponencial generalizado autorregressivo com heteroscedasticidade condicional (EGARCH) proposto por Nelson (1991) e amplamente utilizado para modelar a variância condicional de retornos em mercados financeiros. Em modelos do tipo ARCH, a volatilidade é estimada como um processo autorregressivo, sendo que no modelo exponencial a transformação logarítmica relaxa a restrição de não-negatividade aos coeficientes.

No modelo EGARCH(1,1) adotado, a série de retornos $\{r_t\}_{t=1}^T$ é estimada como:

$$r_t = \mu + \varepsilon_t, \text{ com } \varepsilon_t | I_{t-1} \sim GED(0, h_t, \nu), \text{ e}$$

$$\ln(h_t) = \omega + \alpha \left(\left| \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \right| - E \left[\left| \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} \right| \right] \right) + \gamma \frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}} + \beta \ln(h_{t-1}), \quad (3.10)$$

onde μ é a média dos retornos, I_{t-1} é o conjunto informacional até o tempo $t - 1$ e ε_t é o resíduo do modelo, que segue a distribuição de erros generalizada. Na equação (3.10), o termo $\frac{\varepsilon_{t-1}}{\sqrt{h_{t-1}}}$ corresponde ao resíduo padronizado do modelo, ω define a média do processo h_t , e β mede a persistência da variância condicional. Os

coeficientes α e γ capturam o efeito tamanho e o efeito sinal, respectivamente. O primeiro mede o aumento da volatilidade causado pelo choque, independentemente da direção do mesmo. O segundo mede a assimetria dos choques na volatilidade, sendo que choques negativos terão importância maior que choques positivos caso este coeficiente seja estatisticamente significativo e menor que zero.

A importância relativa da assimetria para o conjunto dos dados é estimada pelo termo $|-1 + \gamma|/(1 + \gamma)$. Quanto mais negativo for o coeficiente γ , maior será essa razão, indicando que choques negativos têm maiores impactos na volatilidade.

Tendo em vista o excesso de curtose presente nos retornos, conforme indica a Tabela 3.1, utilizamos a distribuição de erros generalizada $GED(0, h_t, v)$ para o resíduo ε_t do modelo descrito em (3.10), sendo v o parâmetro que mede a espessura da cauda da distribuição. A densidade da distribuição GED com média zero e variância unitária é descrita por:

$$f(\varepsilon; v) = \frac{v \exp[-(1/2)|\varepsilon/\lambda|^v]}{\lambda 2^{(1+1/v)} \Gamma(1/v)} \text{ com } -\infty < \varepsilon < \infty, 0 < v < \infty, \quad (3.11)$$

onde $\Gamma(\cdot)$ é a função gama e $\lambda = [2^{(-2/v)} \Gamma(1/v) / \Gamma(3/v)]^{1/2}$. Quando $v = 2$ obtemos a distribuição normal, quando $v < 2$ a distribuição apresenta caudas mais espessas do que a normal, e se $v = 1$, ela se equivalerá à distribuição de Laplace.

Para estimar os parâmetros devemos maximizar a função de log-verossimilhança do modelo:

$$L_t = \ln \left(\frac{v}{\lambda} \right) - 0,5 \left| \frac{\varepsilon_t}{h_t^{1/2} \lambda} \right|^v - \left(1 + \frac{1}{v} \right) \ln 2 - \ln \Gamma \left(\frac{1}{v} \right). \quad (3.12)$$

Os coeficientes que maximizam a função acima são os parâmetros estimados do modelo, calculados através de métodos numéricos recursivos (algoritmo BFGS - Broyden-Fletcher-Goldfarb-Shanno). São utilizados erros padrão robustos de White (1982), comumente aplicados na estimação de modelos GARCH para correção da heteroscedasticidade presente nos resíduos.

3.3.4 Modelo autorregressivo com variável exógena

Uma vez obtidas as estimativas para a correlação serial e a volatilidade, podemos utilizá-las para mensurar as relações existentes entre essas variáveis. Como o objetivo do capítulo é verificar se a volatilidade exerce algum tipo de influência na

correlação serial existente no mercado acionário brasileiro, utilizamos regressões onde a variável dependente é a razão de variância e a variável explicativa é a volatilidade.

A série das razões de variância, como será demonstrado, apresenta alto grau de persistência devido à utilização de observações sobrepostas e pela peculiaridade dessa estatística. Assim, devemos remover a influência das observações anteriores incluindo coeficientes autorregressivos. Utilizamos para isso um modelo autorregressivo com variável exógena, ARX(p), dado por:

$$VR(k)_t = \alpha_0 + \sum_{i=1}^p \alpha_i VR(k)_{t-i} + \beta h_t + \varepsilon_t, \quad (3.13)$$

onde os coeficientes α_i medem a persistência da razão de variância, β a relação entre correlação serial e volatilidade, e ε_t corresponde aos resíduos do modelo, que seguem uma distribuição normal com média zero e variância σ^2 .

A estimação é realizada pelo método da máxima verossimilhança exata, através da maximização da função de log-verossimilhança:

$$L_t = -0,5T \ln(2\pi) - 0,5T \ln(\sigma^2) - 0,5 \sum_{t=1}^T \left[\frac{\varepsilon_t^2}{\sigma^2} \right]. \quad (3.14)$$

Neste modelo são utilizados erros padrão de Newey-West por serem robustos na presença de heteroscedasticidade, propriedade característica de dados financeiros. O valor da defasagem p é escolhido com base nos critérios de informação de Akaike e Hannan-Quinn, descritos respectivamente por:

$$AIC = \left(\frac{2T}{T - k - 1} \right) k - 2 \ln(L_{max}), \text{ e} \quad (3.15)$$

$$HQC = 2 \ln(\ln(T))k - 2 \ln(L_{max}), \quad (3.16)$$

onde T é o tamanho da amostra, k é o número de parâmetros a serem estimados e L_{max} é o valor máximo da função de log-verossimilhança encontrado na etapa da estimação.

O critério de informação Bayesiano não foi utilizado pois penaliza modelos com número elevado de coeficientes, podendo selecionar modelos que não eliminem completamente a persistência das razões de variância. Para contornar o problema do excesso de parâmetros, definimos o grau máximo de defasagens como cinco. A análise dos critérios de informação e seleção das defasagens é realizada na seção 3.4, bem como o cálculo dos coeficientes para as regressões estimadas.

3.3.5 Modelo com inclusão de *dummy* para a crise

Para avaliarmos o impacto da crise do *subprime* de 2008 na relação entre volatilidade e correlação serial, incluímos *dummies* de intercepto e de declividade no modelo exposto na seção anterior. Assim, temos a seguinte regressão:

$$VR(k)_t = \alpha_0 + \sum_{i=1}^p \alpha_i VR(k)_{t-i} + \beta h_t + \delta_1 D_t + \delta_2 D_t h_t + \varepsilon_t, \quad (3.17)$$

onde os parâmetros δ_1 e δ_2 são os coeficientes das *dummies* de intercepto e de declividade, respectivamente. A variável D_t possui valor um em períodos que correspondem a crise do *subprime*, e zero caso contrário.

Para definirmos o período que abrange o começo e o fim da crise, utilizamos a metodologia de Johnson e Mitton (2003) que se baseia em critérios subjetivos, dependendo de notícias e eventos políticos, econômicos e financeiros. Assim, o início da crise corresponderá ao mês de julho de 2008, dada a queda subsequente de mais de 40% no índice Ibovespa. A recuperação no valor do índice começou em abril de 2009, por isso definimos o mês de março de 2009 como o fim da crise.

3.3.6 Modelo EGARCH com efeito autocorrelação

Para estudar a influência da volatilidade na dinâmica dos retornos acionários e subsidiar os resultados obtidos com as regressões da seção anterior, estimamos um modelo AR(1)-EGARCH(1,1) onde o coeficiente autorregressivo é influenciado pela volatilidade:

$$r_t = \mu + \rho_1 h_t^{1/2} r_{t-1} + \varepsilon_t, \text{ com } \varepsilon_t | I_{t-1} \sim GED(0, h_t, \nu), \text{ e} \\ \ln(h_t) = \omega + \alpha \left(\left| \frac{\varepsilon_{t-1}}{\sqrt{h_t}} \right| - E \left[\left| \frac{\varepsilon_{t-1}}{\sqrt{h_t}} \right| \right] \right) + \gamma \frac{\varepsilon_{t-1}}{\sqrt{h_t}} + \beta \ln(h_{t-1}). \quad (3.18)$$

As variáveis são definidas conforme a seção 3.3.3, com exceção do coeficiente ρ_1 , que mede o impacto da volatilidade na autocorrelação de primeira ordem dos retornos. A estimação é conduzida de maneira semelhante ao modelo (3.10). Note que um valor negativo do coeficiente ρ_1 implica na existência do efeito LeBaron, dando suporte ao modelo de *feedback trading* de Sentana e Wadhvani (1992).

3.4 Resultados

Para analisarmos a relação entre correlação serial e volatilidade, primeiro construímos as razões de variância (VR) dadas pela equação (3.5). A Figura 3.1 mostra o comportamento dessa estatística com dados diários utilizando observações sobrepostas de 100 períodos. Duas características são peculiares, a concentração dos valores em torno de um e uma alta persistência dos valores passados.




Figura 3.1: Razões de variância diárias com 100 observações sobrepostas.

Na Figura 3.2 podemos observar que o comportamento das razões de variância utilizando dados semanais difere substancialmente da mesma estatística com dados diários, devido à maior presença de valores abaixo de um. Isso é reflexo da autocorrelação presente nos retornos semanais, como indica a Tabela 3.1, mostrando uma tendência de reversão à média em retornos com essa frequência. O componente autorregressivo nas razões de variância ainda continua visível, entretanto os movimentos são mais suaves do que na série diária.

As estatísticas descritivas das razões de variância para ambas as frequências estão resumidas no Painel A da Tabela 3.2. Elas confirmam alguns dos fatos ilustrados pelas Figuras 3.1 e 3.2. Na frequência diária, as razões de variância têm média aproximadamente um, apresentam autocorrelação devido à rejeição da hipótese nula do teste de Ljung-Box, e distanciam-se da distribuição normal, com excesso de curtose e enviesamento positivo. Na frequência semanal, a média é menor que um e a




Figura 3.2: Razões de variância semanais com 100 observações sobrepostas.

série é autocorrelacionada mas próxima da distribuição normal. O Painel B indica o grau ótimo de defasagem autorregressiva para ambas as séries de acordo com os critérios de Akaike e Hannan-Quinn. Devemos incluir cinco defasagens das razões de variância diárias e semanais nas regressões para remover as influências de observações passadas.

Tabela 3.2: Estatísticas descritivas das razões de variância

Painel A: Estatísticas descritivas				
	VR diária		VR semanal	
Média	1,0055		0,8919	
Desvio-padrão	0,0978		0,0656	
$LB(10)$	24208,04 [‡]		2849,23 [‡]	
Assimetria	0,6812		-0,1904	
Curtose (Exc.)	1,5847		-0,2171	
Jarque-Bera	561,427 [‡]		4,604	
Painel B: Critérios de informação para defasagem AR				
Defasagens	Akaike	Hannan-Quinn	Akaike	Hannan-Quinn
1	-4,774922	-4,773514	-4,662729	-4,656779
2	-4,779276	-4,777165	-4,676132	-4,667208
3	-4,793615	-4,790801	-4,680009	-4,668111
4	-4,794669	-4,791151	-4,685990	-4,671117
5	-4,801143**	-4,796921**	-4,689137**	-4,671289**

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores indicados por ** são as defasagens escolhidas pelo respectivo critério.

Para estimação da volatilidade, utilizamos o modelo EGARCH(1,1) dado pela equação (3.10) e incluímos um componente autorregressivo nos retornos semanais para remover a autocorrelação indicada na Tabela 3.1. Os resultados da estimação estão na Tabela 3.3.

Tabela 3.3: Estimação da volatilidade para retornos diários e semanais

Painel A: Estimativa dos parâmetros				
	Retornos diários		Retornos semanais	
Coefficientes	Valor estimado	Razão t	Valor estimado	Razão t
μ	0,000726	2,5687 [†]	0,004507	2,7186 [‡]
ϕ_1	-	-	-0,080688	-2,3795 [†]
ω	-0,233655	-3,0807 [‡]	-0,342251	-2,2868 [†]
α	0,145044	6,4761 [‡]	0,113377	2,9445 [‡]
β	0,971144	102,6579 [‡]	0,947764	40,7744 [‡]
γ	-0,076000	-4,3962 [‡]	-0,074743	-2,2931 [†]
ν	1,609744	26,2027 [‡]	1,549785	10,7981 [‡]
Painel B: Diagnósticos do modelo				
	Retornos diários		Retornos semanais	
Testes	Valor	P-valor	Valor	P-valor
LB(15)	13,520	0,5622	12,920	0,5330
$LB^2(15)$	13,868	0,5356	8,214	0,8779

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente. São utilizados erros robustos baseados em White (1982).

Os retornos diários e semanais do Ibovespa apresentam assimetria, como indicado pelos coeficientes γ . Assim, choques negativos impactam mais a volatilidade do que choques positivos. A importância relativa da assimetria é mensurada pelo coeficiente $| -1 + \gamma | / (1 + \gamma)$, igual a 1,1645 para retornos diários e 1,1616 para retornos semanais. Em ambas as frequências, a variância condicional apresenta alta persistência, sendo as estimativas dos coeficientes β perto de um. Os valores estimados de ν são menores do que dois, caracterizando a presença de caudas mais espessas na distribuição dos resíduos. Por fim, o coeficiente ϕ_1 é negativo para retornos semanais, dando mais evidências da presença de reversão à média nessa frequência. Estes resultados são consistentes com as evidências da literatura para retornos acionários (Liu et al., 1999).

O Painel B da Tabela 3.3 mostra os valores das estatísticas de Ljung-Box para os resíduos e o quadrado dos resíduos dos modelos estimados. Podemos observar que para ambos os retornos diários e semanais, os modelos eliminam a autocorrelação e a heteroscedasticidade condicional, visto que o teste de Ljung-Box não rejeita a hipótese nula de que ambos os resíduos e o quadrado dos resíduos não são

autocorrelacionados.

As Figuras 3.3 e 3.4 mostram o comportamento da volatilidade diária e semanal estimadas pelos modelos EGARCH(1,1) e AR(1)-EGARCH(1,1), respectivamente. Verifica-se a ocorrência de observações significativas em torno de períodos críticos do mercado acionário brasileiro, como o estouro da bolha da Internet em 2000, as eleições de 2002 e a crise do *subprime* em 2008.




Figura 3.3: Volatilidade dos retornos diários.

Para estudar a relação entre correlação serial e volatilidade, utilizamos regressões onde a razão de variância é a variável dependente e a variância condicional é a variável explicativa. Na próxima página, vemos que a regressão 1 da Tabela 3.4 aponta para uma relação positiva entre essas variáveis na frequência diária, porém o modelo está mal especificado, devido ao alto grau de correlação dos resíduos, de acordo com o teste de Ljung-Box.

Para corrigir esse problema, estimamos o modelo ARX(p) descrito na equação (3.13), incluindo cinco defasagens das razões de variância, conforme os critérios de Akaike e Hannan-Quinn. A regressão 2 encontra uma relação negativa expressa pelo coeficiente β , entretanto, ela não é significativa para retornos diários.

Na terceira regressão, incluímos *dummies* de intercepto e declividade no modelo para estimar a influência da crise de 2008 na relação entre as variáveis. Vemos então que o coeficiente β passa a ser significativo ao nível de 10%, e aumenta muito em magnitude. Por outro lado, o coeficiente da *dummy* de declividade é positivo e significativo ao nível de 5%, sendo maior em módulo do que β .




Figura 3.4: Volatilidade dos retornos semanais.

Assim, a crise inverte o sinal da relação entre volatilidade e correlação serial para retornos diários. Esse fato é reflexo da correlação positiva existente entre retornos diários durante o momento da crise (efeito manada), fazendo com que a volatilidade esteja associada a razões de variância maiores (correlação serial positiva).

Tabela 3.4: Regressões da razão de variância com a volatilidade para retornos diários

Painel A: Estimativa dos parâmetros			
Coeficientes	Regressão 1	Regressão 2	Regressão 3
α_0	0,9922 (132,70 [‡])	0,0217 (4,31 [‡])	0,0222 (4,36 [‡])
α_1	-	1,0424 (24,46 [‡])	1,0397 (24,96 [‡])
α_2	-	-0,1960 (-3,13 [‡])	-0,1951 (-3,16 [‡])
α_3	-	0,0947 (3,00 [‡])	0,0957 (3,02 [‡])
α_4	-	-0,0467 (-1,59)	-0,0467 (-1,59)
α_5	-	0,0847 (3,82 [‡])	0,0871 (3,93 [‡])
β	36,2093 (2,59 [‡])	-1,9019 (-0,91)	-8,5297 (-1,95*)
δ_1	-	-	-0,0035 (-1,18)
δ_2	-	-	9,6412 (2,00 [†])
Painel B: Diagnósticos dos resíduos do modelo			
$LB(10)$	24003,45 [‡]	10,4550	10,2836
Jarque-Bera	204,87 [‡]	5604,32 [‡]	5364,57 [‡]
R^2 ajustado	0,0110	0,9498	0,9499

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores em parênteses são as razões t com erros robustos de Newey-West (HAC).

Os resultados encontrados na literatura advogam uma relação negativa entre as duas variáveis (LeBaron, 1992; Venetis e Peel, 2005). Para o caso brasileiro, os retornos diários do Ibovespa nos indicam que essa relação negativa existe mas é pouco significativa. Ao controlarmos para os efeitos da crise, encontramos um coeficiente β de maior magnitude e significância, indicando que a correlação serial positiva gerada em momentos críticos do mercado acionário tende a mitigar a relação negativa entre volatilidade e correlação serial. Para demonstrar se este é o caso, examinamos os dados na frequência semanal, onde encontramos menor prevalência de correlação serial positiva, conforme a Figura 3.2.

Para retornos semanais, o mesmo problema de má especificação ocorre na regressão 1 da Tabela 3.5, entretanto encontramos uma relação negativa e significativa entre correlação serial e volatilidade expressa pelo coeficiente β da regressão 2 ao incluir as defasagens das razões de variância.

Tabela 3.5: Regressões da razão de variância com a volatilidade para retornos semanais

Painel A: Estimativa dos parâmetros			
Coeficientes	Regressão 1	Regressão 2	Regressão 3
α_0	0,9081 (61,78 [‡])	0,0704 (3,85 [‡])	0,0645 (3,62 [‡])
α_1	-	1,0641 (13,41 [‡])	1,0668 (13,06 [‡])
α_2	-	-0,1993 (-1,69*)	-0,1979 (-1,68*)
α_3	-	-0,03235 (-0,67)	-0,0301 (-0,61)
α_4	-	0,1829 (1,51)	0,1817 (1,49)
α_5	-	-0,0880 (-0,95)	-0,0856 (-0,94)
β	-9,7989 (-1,23)	-3,4661 (-3,01 [‡])	-4,2660 (-2,90 [‡])
δ_1	-	-	0,0140 (0,86)
δ_2	-	-	-2,0031 (-0,54)
Painel B: Diagnósticos dos resíduos do modelo			
$LB(10)$	2701,56 [‡]	9,3169	10,0685
Jarque-Bera	2,67	510,19 [‡]	503,19 [‡]
R^2 ajustado	0,0134	0,8781	0,8783

Os símbolos [‡], [†] e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores em parênteses são as razões t com erros robustos de Newey-West (HAC).

Ao incluirmos as *dummies* para avaliar os efeitos da crise de 2008 não obtemos significância do parâmetro δ_2 , indicando que a crise não intensificou significativamente essa relação para retornos semanais do Ibovespa.

Concluimos que a relação negativa entre volatilidade e correlação serial para o índice Ibovespa é mais evidente em retornos semanais. Este resultado diverge dos encontrados por LeBaron (1992), onde a série de retornos semanais do índice *Standard*

ℰ Poor's apresenta evidência mais fraca desta relação do que a série diária. Parte dessa diferença é explicada pelo fato de retornos semanais do Ibovespa apresentarem maior tendência de reversão à média. Por outro lado, a relação para retornos diários torna-se mais evidente quando controlamos a influência da crise de 2008 nos dados, sugerindo que períodos críticos tendem a mitigar essa relação para retornos em frequências mais altas.

A questão teórica da causa dessa relação em mercados acionários ainda não foi devidamente explicada. Isso sugere algumas conexões interessantes com a teoria de finanças e finanças comportamentais. Mais especificamente, o fato de período de alta volatilidade gerarem tendências de reversão à média pode estar associado a tópicos como *overreaction* dos agentes, acumulação de notícias, em que os agentes não reagem até terem informações suficientes, efeito manada, entre outros.

Estatísticas de razão de variância são extensamente utilizadas na literatura para medir a eficiência de mercados financeiros na forma fraca (Charles e Darné, 2009). O fato de períodos de alta volatilidade estarem associados a correlação serial negativa dos retornos pode ser interpretado como uma evidência da relação positiva entre eficiência e volatilidade. Investigamos essa relação na próxima seção.

3.4.1 Relação entre volatilidade e eficiência

A literatura em finanças explorou a relação entre risco, medido através da volatilidade, e prêmio pelo risco, medido como o excesso de retornos esperados em relação à taxa de juros livre de risco (French et al., 1987). As evidências indicam que há uma relação positiva entre essas variáveis, de modo que parte da volatilidade existente no mercado não é explicada através do prêmio pelo risco. Logo, testes de volatilidade foram extensamente aplicados para mensurar eficiência no mercado acionário (Frankel e Stock, 1987). Cochrane (1991) relembra que a interpretação de testes de volatilidade não é a de que mercados são ineficientes porque preços são muito voláteis, e sim que os modelos de precificação deixam um resíduo porque retornos são previsíveis.

Para medir a relação entre volatilidade e eficiência no mercado acionário, consideramos o fato de que quanto mais eficiente for a precificação dos ativos, mais próximo de um a estatística de razão de variância estará, pois neste caso, os preços serão passeios aleatórios. Essa relação está demonstrada na seção 3.3.2, onde introduzimos a estatística de razão de variância.

Assim, a série $|VR(k)_t - 1|$ será sempre maior que zero para qualquer defasagem

k e tempo t , sendo próxima de zero quando retornos não são autocorrelacionados. Se houver uma relação positiva entre volatilidade e esta *proxy* para eficiência na precificação, então podemos dizer que a volatilidade induz ineficiência no mercado. A Tabela 3.6 apresenta os resultados da regressão entre essas variáveis.

Tabela 3.6: Relações entre eficiência e volatilidade

Painel A: Estimativa dos parâmetros				
Coeficientes	Retornos diários		Retornos semanais	
	Regressão 2	Regressão 3	Regressão 2	Regressão 3
α_0	0,0027 (3,81 [‡])	0,0030 (2,55 [‡])	0,0029 (1,18)	0,0010 (0,42)
α_1	0,9275 (22,30 [‡])	0,9273 (22,26 [‡])	1,0227 (14,34 [‡])	1,0225 (14,34 [‡])
α_2	-0,0574 (-0,99)	-0,0574 (-0,99)	-0,1221 (-1,11)	-0,1207 (-1,10)
α_3	0,0554 (1,59)	0,0557 (1,59)	-0,0468 (-1,08)	-0,0470 (-1,09)
α_4	-0,0185 (-0,65)	-0,0185 (-0,65)	0,1787 (1,29)	0,1780 (1,28)
α_5	0,0574 (2,71 [‡])	0,0576 (2,72 [‡])	-0,1016 (-1,05)	-0,0980 (-1,01)
β	-0,8906 (-0,55)	-1,9129 (-0,52)	2,8770 (2,51 [†])	4,0142 (2,76 [‡])
δ_1	-	-0,0023 (-0,86)	-	-0,0052 (-0,41)
δ_2	-	2,4164 (0,57)	-	-0,2820 (-0,09)
Painel B: Diagnósticos dos resíduos do modelo				
LB(10)	4,6025	4,6475	4,9014	5,4371
Jarque-Bera	5125,59 [‡]	5105,96 [‡]	561,41 [‡]	563,20 [‡]
R^2 ajustado	0,9151	0,9151	0,8861	0,8861

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores em parênteses são as razões t com erros robustos de Newey-West (HAC).

Para retornos diários não encontramos nenhuma relação significativa entre eficiência e volatilidade, entretanto, o coeficiente β foi positivo e significativo ao nível de 5% na frequência semanal. Momentos de maior volatilidade parecem provocar uma queda na eficiência da precificação para as ações que compõem o índice Ibovespa, pelo menos para retornos semanais. Isso é reflexo da relação entre volatilidade e reversão à média nos retornos.

3.4.2 Efeito LeBaron

Os resultados encontrados por LeBaron (1992) são válidos apenas para correlação serial de primeira ordem. Para estimar essa relação utilizamos o modelo AR(1)-EGARCH(1,1) com efeito autocorrelação, dado pela equação (3.18). Note que o coeficiente ρ_1 mede o impacto linear que a variância condicional causa na correlação

serial de primeira ordem. Os resultados da Tabela 3.7 mostram que esse coeficiente é negativo e estatisticamente significativo ao nível de 5% para ambos os retornos diários e semanais, apesar de ele apresentar uma maior magnitude para retornos semanais.

Tabela 3.7: Modelo AR(1)-EGARCH(1,1) com efeito autocorrelação

Painel A: Estimativa dos parâmetros				
	Retornos diários		Retornos semanais	
Coefficientes	Valor estimado	Razão t	Valor estimado	Razão t
μ	0,000736	2,5930 [†]	0,004636	3,1423 [†]
ρ_1	-0,173007	-2,2918 [†]	-2,093510	-2,4902 [†]
ω	-0,234240	-3,4292 [‡]	-0,341129	-1,9900 [†]
α	0,145340	6,6590 [‡]	0,111156	2,7868 [‡]
β	0,971074	113,9494 [‡]	0,947959	35,9383 [‡]
γ	-0,075748	-4,7549 [‡]	-0,076788	-3,0627 [‡]
ν	1,608170	26,3183 [‡]	1,547218	12,6749 [‡]
Painel B: Diagnósticos dos resíduos do modelo				
	Retornos diários		Retornos semanais	
Testes	Valor	P-valor	Valor	P-valor
LB(10)	8,832	0,5481	10,210	0,4222
LB(15)	14,043	0,5223	13,010	0,6018
$LB^2(10)$	7,648	0,6632	3,739	0,9584
$LB^2(15)$	15,365	0,4255	7,340	0,9475

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores em parênteses são as razões t com erros robustos baseados em White (1982).

Os resultados encontrados para o Brasil aproximam-se da literatura para outros mercados internacionais (Koutmos, 1997; Venetis e Peel, 2005; Bianco et al., 2009). Uma característica peculiar para o caso brasileiro foi o efeito mais pronunciado para retornos semanais do Ibovespa, sendo que utilizando uma medida de razão de variância com as defasagens calculadas endogenamente não foi possível encontrar a relação entre volatilidade e correlação serial para retornos diários. Esse fato pode ser reflexo da maior presença de momentos de reversão à média nos retornos semanais.

Conforme demonstrado, a volatilidade não apenas diminui a correlação serial dos retornos, mas tende a induzir momentos de reversão à média. Podemos concluir que a volatilidade está associada a ineficiência na precificação dos agentes, talvez por induzir períodos de *overreaction* no mercado acionário.

3.4.3 Testes de robustez

Foram realizados alguns testes para verificar a robustez dos resultados das regressões nas Tabelas 3.4 e 3.5. Primeiro utilizamos valores diferentes para o tamanho dos blocos nas estatísticas de razão de variância. Depois rodamos as regressões com diferentes quantidades de coeficientes autorregressivos para as razões de variância. Por fim, analisamos um possível problema de endogeneidade nas regressões utilizadas.

Para verificar se a utilização de blocos com apenas 100 observações pode causar distorções nas estimativas da razão de variância de modo a mudar a significância das regressões, estimamos esta estatística com blocos de 200 e 300 observações. Em ambos os casos, a perda de 100 e 200 observações em relação à estatística anterior foi compensada eliminando estas observações da estatística original. Os resultados indicam que não há distorção significativa, pois o sinal e a significância dos coeficientes permanecem inalterados. Utilizando 200 observações, a diferença na magnitude do coeficiente β na segunda regressão para retornos diários foi $-0,3453$ e para retornos semanais foi $-1,0341$. Com blocos de 300 observações, as diferenças foram $0,5619$ e $0,5912$, respectivamente.

Outra possível fonte de distorções é a seleção da defasagem no modelo $ARX(p)$. Ao incluir um menor número de coeficientes autorregressivos da razão de variância nas regressões das Tabelas 3.4 e 3.5 os resultados não foram afetados significativamente, entretanto, os resíduos da regressão passam a ser correlacionados, indicando uma má especificação do modelo. Os resultados demonstram que o menor número de coeficientes autorregressivos que elimina completamente a correlação dos resíduos da regressão é cinco.

Por fim, uma possível endogeneidade na regressão pode fazer com que os estimadores sejam inconsistentes. Bianco et al. (2009) utilizam regressões semelhantes da razão de variância com a volatilidade, porém não discutem uma possível endogeneidade entre as variáveis. Se os resíduos da regressão estiverem correlacionados com a volatilidade então haverá evidência de endogeneidade. A Figura 3.5 mostra o correlograma cruzado entre essas variáveis para a regressão 2 da Tabela 3.4.

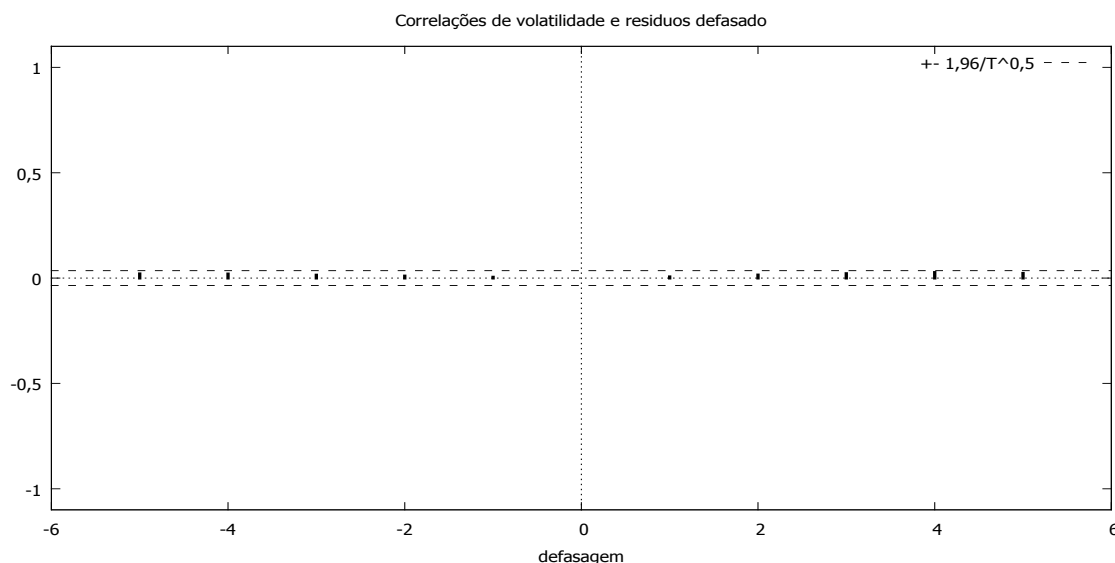


Figura 3.5: Correlograma cruzado entre volatilidade e resíduos

Podemos observar que para as dez defasagens utilizadas, não há correlação significativa entre as variáveis. Para retornos semanais o mesmo resultado foi encontrado, dando evidências de que não há problemas de endogeneidade na regressão. O teste de causalidade de Granger também não apontou uma relação no sentido inverso, das razões de variância para a volatilidade.

3.5 Conclusão

Este capítulo investigou a relação entre correlação serial e volatilidade no mercado acionário brasileiro com dados de retornos diários e semanais do Ibovespa. Para a estimação da volatilidade foram utilizados modelos EGARCH, enquanto a correlação serial foi estimada com uma medida de razão de variância que calcula endogenamente a defasagem dos retornos. A relação entre as duas variáveis foi mensurada com regressões onde a razão de variância é a variável dependente. Utilizamos também uma *proxy* para eficiência e *dummies* para avaliar os efeitos da crise do *subprime* nessa relação. Por fim, estimamos um modelo EGARCH em autocorrelação descrito na equação (3.18) para subsidiar os resultados anteriores e verificar a existência do efeito LeBaron no Brasil.

Os resultados demonstram que a volatilidade afeta negativamente a correlação serial dos retornos na frequência semanal, tendo o efeito menor intensidade para

retornos diários. Além disso, a volatilidade está associada a momentos de reversão à média e causa maior ineficiência na precificação de ativos. Os efeitos da crise de 2008 nessa relação não são significativos para retornos semanais, mas acabaram invertendo o sinal da relação para retornos diários devido a existência de correlação serial positiva (efeito manada) nas observações.

As evidências encontradas sugerem novas questões empíricas e teóricas. Por um lado, temos poucas respostas sobre a exata natureza da relação entre volatilidade e correlação serial, visto que os resultados podem ser reflexos de diversas outras fricções existentes no mercado acionário. Esta e outras evidências de previsibilidade podem ser diferentes sintomas de uma mesma doença, o que levanta a questão teórica de como explicar estes resultados.

LeBaron (1992) descarta a possibilidade destes resultados serem reflexo de problemas de *nontrading* devido a relação negativa deste efeito com o volume negociado. *Nontrading* ocorre quando ações não são negociadas no final do dia, gerando correlação positiva dos retornos, pois as últimas informações serão incorporadas apenas no próximo período. Como há uma relação positiva entre volume e volatilidade, então caso houvesse *nontrading*, as correlações seriais seriam maiores em períodos de baixa volatilidade.

Por outro lado, a teoria de finanças comportamentais tem demonstrado que padrões de reversão à média nos retornos podem ser explicados pela existência de *overreaction* por parte dos agentes (Forbes, 1996). É natural pensar que tais momentos coincidam com períodos de alta volatilidade, explicando a relação negativa entre correlação serial e volatilidade. A relação é inversa durante a crise pois observamos um efeito manada por parte dos investidores, assim, o aumento da volatilidade acaba estando associado à correlação serial positiva dos retornos.

Este capítulo contribui para a literatura ao abordar relações ainda não estudadas no mercado acionário brasileiro entre volatilidade, eficiência e correlação serial de retornos. Do ponto de vista metodológico, abordamos o problema de uma maneira diferente, utilizando novos métodos para estimar a correlação serial e modelos para estudar o efeito da volatilidade nessa variável.

Os resultados têm importantes implicações práticas, uma vez que existe a possibilidade de explorarmos a relação entre volatilidade e reversão à média nos retornos acionários. Uma pergunta interessante é até que ponto podemos construir estratégias que tenham resultados melhores do que a média do mercado utilizando esta relação. Por exemplo, uma estratégia do tipo *contrarian* em períodos de alta volatilidade poderia induzir ganhos significativamente maiores do que a média do mercado? Estes seriam tópicos interessantes para futura pesquisa.

As relações discutidas neste capítulo ainda precisam ser mais investigadas para podermos explicá-las através da teoria de finanças. Futuros trabalhos devem averiguar até que ponto a relação aqui encontrada está relacionada com outras evidências de previsibilidade de retornos, ou então utilizar modelos não lineares que iluminem melhor alguns aspectos dos dados.

Capítulo 4

Dinâmica dos saltos condicionais na taxa de câmbio brasileira

Este capítulo estuda a dinâmica dos saltos condicionais na taxa de câmbio Real/Dólar desde a introdução do regime de câmbio flutuante no Brasil. Utilizamos um modelo de saltos condicionais constantes e três especificações diferentes do modelo ARJI-GARCH proposto por Chan e Maheu (2002) para modelar a dinâmica dos saltos. Os resultados sugerem que (i) os saltos condicionais da taxa de câmbio são variantes no tempo e sensíveis a choques passados, (ii) depreciações cambiais no período anterior tendem a mudar a direção dos saltos no próximo período, e (iii) a intensidade dos saltos é persistente, podendo ser modelada por um processo autorregressivo de médias móveis.

4.1 Introdução

Desde a flexibilização cambial no Brasil em 1999, o comportamento dinâmico da taxa de câmbio tem sido objeto de estudo da literatura especializada (Tabak e Lima, 2009; Oliveira e Plaga, 2011). As variações da taxa de câmbio exibem enviesamento negativo e excesso de curtose em sua distribuição, gerando persistência dos choques e quedas abruptas (Hsieh, 1988). Entender o processo por trás do aparecimento de eventos raros no mercado cambial é importante tanto para a administração de risco como para a formulação de políticas.

Para modelar a curtose e a assimetria existentes em retornos financeiros, além da heteroscedasticidade condicional, normalmente são utilizados processos difusos com saltos para lidar com eventos “normais” e “raros” simultaneamente (Tauchen e Zhou, 2011; Todorov, 2011). Por outro lado, saltos discretos são difíceis de prever, por isso existem poucas evidências sobre o comportamento dos saltos em tempo discreto nos mercados cambiais.

Os modelos de saltos foram estendidos de diversas maneiras ao longo tempo (Andersen et al., 2002; Maheu e McCurdy, 2004), entretanto, ao se trabalhar em tempo discreto, é natural incluir uma especificação de heteroscedasticidade condicional, visto que a variância condicional de retornos financeiros apresenta persistência. Nesse caso, a parametrização GARCH explica mudanças suaves na volatilidade, enquanto os saltos explicam grandes movimentos discretos nos retornos.

Este capítulo estuda a dinâmica dos saltos condicionais na taxa de câmbio no Brasil através dos modelos de saltos discretos propostos por Chan e Maheu (2002). Com isso pretendemos responder as seguintes perguntas: 1) Qual a intensidade dos saltos condicionais na taxa de câmbio ao longo do tempo? 2) Os saltos aparecem de maneira persistente ou se comportam como ruído branco? 3) Existe assimetria no comportamento dos saltos, ou seja, depreciações cambiais têm maiores efeitos na direção dos saltos do que apreciações do câmbio?

Este estudo pode fornecer evidências sobre como a chegada de novas informações ou eventos raros influenciam o mercado cambial através do aparecimento de saltos nas variações da taxa de câmbio, além de contribuir para previsão da volatilidade nesse mercado. A literatura brasileira ainda carece de resultados que indiquem o comportamento dos saltos condicionais discretos na taxa de câmbio, subsidiando investidores, administradores e formuladores de políticas internos e externos.

4.2 Revisão de literatura

Press (1967) foi quem primeiro introduziu modelos de saltos onde o número de movimentos nos preços é governado por uma distribuição de Poisson. A partir daí, diversos estudos empíricos demonstraram a utilidade desses modelos. Mais especificamente, Akgiray e Booth (1988), Tucker e Pond (1988) e Hsieh (1989) concluíram que tais modelos fornecem boas caracterizações estatísticas de taxas de câmbio na frequência diária.

Como a principal característica dos retornos financeiros é a presença de heteroscedasticidade condicional, a literatura empregou modelos de saltos com efeitos ARCH (Jorion, 1988; Vlaar e Palm, 1993; Nieuwland et al., 1994). Entretanto, é razoável supor que a probabilidade de ocorrer saltos em um dado período seja diferente de outros (Bates, 1991), de modo que os parâmetros do processo que determina a ocorrência de saltos são variantes no tempo.

Alguns trabalhos exploraram essa propriedade. Fortune (1999) propôs o uso de variáveis *dummy* para mudar a intensidade dos saltos em diferentes semanas. Chernov et al. (2003) estimaram modelos que permitem que a intensidade dos saltos dependa tanto de observações anteriores como de um fator de volatilidade estocástica. Chan e Maheu (2002) permitiram que a intensidade dos saltos condicionais seguisse um processo autorregressivo endógeno. Artigos mais recentes estudaram mudanças de regime na intensidade dos saltos (Liu, 2012), incorporaram medidas de prêmio pelo risco nos componentes de volatilidade e saltos (Christoffersen et al., 2012), e utilizaram procedimentos não-paramétricos para detectar saltos em dados intradiários (Evans, 2011).

A dinâmica dos saltos em retornos financeiros foi objeto de estudo empírico de diversos artigos na literatura. Chan e Maheu (2002) encontraram significativa variação no tempo da intensidade dos saltos condicionais e dos parâmetros da distribuição do tamanho dos saltos para retornos do mercado acionário americano. Chan (2004) concluiu que as correlações entre variações nas taxas de câmbio Marco alemão/Libra esterlina e Yen/Dólar são reflexos dos saltos que ocorrem nesses mercados. Lee et al. (2010) utilizaram modelos com quebras estruturais no preço do petróleo, encontrando componentes de variação na intensidade dos saltos.

Para o Brasil, a literatura ainda carece de estudos sobre o comportamento dos saltos na taxa de câmbio. Guimarães e Silva (2002) explicaram os *smiles* de volatilidade no câmbio no período de janeiro de 1997 a janeiro de 1999 através da possibilidade de saltos discretos. Ferreira e Zachis (2012) concluíram que os saltos no Ibovespa estão associados a saltos conjuntos na taxa de câmbio e na taxa SELIC.

4.3 Metodologia

A primeira parte desta seção contém a descrição e a análise dos dados utilizados. A segunda parte desenvolve os quatro modelos distintos de saltos condicionais utilizados neste capítulo. A terceira e última parte discute as interpretações da dinâmica e dos coeficientes dos modelos expostos na parte anterior.

4.3.1 Dados

Os dados consistem na taxa de câmbio nominal diária Real/Dólar entre o período de fevereiro de 1999 a dezembro de 2011. O período amostral inclui todos os dados disponíveis desde a flexibilização do câmbio no Brasil até o final de 2011. Ao todo temos 3224 observações. As variações na taxa de câmbio são calculadas como:

$$R_t = \ln(P_t/P_{t-1}), \quad (4.1)$$

onde P_t é o valor da taxa de câmbio no tempo t e \ln é o logaritmo natural. Na Figura 4.1 vemos o comportamento da série ao longo do período analisado.




Figura 4.1: Logaritmo das variações diárias na taxa de câmbio Real/Dólar

As observações da série giram em torno de zero e apresentam períodos de agru-

pamento em torno de algumas observações importantes relacionadas a crises que afetaram o mercado cambial. Na Tabela 4.1 apresentamos as estatísticas descritivas para a série de variações na taxa de câmbio.

Tabela 4.1: Estatísticas descritivas das variações na taxa de câmbio

Estatísticas	Valor
Média	-0,000017
Desvio-padrão	0,010259
$LB(10)$	33,1288 [‡]
$LB^2(10)$	2204,7337 [‡]
Phillips-Perron	-52,5306 [‡]
Assimetria	-0,11398
Excesso de curtose	11,843
Jarque-Bera	18848,5 [‡]

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

A série apresenta média negativa mas próxima de zero, divergindo da distribuição normal por apresentar assimetria negativa e excesso de curtose, ou seja, a série é enviesada e altamente leptocúrtica. O teste de Ljung-Box indica a presença de autocorrelação na série, bem como no quadrado das variações da taxa de câmbio, dando evidência da presença de heteroscedasticidade condicional. As variações da taxa de câmbio são estacionárias, conforme indica a rejeição da hipótese nula de raiz unitária do teste de Phillips-Perron.

4.3.2 Modelos dinâmicos de saltos condicionais

Para avaliar o comportamento dos saltos nas variações da taxa de câmbio, utilizamos um modelo de saltos em tempo discreto com intensidades variantes no tempo, proposto por Chan e Maheu (2002). A especificação dos saltos é combinada com uma parametrização GARCH da volatilidade, devido à presença de heteroscedasticidade condicional na série, conforme a Tabela 4.1.

Sendo o conjunto de informação no tempo t dado por $\Phi_t = \{R_t, \dots, R_1\}$, com R_t definido conforme equação (4.1), o modelo é descrito por:

$$R_t = \mu + \sum_{i=1}^l \phi_i R_{t-i} + \sqrt{h_t} z_t + \sum_{k=1}^{n_t} J_{t,k}, \text{ com} \quad (4.2)$$

$$z_t \sim NID(0,1) \text{ e } J_{t,k} \sim N(\theta_t, \delta_t^2), \quad (4.3)$$

onde μ é a média do processo, ϕ_i são os parâmetros do componente autorregressivo do modelo, h_t é a variância condicional, z_t é um ruído branco independente e $J_{t,k}$ é o tamanho do salto condicional ao conjunto informacional Φ_{t-1} , que se distribui normalmente, com média θ_t e variância δ_t^2 . Por simplificação, supomos que as variáveis z_t e $J_{t,k}$ são independentes.

A variância condicional h_t segue um processo $GARCH(p,q)$:

$$h_t = \omega + \sum_{i=1}^q \alpha_i \varepsilon_{t-i}^2 + \sum_{i=1}^p \beta_i h_{t-i}, \quad (4.4)$$

sendo que $\varepsilon_t = R_t - \mu - \sum_{i=1}^l \phi_i R_{t-i}$. Note que essa especificação do resíduo ε_t contém os saltos esperados, possibilitando que eles afetem a volatilidade do processo.

O número de saltos que acontece durante os períodos $t-1$ e t é dado por n_t , que é governado por um processo discreto com distribuição de Poisson:

$$P(n_t = j | \Phi_{t-1}) = \frac{\exp(-\lambda_t) \lambda_t^j}{j!}, \quad j = 0, 1, 2, \dots, \quad (4.5)$$

onde $\lambda_t > 0$ é o parâmetro da distribuição, que corresponde à média e à variância do processo, sendo interpretado como a intensidade dos saltos.

Para calcular o comportamento dos saltos na taxa de câmbio brasileira, utilizamos quatro modelos distintos de acordo com a dinâmica dos coeficientes λ_t , θ_t e δ_t^2 , conforme Chan e Maheu (2002). O primeiro modelo é o de intensidade e distribuição do tamanho dos saltos constantes, onde $\lambda_t = \lambda_0$, $\theta_t = \theta_0$ e $\delta_t^2 = \delta_0^2$. O segundo modelo, denotado $ARJI(r,s)$, considera os parâmetros da distribuição de $J_{t,k}$ constantes, mas a intensidade dos saltos segue um processo autorregressivo de médias móveis (ARMA) dado por:

$$\lambda_t = \lambda_0 + \sum_{i=1}^r \rho_i \lambda_{t-i} + \sum_{i=1}^s \gamma_i \xi_{t-i}. \quad (4.6)$$

Note que $\lambda_t \equiv E[n_t | \Phi_{t-1}]$ é a expectativa condicional do número de saltos que ocorrerá no instante t dado o conjunto de informação em $t-1$, Φ_{t-1} . Iremos nos referir a λ_t como a intensidade dos saltos no período t . ξ_t é um choque que corresponde ao componente não previsível que afeta a quantidade de saltos, ou seja, $\xi_{t-i} \equiv E[n_{t-i} | \Phi_{t-i}] - \lambda_{t-i}$.

O termo ξ_{t-i} é medido *ex post* utilizando-se o valor esperado $E[n_{t-i} | \Phi_{t-i}] =$

$\sum_{j=0}^{\infty} jP(n_{t-i} = j|\Phi_{t-i})$ e a regra de Bayes:

$$P(n_t = j|\Phi_t) = \frac{f(R_t|n_t = j, \Phi_{t-1})P(n_t = j|\Phi_{t-1})}{\sum_{j=0}^{\infty} f(R_t|n_t = j, \Phi_{t-1})P(n_t = j|\Phi_{t-1})}, \quad j = 0, 1, 2, \dots \quad (4.7)$$

Conforme a equação (4.7), o modelo pode ser visto como uma mistura discreta de distribuições governada por uma distribuição de Poisson variante no tempo. Assim, os retornos condicionados a ϕ_{t-1} e $n_t = j$ serão normalmente distribuídos como:

$$f(R_t|n_t = j, \Phi_{t-1}) = \frac{1}{\sqrt{2\pi(h_t + j\delta_t^2)}} \times \exp\left(-\frac{(R_t - \mu - \sum_{i=1}^l \phi_i R_{t-i} - \theta_t j)^2}{2(h_t + j\delta_t^2)}\right). \quad (4.8)$$

A maximização de (4.8) é realizada iterando-se as equações (4.6) e (4.7). Como o denominador da equação (4.7) envolve uma soma infinita, delimitamos o número máximo de saltos diários em 20, de modo que a probabilidade de ocorrer 20 ou mais saltos em um dia seja zero.

Como a intensidade dos saltos λ_t segue um processo $ARMA(r,s)$ dado pela equação (4.6), o resíduo ξ_t pode ser interpretado como uma diferença de martingale, visto que:

$$E[\xi_t|\Phi_{t-1}] = E[E[n_t|\Phi_t]|\Phi_{t-1}] - \lambda_t = \lambda_t - \lambda_t = 0, \quad (4.9)$$

de modo que $E[\xi_t] = 0$ e $Cov(\xi_t, \xi_{t-i}) = 0$ para $i > 0$. Podemos então expressar a média incondicional da intensidade dos saltos como:

$$E[\lambda_t] = \frac{\lambda_0}{1 - \sum_{i=1}^r \rho_i}. \quad (4.10)$$

Esse valor existe se o processo $ARMA(r,s)$ for estacionário, e então a previsão da intensidade dos saltos futuros no caso em que $r = s = 1$ será dada por:

$$E[\lambda_{t+i}|\Phi_{t-1}] = \begin{cases} \lambda_t, & \text{se } i = 0 \\ \rho^i \lambda_t + \lambda_0 \sum_{j=0}^{i-1} \rho^j, & \text{se } i \geq 1. \end{cases} \quad (4.11)$$

Se $|\rho| < 1$, a previsão se aproxima da média incondicional (4.10) quando $i \rightarrow \infty$. Para garantir que $\lambda_t > 0$ para todo t , impomos as condições suficientes de que $\lambda_0 > 0$, $\rho_i \geq \gamma_i$, e $\gamma_i \geq 0$. Para a estimação, definimos os valores iniciais de λ_i e ξ_i para $i \leq 0$ como o valor da média incondicional da intensidade dos saltos expressa na equação (4.10), e zero, respectivamente.

O terceiro modelo, denotado $ARJI - R_{t-1}^2$, segue a mesma dinâmica para λ_t , entretanto permite que a média condicional e a variância condicional da distribuição do tamanho dos saltos seja uma função das variações passadas na taxa de câmbio:

$$\theta_t = \eta_0 + \eta_1 R_{t-1} D(R_{t-1}) + \eta_2 R_{t-1} (1 - D(R_{t-1})), \text{ e} \quad (4.12)$$

$$\delta_t^2 = \zeta_0^2 + \zeta_1 R_{t-1}^2, \quad (4.13)$$

onde $D(x) = 1$ se $x > 0$ e zero caso contrário, e $\eta_0, \eta_1, \eta_2, \zeta_0$ e ζ_1 são os parâmetros a serem estimados.

No quarto modelo, denotado $ARJI - h_t$, as dinâmicas de λ_t e θ_t são definidas como anteriormente, entretanto a variância condicional do tamanho dos saltos é uma função da volatilidade estimada:

$$\delta_t^2 = \zeta_0^2 + \zeta_1 h_t. \quad (4.14)$$

O primeiro e o segundo modelo são casos específicos desses dois últimos onde a média e a variância do tamanho dos saltos são parâmetros constantes. A diferença entre as duas especificações da variância condicional dos saltos no terceiro e quarto modelo é que em (4.13) o termo R_{t-1}^2 é uma *proxy* para a volatilidade do último período, enquanto h_t é a previsão da volatilidade contemporânea. Assim, no último modelo permitimos que a variância condicional dos saltos no tempo t seja afetada pela volatilidade nesse mesmo período. Esta propriedade é mais desejável, visto que h_t contém mais informação do que R_{t-1}^2 .

Como os dois primeiros momentos condicionais do tamanho dos saltos, $\sum_{k=1}^{n_t} J_{t,k}$, são dados por:

$$E\left[\sum_{k=1}^{n_t} J_{t,k} | \Phi_{t-1}\right] = \theta_t \lambda_t, \text{ e} \quad (4.15)$$

$$Var\left(\sum_{k=1}^{n_t} J_{t,k} | \Phi_{t-1}\right) = (\delta_t^2 + \theta_t^2) \lambda_t, \quad (4.16)$$

então a média e a variância condicional dos quatro modelos propostos serão:

$$E[R_t | \Phi_{t-1}] = \mu + \sum_{i=1}^l \phi_i R_{t-i} + \theta_t \lambda_t, \text{ e} \quad (4.17)$$

$$Var(R_t | \Phi_{t-1}) = h_t + (\delta_t^2 + \theta_t^2) \lambda_t, \quad (4.18)$$

sendo que em cada modelo, a dinâmica de λ_t, θ_t e δ_t definirá os valores dos momentos condicionais. Note que a variância condicional será uma função crescente

da intensidade dos saltos, enquanto a média condicional das variações na taxa de câmbio poderá ser uma função crescente ou decrescente dos saltos, dependendo se θ_t é positivo ou negativo.

4.3.3 Interpretação dos modelos

A probabilidade de grandes variações no mercado cambial pode mudar consideravelmente no tempo, sendo que a dinâmica descrita pela intensidade dos saltos na equação (4.6) captura mudanças sistemáticas no risco de saltos.

Enquanto os parâmetros ρ_i medem a persistência do aparecimento de saltos, os parâmetros γ_i medem a sensibilidade em relação aos resíduos passados expressos por ξ_t . No caso em que $\xi_t > 0$ para vários períodos, então a intensidade dos saltos desvia-se consideravelmente da média incondicional expressa na equação (4.10).

Por outro lado, o tamanho do salto, $J_{t,k}$, é definido pelos parâmetros de sua distribuição, θ_t e δ_t^2 . A especificação da média condicional do tamanho dos saltos descrita na equação (4.12) permite a presença de assimetria, sendo que se $\eta_1 < 0$, depreciações cambiais (variações positivas na taxa de câmbio) tornam a média dos saltos negativa na próxima observação. No caso em que $\eta_2 < 0$, apreciações cambiais (variações negativas na taxa de câmbio) farão com que a média dos saltos no próximo período seja positiva. Em ambos os casos, os coeficientes negativos implicam em uma tendência de reversão de sinal nas próximas observações.

É razoável supor que apreciações cambiais são reflexos de fundamentos macroeconômicos e estão associadas a tendências de médio a longo prazo, por isso apresentam um menor grau de reversão no curto prazo. Já depreciações cambiais em países emergentes muitas vezes são reflexos de intervenções no câmbio, gerando um grau maior de incerteza. Isso, junto com o fato de que agentes são exageradamente avessos ao risco, tende a fazer com que depreciações cambiais sejam seguidas de momentos de reversão à média. Esses resultados estarão presentes no modelo caso o coeficiente η_1 seja negativo e η_2 positivo.

As especificações da variância condicional nas equações (4.13) e (4.14) medem a mudança no tamanho dos saltos. Em ambos os casos, permitimos a diminuição do aparecimento de novos saltos, visto que duas ou mais ocorrências no modelo de variância constante podem ser vistas como apenas uma nos modelos em que a variância muda no tempo. Isso acontece porque em momentos de maior volatilidade temos uma variância maior no tamanho dos saltos, fazendo com que um número menor de saltos explique a variação na taxa de câmbio. Intuitivamente, a segunda

especificação apresenta uma melhor aproximação, pois a volatilidade prevista, h_t , contém mais informação do que R_{t-1}^2 , uma mera *proxy* para a volatilidade no período $t - 1$.

4.4 Resultados

A Tabela 4.2 reporta os resultados da estimação dos modelos $AR(2)$ com intensidade dos saltos constante, e $AR(2) - ARJI(1,1)$ com as três especificações diferentes para os parâmetros da distribuição dos saltos dadas na seção anterior. Os modelos incluem dois coeficientes autorregressivos, número escolhido de acordo com o critério de Akaike, por apresentar maior eficiência do que outros critérios na escolha do número de parâmetros.

Tabela 4.2: Resultados do modelo dinâmico de saltos condicionais

Parâmetros	Constante	$ARJI$	$ARJI - R_{t-1}^2$	$ARJI - h_t$
μ	-0,0654 (0,0176) [‡]	-0,0779 (0,0153) [‡]	-0,0793 (0,0146) [‡]	-0,1057 (0,0200) [‡]
ϕ_1	0,1118 (0,0169) [‡]	0,0778 (0,0207) [‡]	0,0867 (0,0201) [‡]	0,0689 (0,0225) [‡]
ϕ_2	-0,0462 (0,0174) [‡]	-0,0692 (0,0182) [‡]	-0,0693 (0,0178) [‡]	-0,0658 (0,0183) [‡]
ω	0,0061 (0,0035) [*]	0,0074 (0,0020) [‡]	0,0067 (0,0018) [‡]	0,0055 (0,0018) [‡]
α	0,1524 (0,0140) [‡]	0,1063 (0,0152) [‡]	0,0721 (0,0135) [‡]	0,0452 (0,0151) [‡]
β	0,8293 (0,0129) [‡]	0,8603 (0,0152) [‡]	0,8927 (0,0152) [‡]	0,9147 (0,0172) [‡]
ζ_0	0,6449 (0,2003) [‡]	0,5543 (0,0958) [‡]	0,5461 (0,0746) [‡]	-0,1782 (0,2099)
ζ_1	-	-	0,0452 (0,0289)	0,6244 (0,2516) [†]
η_0	0,3576 (0,2133) [*]	0,2914 (0,0935) [‡]	0,4049 (0,1126) [‡]	0,2621 (0,0979) [‡]
η_1	-	-	-0,1186 (0,0438) [‡]	-0,0718 (0,0410) [*]
η_2	-	-	0,1236 (0,0584) [†]	0,1181 (0,0476) [†]
λ_0	0,1292 (0,1089)	0,0614 (0,0274) [†]	0,0602 (0,0207) [‡]	0,1280 (0,0585) [†]
ρ	-	0,8321 (0,0522) [‡]	0,8623 (0,0339) [‡]	0,8080 (0,0402) [‡]
γ	-	1,4511 (0,4220) [‡]	1,6012 (0,3402) [‡]	1,5458 (0,3636) [‡]
L_{max}	-3709,3548	-3687,8451	-3674,7606	-3668,7617

Os símbolos ‡, † e * denotam significância ao nível de 1%, 5% e 10%, respectivamente.

Os valores em parênteses são os erros-padrão dos coeficientes.

Podemos notar que o modelo com a intensidade dos saltos constante é o que apresenta o menor valor máximo da log-verossimilhança, tendo o pior ajuste aos dados. Já o modelo $ARJI - h_t$ apresenta o maior valor para a log-verossimilhança máxima, indicando que a intensidade dos saltos é variante no tempo, bem como os parâmetros da distribuição do tamanho dos saltos.

Em todos os modelos, os coeficientes autorregressivos e da especificação GARCH são significantes, indicando persistência e heteroscedasticidade condicional nas variações da taxa de câmbio. No primeiro modelo, consideramos $\lambda_t = \lambda_0$, $\theta_t = \eta_0$, e $\delta_t^2 = \zeta_0^2$. Os parâmetros λ_0 e η_0 não são significantes ao nível de 5%, ou seja, o modelo não consegue captar os saltos existentes nas variações da taxa de câmbio.

No segundo modelo, os parâmetros da distribuição são constantes, de modo que $\theta_t = \eta_0$ e $\delta_t^2 = \zeta_0^2$. Porém, agora a intensidade dos saltos segue uma estrutura autorregressiva de médias móveis. Observamos que todos os parâmetros são significantes. Em particular, o número médio de saltos em dado período depende de sua intensidade no período anterior, bem como da ocorrência de saltos não previstos. Os coeficientes ρ e γ são respectivamente, 0,8321 e 1,4511, indicando que saltos não previstos no período anterior têm forte influência na probabilidade da ocorrência de novos saltos. A média incondicional do número de saltos da série é 0,3657, calculada pela equação (4.10).

Por outro lado, os coeficientes η_0 e ζ_0 são respectivamente, 0,5543 e 0,2914. A média do tamanho dos saltos é positiva, ou seja, eles são responsáveis pelo aumento das variações na taxa de câmbio (depreciações). Já o desvio-padrão é considerado baixo, comparado aos resultados para retornos acionários (Chan e Maheu, 2002), mostrando que saltos no mercado cambial tendem a apresentar um comportamento mais estável do que saltos no mercado acionário.

No terceiro modelo, a média e a variância da distribuição dos saltos seguem as dinâmicas expressas em (4.12) e (4.13). Os valores dos outros parâmetros são semelhantes ao segundo modelo. Para a média, observamos um comportamento assimétrico em relação à depreciação cambial, visto que após variações positivas no câmbio, a média dos saltos no próximo período muda de direção, devido ao valor negativo de η_1 . O mesmo resultado não é observado para a apreciação cambial, pois o coeficiente η_2 é positivo. Esse resultado corrobora a idéia de que depreciações cambiais geram tendências de reversão à média como discutido na seção 4.3.3. Para a variância, o coeficiente ζ_1 não foi significativo, ou seja, retornos no período passado não explicam satisfatoriamente a variância do tamanho dos saltos.

O último modelo utiliza a previsão de volatilidade h_t como variável explicativa para a variância da distribuição do tamanho dos saltos, conforme a equação (4.14). Dessa vez, o coeficiente ζ_1 é significativo ao nível de 5%, tendo o valor de 0,6244. A não significância do coeficiente ζ_0 indica que a variância dos saltos pode ser inteiramente explicada pela volatilidade do período, sendo em média 62,44% menor que esta.

Os resultados indicam que o último modelo, $ARJI - h_t$, é o que melhor descreve

os dados, de modo que a intensidade dos saltos condicionais pode ser descrita como um processo $ARMA$ e os parâmetros da distribuição dos saltos são variantes no tempo, com a média apresentando assimetria em relação à depreciação cambial e a variância dependendo da volatilidade esperada das variações na taxa de câmbio.

Na Figura 4.2 podemos observar a intensidade dos saltos ao longo do período amostral, calculadas pelo modelo $ARJI - h_t$. O aumento do número esperado de saltos em períodos críticos do mercado cambial reflete a importância da utilização de saltos condicionais para modelar o aparecimento de eventos raros e a chegada de novas informações. A série λ_t tem uma amplitude em torno de 6, apresentando alta persistência e uma certa regularidade no aumento do número médio de saltos.




Figura 4.2: Intensidade dos saltos nas variações da taxa de câmbio

A maior intensidade dos saltos pode ser vista durante o período eleitoral de 2002, quando o valor esperado do número de saltos chega a seis por dia. Outros períodos críticos do mercado cambial são o início da amostra, em 1999, e fins de 2008, quando da crise do *subprime*. Em ambos os casos a intensidade dos saltos aumentou significativamente, porém não parece ser maior do que a de outras datas com grandes variações na taxa de câmbio. Isso indica que a magnitude dos saltos foi maior nesses períodos.

Para avaliarmos a capacidade do modelo de prever volatilidade através de saltos no câmbio, analisamos o período do mês de outubro de 2008, mês em que a taxa de câmbio sofreu uma das maiores depreciações do período de câmbio flutuante, devido a crise do *subprime*. A Figura 4.3 mostra os valores de da série $P(n_t = 1|\Phi_t)$

ao longo deste mês, indicando a probabilidade de ocorrer pelo menos um salto no período t dado o conjunto informacional até a presente data.



Figura 4.3: Probabilidade de pelo menos um salto no câmbio durante o mês de outubro de 2008.

Podemos observar que houve um aumento significativo na probabilidade de pelo menos um salto durante os dias 6 a 9 de outubro de 2008, representados pelo pico inicial na Figura 4.3. O dia 8 de outubro de 2008 representou a maior depreciação cambial do período amostral. A estatística cai rapidamente após o dia 9, refletindo a diminuição na volatilidade da série. Assim, o modelo com saltos explica boa parte da volatilidade do mercado cambial no período mais crítico da crise de 2008.

4.5 Conclusão

Este capítulo examinou a dinâmica dos saltos condicionais na taxa de câmbio Real/Dólar desde a introdução do regime de câmbio flutuante no Brasil. Para isso, utilizamos um modelo de saltos condicionais constantes e três especificações diferentes do modelo ARJI-GARCH proposto por Chan e Maheu (2002), onde o número de saltos em dado período segue uma distribuição de Poisson com o coeficiente determinado por um modelo autorregressivo de médias móveis. Cada especificação

determina uma dinâmica diferente para a média e a variância da distribuição do tamanho dos saltos.

Os resultados indicam que a intensidade dos saltos é persistente no tempo, tendo uma amplitude máxima de seis saltos por dia, para o período analisado de fevereiro de 1999 a dezembro de 2011. Períodos críticos no mercado cambial demonstraram ter um valor esperado do número de saltos maior, bem como uma maior probabilidade de ocorrência de pelo menos um salto. Depreciações cambiais em períodos anteriores tendem a mudar a direção dos saltos no próximo período, sendo que a variância dos saltos é positivamente correlacionada à previsão da volatilidade.

Estes resultados evidenciam a importância dos saltos na modelagem da dinâmica da taxa de câmbio no Brasil. Modelos de previsão de volatilidade devem incorporar estas não lineares, possibilitando resultados mais confiáveis para subsidiar a tomada de decisões, a administração de risco de portfólios e a formulação de políticas. A intensidade dos saltos apresenta um caráter persistente ao longo do tempo, podendo ser interpretada como a chegada de novos eventos ou informações no mercado. Um possível tópico para pesquisas futuras seria incluir variáveis exógenas nos processos que explicam a intensidade e os parâmetros da distribuição dos saltos, como por exemplo as intervenções do Banco Central no mercado *spot*.

Capítulo 5

Considerações Finais

Os três ensaios desta tese concernem os mercados acionário e cambial brasileiros, tendo como objetivo principal coletar evidências sobre tópicos ainda não abordados através de métodos econométricos avançados. Os mercados emergentes têm demonstrado alguns comportamentos peculiares na literatura de finanças, devido ao maior grau de incerteza existente nesses países. Por um lado, isso faz com que o interesse de investidores externos nesses mercados aumente, dada a possibilidade de retornos esperados maiores. Por outro lado, muitos resultados ainda não foram documentados, dificultando a análise e o entendimento da dinâmica dos mercados financeiros em países emergentes.

O primeiro ensaio conclui que apesar de retornos acionários liderarem as variações na taxa de câmbio nos primeiros momentos, a transmissão da volatilidade entre esses mercados caminha no sentido inverso. Assim, a volatilidade no mercado cambial antecipa a volatilidade no mercado acionário. A relação entre essas variáveis é assimétrica, bem como a dinâmica do processo de correlação condicional entre os mercados. Dividimos nossa amostra em dois subperíodos para analisarmos os efeitos da crise de 2008 na transmissão de volatilidade. Os resultados indicaram que a crise intensificou as transmissões, fazendo com que o mercado cambial impactasse mais a volatilidade do mercado acionário.

As evidências de interligação entre os mercados cambial e acionário no Brasil se afastam dos resultados para países desenvolvidos, mas se aproximam da literatura para mercados emergentes. O fato da volatilidade do mercado acionário não impactar significativamente o mercado cambial pode ser reflexo da tendência dos investidores externos de reinvestir os resgates em renda variável no mercado de renda fixa, não causando movimentos de divisas cambiais. Por outro lado, variações na taxa de câmbio afetam custos e lucros de empresas nacionais, além de aumentar o grau de risco do mercado acionário.

Esses resultados podem ser incorporados na modelagem do risco de portfólios, bem como fornecer subsídio para operações de *hedge* nesses mercados, dada a importância da previsão de volatilidade para a tomada de decisão. Outras possíveis relações não lineares entre os dois mercados podem existir, de modo que apenas modelamos uma parcela da interligação entre os mercados cambial e acionário.

O segundo ensaio dá evidências de uma relação negativa entre volatilidade e correlação serial para retornos do índice Ibovespa. A relação para retornos semanais é mais forte do que para retornos diários, entretanto, ao controlarmos os efeitos da crise de 2008, observamos um aumento da significância dessa relação para retornos diários. O período da crise acabou por inverter o sinal dessa relação, devido a maior predominância de correlação serial positiva, um reflexo do efeito manada que ocorreu durante a crise.

Esses resultados ainda precisam ser mais investigados para podermos explicá-los através da teoria de finanças, entretanto, eles sugerem algumas conexões interessantes com a teoria de finanças comportamentais. A relação entre volatilidade e reversão à média pode ser reflexo de momentos de *overreaction* por parte dos agentes em períodos de alta volatilidade.

Por fim, a relação encontrada no segundo ensaio pode ajudar a identificar possibilidades de arbitragem, bem como inferir sobre a influência da volatilidade no mecanismo de formação de preços. Uma questão para futura pesquisa seria verificar até que ponto uma estratégia do tipo *contrarian* em períodos de alta volatilidade resultaria em retornos acima da média do mercado.

O terceiro ensaio estuda a dinâmica dos saltos condicionais na taxa de câmbio brasileira. Períodos críticos do mercado cambial estão associados ao aumento da intensidade dos saltos, que apresentam um comportamento autorregressivo. As depreciações no câmbio induzem a mudança da direção dos saltos no próximo período, indicando uma tendência de reversão. Os resultados contribuem para a modelagem da volatilidade no câmbio, bem como para explicar a influência do aparecimento de eventos raros no mercado.

Modelos previsão de volatilidade devem incorporar não linearidades no câmbio, possibilitando a obtenção de resultados mais confiáveis para subsidiar as operações financeiras que envolvem riscos cambiais, bem como a formulação de políticas. Uma extensão interessante do modelo proposto no terceiro ensaio seria acrescentar uma variável exógena para explicar a intensidade dos saltos no câmbio, como por exemplo uma *proxy* para as intervenções do governo no mercado cambial.

A tese forneceu um conjunto de evidências empíricas sobre o comportamento dos mercados acionário e cambial brasileiros que ainda não foram abordadas na literatura

especializada. Demonstramos que esses mercados têm características diferentes dos países desenvolvidos, muitas vezes gerando resultados que descolam do corpo teórico. Assim, trabalhos futuros podem incorporar estes resultados em modelos teóricos, ou identificar outros padrões que expliquem as divergências encontradas.

Referências Bibliográficas

- Adjasi, C., Harvey, S. K., e Agyapongand, D. (2008). Effect of exchange rate volatility on the ghana stock exchange. *African Journal of Accounting, Economics, Finance and Banking Research*, 9:241-251.
- Akgiray, V. e Booth, G. G. (1988). Mixed diffusion-jump process modeling of exchange rate movements. *The Review of Economics and Statistics*, 70(4):631-637.
- Andersen, T. G., Benzoni, L., e Lund, J. (2002). An empirical investigation of continuous-time equity return models. *The Journal of Finance*, 57(3):1239-1284.
- Andrews, D. W. K. (1991). Heteroskedasticity and autocorrelation consistent covariance matrix estimation. *Econometrica*, 59(3):817-858.
- Ang, A., Hodrick, R. J., Xing, Y., e Zhang, X. (2006). The cross-section of volatility and expected returns. *The Journal of Finance*, 61(1):259-299.
- Baillie, R. T. e Bollerslev, T. (2002). The message in daily exchange rates. *Journal of Business & Economic Statistics*, 20(1):60-68.
- Bates, D. S. (1991). The crash of '87: Was it expected? The evidence from options markets. *The Journal of Finance*, 46(3):1009-1044.
- Bera, A. K. e Kim, S. (2002). Testing constancy of correlation and other specifications of the bgarch model with an application to international equity returns. *Journal of Empirical Finance*, 9(2):171-195.
- Bianco, S., Corsi, F., e Renò, R. (2009). Intraday lebaron effects. *Proceedings of the National Academy of Sciences*, 106(28):11439-11443.
- Bollerslev, T. (1986). Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, 31(3):307-327.
- Bollerslev, T. (1990). Modelling the coherence in short-run nominal exchange rates: A multivariate generalized arch model. *The Review of Economics and Statistics*, 72(3):498-505.

- Branson, W. H. (1983). Macroeconomic determinants of real exchange risk. In Herring, R. J., editor, *Managing Foreign Exchange Risk*, págs 33-74. Cambridge University Press, Cambridge.
- Cai, J. (1994). A markov model of switching-regime arch. *Journal of Business & Economic Statistics*, 12(3):309-316.
- Campbell, J. Y. e Hentschel, L. (1992). No news is good news: An asymmetric model of changing volatility in stock returns. *Journal of Financial Economics*, 31(3):281-318.
- Cappiello, L., Engle, R. F., a Sheppard, K. (2006). Asymmetric dynamics in the correlations of global equity and bond returns. *Journal of Financial Econometrics*, 4:537-572.
- Chan, W. H. (2004). Conditional correlated jump dynamics in foreign exchange. *Economics Letters*, 83(1):23-28.
- Chan, W. H. e Maheu, J. M. (2002). Conditional jump dynamics in stock market returns. *Journal of Business & Economic Statistics*, 20(3):377-389.
- Chang, E. J., Lima, E. J. A., e Tabak, B. M. (2004). Testing for predictability in emerging equity markets. *Emerging Markets Review*, 5(3):295-316.
- Chang, C.-Y. (2009). The volatility's asymmetrical reaction to serial correlation: Evidences from america and taiwan cases. *International Research Journal of Finance and Economics*, 28:98-103.
- Charles, A. e Darné, O. (2009). Variance-ratio tests of random walk: an overview. *Journal of Economic Surveys*, 23(3):503-527.
- Chen, W. W. e Deo, R. S. (2006). The variance ratio statistic at large horizons. *Econometric Theory*, 22(2):206-234.
- Chernov, M., Gallant, A. R., Ghysels, E., e Tauchen, G. (2003). Alternative models for stock price dynamics. *Journal of Econometrics*, 116(1):225-257.
- Choi, I. (1999). Testing the random walk hypothesis for real exchange rates. *Journal of Applied Econometrics*, 14(3):293-308.
- Choi, D. F., Fang, V., e Fu, T. Y. (2009). Volatility spillovers between New Zealand stock market returns and exchange rate changes before and after the 1997 asian financial crisis. *Asian Journal of Finance & Accounting*, 1:106-117.

- Chordia, T., Roll, R., e Subrahmanyam, A. (2008). Liquidity and market efficiency. *Journal of Financial Economics*, 87(2):249-268.
- Christoffersen, P., Jacobs, K., e Ornathanalai, C. (2012). Dynamic jump intensities and risk premiums: Evidence from S&P500 returns and options. *Journal of Financial Economics*, Forthcoming.
- Cochrane, J. H. (1988). How big is the random walk in gnp? *The Journal of Political Economy*, 96(5):893-920.
- Cochrane, J. H. (1991). Volatility tests and efficient markets: A review essay. *Journal of Monetary Economics*, 27(3):463-485.
- Corradi, V., Distaso, W., e Fernandes, M. (2012). International market links and volatility transmission. *Journal of Econometrics*, 170(1):117-141.
- Dornbusch, R. e Fischer, S. (1980). Exchange rates and the current account. *The American Economic Review*, 70(5):960-971.
- Doyle, J. R. e Chen, C. H. (2009). The wandering weekday effect in major stock markets. *Journal of Banking & Finance*, 33(8):1388-1399.
- Eissa, M. A., Chortareas, G., e Cipollini, A. (2010). Stock returns and exchange rate volatility spillovers in the mena region. *Journal of Emerging Market Finance*, 9(3):257-284.
- Engle, R. F. (1982). Autoregressive conditional heteroscedasticity with estimates of the variance of united kingdom inflation. *Econometrica*, 50(4):987-1007.
- Engle, R. (2002). Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models. *Journal of Business & Economic Statistics*, 20(3):339-350.
- Engle, R. (2004). Risk and volatility: Econometric models and financial practice. *The American Economic Review*, 94(3):405-420.
- Escanciano, J. C. e Lobato, I. N. (2009). An automatic portmanteau test for serial correlation. *Journal of Econometrics*, 151(2):140-149.
- Evans, K. P. (2011). Intraday jumps and US macroeconomic news announcements. *Journal of Banking & Finance*, 35(10):2511-2527.
- Fama, E. F. e French, K. R. (1988). Permanent and temporary components of stock prices. *The Journal of Political Economy*, 96(2):246-273.

- Ferreira, M. A. e Santa-Clara, P. (2011). Forecasting stock market returns: The sum of the parts is more than the whole. *Journal of Financial Economics*, 100(3):514-537.
- Ferreira, R. T. e Zachis, S. de M. (2012). Análise dos saltos e co-saltos nas séries do ibovespa, dow jones, taxa de juros, taxa de câmbio e no spread do c-bond. *Revista Economia*, 13:15-34.
- Forbes, W. P. (1996). Picking winners? a survey of the mean reversion and overreaction of stock prices literature. *Journal of Economic Surveys*, 10:123-158.
- Fortune, P. (1999). Are stock returns different over weekends? a jump diffusion analysis of the weekend effect. *New England Economic Review*, Setembro/Outubro:3-19.
- Frankel, J. (1983). Monetary and portfolio balance models of exchange rate determination. In Bhandari, J. and Putnam, B., editores, *Economic Interdependence and Flexible Exchange Rates*, pages 84-114. MIT Press, Cambridge.
- Frankel, J. A. e Stock, J. H. (1987). Regression vs. volatility tests of the efficiency of foreign exchange markets. *Journal of International Money and Finance*, 6(1):49-56.
- French, K. R. (1980). Stock returns and the weekend effect. *Journal of Financial Economics*, 8(1):55-69.
- French, K. R., Schwert, G., e Stambaugh, R. F. (1987). Expected stock returns and volatility. *Journal of Financial Economics*, 19(1):3-29.
- Glosten, L. R., Jagannathan, R., e Runkle, D. E. (1993). On the relation between the expected value and the volatility of the nominal excess return on stocks. *The Journal of Finance*, 48(5):1779-1801.
- Granger, C. W., Huangb, B.-N., e Yang, C.-W. (2000). A bivariate causality between stock prices and exchange rates: evidence from recent asianflu. *The Quarterly Review of Economics and Finance*, 40(3):337-354.
- Guimarães, B. d. V. e Silva, M. E. d. (2002). A possibilidade de saltos no câmbio implícita nos prêmios das opções. *Revista Brasileira de Economia*, 56:397-428.
- Hamilton, J. D. e Susmel, R. (1994). Autoregressive conditional heteroskedasticity and changes in regime. *Journal of Econometrics*, 64(1):307-333.

- Hassan, S. A. e Malik, F. (2007). Multivariate garch modeling of sector volatility transmission. *The Quarterly Review of Economics and Finance*, 47(3):470-480.
- Hsieh, D. A. (1988). The statistical properties of daily foreign exchange rates: 1974 - 1983. *Journal of International Economics*, 24(1):129-145.
- Hsieh, D. A. (1989). Testing for nonlinear dependence in daily foreign exchange rates. *The Journal of Business*, 62(3):339-368.
- Johnson, S. e Mitton, T. (2003). Cronyism and capital controls: evidence from malaysia. *Journal of Financial Economics*, 67(2):351-382.
- Jorion, P. (1988). On jump processes in the foreign exchange and stock markets. *Review of Financial Studies*, 1(4):427-445.
- Kanas, A. (2000). Volatility spillovers between stock returns and exchange rate changes: International evidence. *Journal of Business Finance and Accounting*, 27(3-4):447-467.
- Kim, J. H. (2009). Automatic variance ratio test under conditional heteroskedasticity. *Finance Research Letters*, 6(3):179-185.
- Koutmos, G. (1997). Feedback trading and the autocorrelation pattern of stock returns: further empirical evidence. *Journal of International Money and Finance*, 16(4):625-636.
- Kumar, M. (2009). A bivariate linear and nonlinear causality between stock prices and exchange rates. *Economics Bulletin*, 29:2884-2895.
- LeBaron, B. (1992). Some relations between volatility and serial correlations in stock market returns. *The Journal of Business*, 65(2):199-219.
- Lee, Y.-H., Hu, H.-N., e Chiou, J.-S. (2010). Jump dynamics with structural breaks for crude oil prices. *Energy Economics*, 32(2):343-350.
- Lehmann, B. N. (1990). Fads, martingales, and market efficiency. *The Quarterly Journal of Economics*, 105(1):1-28.
- Liu, Y., Gopikrishnan, P., Cizeau, Meyer, Peng, e Stanley, H. E. (1999). Statistical properties of the volatility of price fluctuations. *Physical Review E*, 60:1390-1400.
- Liu, P. (2012). Regime-switching garch-jump models with autoregressive jump intensity. *Unpublished*.

- Lo, A. W. e MacKinlay, A. C. (1988). Stock market prices do not follow random walks: Evidence from a simple specification test. *The Review of Financial Studies*, 1(1):41-66.
- Ma, Y. e Kanas, A. (2000). Testing for a nonlinear relationship among fundamentals and exchange rates in the ERM. *Journal of International Money and Finance*, 19(1):135-152.
- Maheu, J. M. e McCurdy, T. H. (2004). News arrival, jump dynamics, and volatility components for individual stock returns. *The Journal of Finance*, 59(2):755-793.
- Moskowitz, T. J., Ooi, Y. H., e Pedersen, L. H. (2012). Time series momentum. *Journal of Financial Economics*, 104(2):228-250.
- Nelson, D. B. (1991). Conditional heteroskedasticity in asset returns: A new approach. *Econometrica*, 59(2):347-370.
- Nieh, C.-C. e Lee, C.-F. (2001). Dynamic relationship between stock prices and exchange rates for g-7 countries. *The Quarterly Review of Economics and Finance*, 41(4):477-490.
- Nieuwland, F. G., Verschoor, W. F., e Wolff, C. C. (1994). Stochastic trends and jumps in ems exchange rates. *Journal of International Money and Finance*, 13(6):699-727.
- Oliveira, F. N. e Plaga, A. R. (2011). Eficácia das intervenções do banco central do brasil sobre a volatilidade da taxa de câmbio nominal. *Revista Brasileira de Economia*, 65:71-92.
- Pesaran, M. H. e Timmermann, A. (1995). Predictability of stock returns: Robustness and economic significance. *The Journal of Finance*, 50(4):1201-1228.
- Press, S. J. (1967). A compound events model for security prices. *The Journal of Business*, 40(3):317-335.
- Samuelson, P. A. (1965). Proof that properly anticipated prices fluctuate randomly. *Industrial Management Review*, 6:41-49.
- Scheinkman, J. A. e LeBaron, B. (1989). Nonlinear dynamics and stock returns. *The Journal of Business*, 62(3):311-337.
- Sentana, E. e Wadhvani, S. (1992). Feedback traders and stock return autocorrelations: Evidence from a century of daily data. *The Economic Journal*, 102(411):415-425.

- Silvennoinen, A. e Teräsvirta, T. (2009). Modeling multivariate autoregressive conditional heteroskedasticity with the double smooth transition conditional correlation garch model. *Journal of Financial Econometrics*, 7(4):373-411.
- Tabak, B. M. (2006). The dynamic relationship between stock prices and exchange rates: Evidence for Brazil. *International Journal of Theoretical and Applied Finance*, 09(08):1377-1396.
- Tabak, B. M. e Lima, E. J. (2009). Market efficiency of brazilian exchange rate: Evidence from variance ratio statistics and technical trading rules. *European Journal of Operational Research*, 194(3):814-820.
- Tauchen, G. e Zhou, H. (2011). Realized jumps on financial markets and predicting credit spreads. *Journal of Econometrics*, 160(1):102-118.
- Todorov, V. (2011). Econometric analysis of jump-driven stochastic volatility models. *Journal of Econometrics*, 160(1):12-21.
- Tse, Y. (2000). A test for constant correlations in a multivariate garch model. *Journal of Econometrics*, 98(1):107-127.
- Tucker, A. L. e Pond, L. (1988). The probability distribution of foreign exchange price changes: Tests of candidate processes. *The Review of Economics and Statistics*, 70(4):638-647.
- Venetis, I. A. e Peel, D. (2005). Non-linearity in stock index returns: the volatility and serial correlation relationship. *Economic Modelling*, 22(1):1-19.
- Vlaar, P. J. G. e Palm, F. C. (1993). The message in weekly exchange rates in the european monetary system: Mean reversion, conditional heteroscedasticity, and jumps. *Journal of Business & Economic Statistics*, 11(3):351-360.
- Walid, C., Chaker, A., Masood, O., e Fry, J. (2011). Stock market volatility and exchange rates in emerging countries: A markov-state switching approach. *Emerging Markets Review*, 12(3):272-292.
- White, H. (1982). Maximum likelihood estimation of misspecified models. *Econometrica*, 50(1):1-25.
- Wu, R.-S. (2005). International transmission effect of volatility between the financial markets during the asian financial crisis. *Transition Studies Review*, 12:19-35.

- Yang, S.-Y. e Doong, S.-C. (2004). Price and volatility spillovers between stock prices and exchange rates: Empirical evidence from the g-7 countries. *International Journal of Business and Economics*, 3:139-153.
- Zakoian, J.-M. (1994). Threshold heteroskedastic models. *Journal of Economic Dynamics and Control*, 18(5):931-955.
- Zhao, H. (2010). Dynamic relationship between exchange rate and stock price: Evidence from china. *Research in International Business and Finance*, 24(2):103-112.