



Universidade de Brasília  
Faculdade de Administração, Contabilidade, Economia e Gestão de Políticas  
Públicas  
Programa de Pós-Graduação em Administração

**Estudos de eventos suportados por modelos  
MGARCH: aplicações em eventos corporativos e  
de política monetária no período entre 2012 e  
2022**

**Arthur de Brito Baldini**

**Brasília-DF, Junho de 2023**

Arthur de Brito Baldini

**Estudos de eventos suportados por modelos MGARCH:  
aplicações em eventos corporativos e de política  
monetária no período entre 2012 e 2022**

**Dissertação de Mestrado** apresentada ao Programa de Pós-Graduação em Administração da UnB (área de concentração: Finanças e Métodos Quantitativos), como requisito parcial para a obtenção do Título de Mestre em Administração.

Universidade de Brasília – UnB

Faculdade de Administração, Contabilidade, Economia e Gestão de Políticas Públicas

Programa de Pós-Graduação em Administração

Orientador: Dr. Ivan Ricardo Gartner

Brasília-DF

Junho de 2023

---

Arthur de Brito Baldini

Estudos de eventos suportados por modelos MGARCH: aplicações em eventos corporativos e de política monetária no período entre 2012 e 2022/ Arthur de Brito Baldini. – Brasília-DF, Junho de 2023-

155 p. : il. (algumas color.) ; 30 cm.

Orientador: Dr. Ivan Ricardo Gartner

Dissertação (Mestrado) – Universidade de Brasília – UnB

Faculdade de Administração, Contabilidade, Economia e Gestão de Políticas Públicas

Programa de Pós-Graduação em Administração, Junho de 2023.

1. Estudo de eventos. 2. MGARCH. 3. Hipótese dos Mercados Eficientes I. Dr. Ivan Ricardo Gartner. II. Universidade de Brasília. III. Faculdade de Administração, Contabilidade, Economia e Gestão de Políticas Públicas. IV. Estudos de eventos suportados por modelos MGARCH: ensaios para o período entre 2012 e 2022

CDU 02:141:005.7

---

Arthur de Brito Baldini

**Estudos de eventos suportados por modelos MGARCH:  
aplicações em eventos corporativos e de política  
monetária no período entre 2012 e 2022**

**Dissertação de Mestrado** apresentada ao Programa de Pós-Graduação em Administração da UnB (área de concentração: Finanças e Métodos Quantitativos), como requisito parcial para a obtenção do Título de Mestre em Administração.

Trabalho aprovado. Brasília-DF, 26 de junho de 2023:

---

**Dr. Ivan Ricardo Gartner**  
Orientador

---

**Dr. José Ângelo Costa do Amor Divino**  
Membro Externo à Instituição

---

**Dr. José Guilherme de Lara Resende**  
Membro Externo ao Programa

Brasília-DF  
Junho de 2023

*A Deus, pois a Ele pertence toda honra e toda glória.*

*Aos meus pais Silézie Barbosa de Brito e José Dimas Baldini, por sempre me incentivarem a buscar o conhecimento e por sempre estarem ao meu lado nessa caminhada. A minha irmã Mayná, que tanto me alegra, orienta e acalma com nossas conversas. Aos meus amigos e irmãos da vida Ariel, Érico e Miguel, cujas companhias tornam os problemas da vida irrisórios. A todos os meus familiares, que sempre me apoiaram.*

# Agradecimentos

Agradeço a Deus, por me dar tantas oportunidades, mesmo sem que eu as mereça. Agradeço a Universidade de Brasília, a qual me recebeu tão bem na graduação em Economia e na pós graduação em Administração. Espero um dia poder retribuir à sociedade os recursos destinados a minha formação. Agradeço ao meu orientador, professor Dr. Ivan Ricardo Gartner, cujo direcionamento foi fundamental para o desenvolvimento deste trabalho e que me acompanhou desde a graduação, sempre proporcionando ensinamentos valiosos sobre o mundo das finanças. Agradeço a professora Msc. Olinda Maria Gomes Lesses pela oportunidade de lecionar o curso de Gestão de Finanças Pessoais no nível da graduação, um desejo que tinha desde o ingresso na Universidade de Brasília. Também expresso minha gratidão a todos os meus alunos de Gestão de Finanças Pessoais, que tiveram compreensão e paciência em minhas aulas durante todo o semestre. Espero que tenham aprendido e se divertido em minhas aulas. Não menos importante, sou grato a todos os funcionários da Universidade de Brasília, que sempre me deram o suporte necessário para o desenvolvimento de minhas atividades, em especial às funcionárias da secretaria da pós graduação em Administração: Selma e Edvânia, sempre solícitas e cordiais.

Agradeço a minha mãe, Silézie Barbosa de Brito, que por meio do incentivo a leitura, fez com que eu obtivesse sucesso nos tantos desafios intelectuais que se apresentaram durante a minha vida. Meu pai, José Dimas Baldini, tem a minha gratidão por me apoiar na busca pelo conhecimento e me ensinar que para vencer esse processo é necessária a virtude da paciência. Agradeço a minha irmã, Mayná de Brito Baldini, por colocar juízo na minha cabeça, quando outros não conseguem. Agradeço ao meu amigo e futuro Doutor, Ariel, que me ajudou a entender o mundo acadêmico, ao meu amigo Miguel, pelo incentivo para alçar voos mais altos e ao meu amigo Érico pela companhia sempre presente. Por fim, agradeço a todos os meus familiares, que tanto me apoiaram nessa trajetória, em especial, ao meu primo Jaider, cujos ensinamentos sobre programação e conselhos sobre a vida foram fundamentais para a conclusão desse trabalho.

*"O mundo não será salvo pelos caridosos, mas pelos eficientes".  
(Roberto Campos)*

# Resumo

A metodologia de estudo de eventos é a forma mais popular de teste da hipótese dos mercados eficientes na forma semi forte. Contudo, problemas relacionados a presença de heterocedasticidade e a dificuldade de se modelar betas dinâmicos limitam o alcance de seus resultados, fazendo com que modelagens alternativas fossem propostas pela literatura como forma de suporte metodológico. Este trabalho segue essa linha de suportes metodológicos ao utilizar modelos multivariados GARCH (MGARCH) para modelar tanto a heterocedasticidade em estudos de eventos, quanto betas dinâmicos. Com esse objetivo, foram realizados dois trabalhos sobre eventos relativos ao mercado acionário brasileiro entre 2012 e 2022, sendo um deles endógeno à economia brasileira e o outro exógeno. O trabalho envolvendo eventos endógenos ao mercado brasileiro explorou anúncios de ofertas de debêntures por meio de modelos BEKK-GARCH, de modo a verificar como informações sobre mudanças na alavancagem das firmas brasileiras afetariam seus retornos. Os resultados apresentados tanto pela metodologia clássica, quanto pela metodologia com modelos MGARCH indicam uma reação negativa e estatisticamente significativa do mercado brasileiro à anúncios de ofertas de debêntures, sendo a maior reação verificada pela metodologia com modelagem de volatilidade. No trabalho envolvendo eventos exógenos ao mercado acionário brasileiro, foi investigada a reação do Ibovespa à anúncios monetários por parte do Federal Open Market Committee (FOMC). Para isso, foi conduzida a metodologia de estudo de eventos considerando os modelos BEKK-GARCH e DCC. Os resultados dos modelos MGARCH estimados indicam uma significativa transferência de volatilidade do índice de S&P500 para o Ibovespa, mas não foram verificadas anormalidades de retornos de forma persistente nas datas dos anúncios monetários americanos. Contudo, nas datas em que houve uma reação estatisticamente significativa do mercado acionário brasileiro, ela foi explicada por elementos de forward guidance presentes nos comunicados do FOMC. Em conjunto, os resultados dos dois artigos evidenciam diferenças relevantes nas anormalidades de retornos obtidas por meio da metodologia de estudo de eventos clássica e pela metodologia que utilizou modelos MGARCH como suporte.

**Palavras-chaves:**Hipótese dos Mercados Eficientes, Estudo de Eventos, GARCH.

**JEL:** G12, G14, G15, G32.



# Abstract

The event studies methodology is the most popular way of testing the efficient markets hypothesis in semi-strong form. However, problems related to the presence of heteroscedasticity and the difficulty of modeling dynamic betas limit the scope of their results, making alternative models proposed by the literature a form of methodological support. This work follows this line of methodological support by using multivariate GARCH models (MGARCH) to model both heteroscedasticity and dynamic betas in event studies. With this objective, two works were carried out on events related to the Brazilian stock market between 2012 and 2022, one of them being endogenous to the Brazilian economy and the other exogenous. The work involving events endogenous to the Brazilian market explored debt offering announcements through BEKK-GARCH models, to verify how information about changes in the leverage of Brazilian firms would affect their returns. The results presented both by the classic methodology and by the methodology with MGARCH models indicate a negative and statistically significant reaction of the Brazilian market to announcements of debenture offers, being the biggest reaction verified by the methodology with volatility modeling. In the work involving exogenous events to the Brazilian stock market, Ibovespa's reaction to monetary announcements by the Federal Open Market Committee (FOMC) was investigated. For this, the event study methodology was conducted considering the BEKK-GARCH and DCC models. The results of the estimated MGARCH models indicate a significant transfer of volatility from the S&P500 index to the Ibovespa, but no persistently abnormal returns were observed on the dates of the FOMC announcements. However, on the dates when there was a statistically significant reaction by the Brazilian stock market, it was explained by elements of forward guidance present in the FOMC announcements. Together, the results of the two articles show relevant differences in the abnormal returns obtained through the classical event study methodology and through the methodology that used MGARCH models as support.

**Keywords:** : Efficient Markets Hypothesis, Event Study, GARCH.

**JEL:** G12, G14, G15, G32.

# Lista de ilustrações

Figura 1 – Evolução dos modelos de precificação de ativos . . . . .	2
Figura 2 – Fronteira Eficiente . . . . .	10
Figura 3 – Linha temporal de um estudo de eventos . . . . .	17
Figura 4 – Beta médio ao longo de 101 dias ao redor dos anúncios de emissão . . . .	37
Figura 5 – Beta do Ibovespa e covariâncias e correlações condicionais entre o Ibovespa e o S&P500 . . . . .	52

# Lista de tabelas

Tabela 1 – Variáveis do Estudo . . . . .	29
Tabela 2 – Evolução anual dos anúncios de emissão de debêntures . . . . .	30
Tabela 3 – Emissões de debêntures por setor econômico . . . . .	30
Tabela 4 – Estatísticas descritivas e testes estatísticos dos CAR's, BEKK bivariado	34
Tabela 5 – Estatísticas descritivas e testes estatísticos dos CAR's, Modelo de Mercado . . . . .	35
Tabela 6 – Estatísticas descritivas e testes estatísticos dos CAR's, Modelo de Mercado com erros corrigidos GARCH . . . . .	36
Tabela 7 – Beta médio ao redor dos anúncios . . . . .	37
Tabela 8 – Resultados dos modelos explicativos . . . . .	39
Tabela 9 – Estatísticas descritivas das variáveis do estudo . . . . .	46
Tabela 10 – Parâmetros estimados do modelo DCC . . . . .	52
Tabela 11 – Parâmetros estimados do modelo BEKK . . . . .	53
Tabela 12 – Estatísticas descritivas e testes de significância dos CAR's . . . . .	54
Tabela 13 – Retornos anormais acumulados (CAR's) positivos dos eventos estatisticamente significantes . . . . .	57
Tabela 14 – Retornos anormais acumulados (CAR's) negativos dos eventos estatisticamente significantes . . . . .	58
Tabela 15 – Modelos probit com CAR's para a janela de 2 dias . . . . .	59
Tabela 16 – Empresas da amostra e testes de estacionariedade . . . . .	76

# Lista de abreviaturas e siglas

APT Arbitrage Pricing Theory

BEKK-GARCH Baba, Engle, Kraft and Kroner Generalized Autoregressive Conditional Heteroskedasticity

CAPM Capital Asset Pricing Model

DCC Dynamic Conditional Correlation

FED Federal Reserve

FOMC Federal Open Market Committee

GARCH Generalized AutoRegressive Conditional Heteroskedasticity

ICAPM Intertemporal Capital Asset Pricing Model

MGARCH Multivariate Generalized AutoRegressive Conditional Heteroskedasticity

MQO Mínimos Quadrados Ordinários

QE Quantitative Easing

# Lista de símbolos

$\alpha$	Alfa
$\beta$	Beta
$\gamma$	Gama
$\delta$	Delta
$\xi$	Xi
$\varepsilon$	Epsilon
$\phi$	Phi
$\mu$	Mu
$\psi$	Psi
$\eta$	Eta
$\omega$	Omega
$\sigma$	Sigma
$\theta$	Theta

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>1</b>
	<b>Introdução</b>	<b>1</b>
<b>1.1</b>	<b>Tema e problema de pesquisa</b>	<b>1</b>
<b>1.2</b>	<b>Objetivos e relevância da dissertação</b>	<b>4</b>
<b>1.3</b>	<b>Hipóteses da dissertação</b>	<b>5</b>
<b>1.4</b>	<b>Aspectos metodológicos e estrutura da dissertação</b>	<b>6</b>
<b>1.5</b>	<b>Contribuições da dissertação</b>	<b>7</b>
<b>2</b>	<b>REFERENCIAL TEÓRICO</b>	<b>9</b>
<b>2.1</b>	<b>Modelos de precificação de ativos em finanças</b>	<b>9</b>
2.1.1	Modelos baseados em fatores	9
2.1.2	Modelos baseados em consumo	12
<b>2.2</b>	<b>Eficiência de mercado</b>	<b>14</b>
<b>3</b>	<b>ASPECTOS METODOLÓGICOS</b>	<b>17</b>
<b>3.1</b>	<b>Estudos de eventos</b>	<b>17</b>
<b>4</b>	<b>ANÚNCIOS DE OFERTA DE DEBÊNTURES COM ABORDAGEM MGARCH: ANÁLISE DA REAÇÃO DO MERCADO BRASILEIRO NO PERÍODO DE 2012 A 2022</b>	<b>22</b>
<b>4.1</b>	<b>Introdução</b>	<b>23</b>
<b>4.2</b>	<b>Revisão de Literatura</b>	<b>25</b>
4.2.1	Teorias de estrutura de capital	25
4.2.2	Estudos de eventos sobre emissão de dívida	27
<b>4.3</b>	<b>Procedimentos Metodológicos</b>	<b>28</b>
4.3.1	Amostra de Dados	28
4.3.2	Metodologia	30
4.3.2.1	Estudo de eventos	30
4.3.2.2	Análise de regressão	33
<b>4.4</b>	<b>Resultados</b>	<b>34</b>
4.4.1	Medidas alternativas de anormalidade	35
4.4.2	Análise de volatilidade	36
4.4.3	Resultados das regressões MGARCH	38
<b>4.5</b>	<b>Conclusões</b>	<b>39</b>

<b>5</b>	<b>REAÇÃO DO MERCADO ACIONÁRIO BRASILEIRO A ANÚNCIOS DO FOMC: UM ESTUDO DE EVENTOS COM ABORDAGEM MGARCH NO PERÍODO ENTRE 2012 E 2022</b>	<b>41</b>
<b>5.1</b>	<b>Introdução</b>	<b>42</b>
<b>5.2</b>	<b>Revisão de literatura</b>	<b>44</b>
5.2.1	Reação do mercado financeiro à política monetária	44
5.2.2	Estudos de eventos com modelos GARCH	45
<b>5.3</b>	<b>Metodologia</b>	<b>46</b>
5.3.1	Amostra de Dados	46
5.3.2	Estudo de eventos	47
5.3.2.1	Modelo de regressão probit	51
<b>5.4</b>	<b>Resultados</b>	<b>51</b>
5.4.1	Modelos de volatilidade estimados	51
5.4.2	Estudo de Eventos	54
5.4.3	Modelos Probit MGARCH	59
<b>5.5</b>	<b>Conclusões</b>	<b>60</b>
<b>6</b>	<b>CONSIDERAÇÕES FINAIS</b>	<b>62</b>
	Considerações Finais	62
	<b>REFERÊNCIAS</b>	<b>65</b>
	<b>APÊNDICES</b>	<b>74</b>
	<b>APÊNDICE A – APÊNDICE A - AMOSTRA DE EMPRESAS DO ARTIGO 1</b>	<b>75</b>
	<b>APÊNDICE B – APÊNDICE B - CÓDIGOS UTILIZADOS NO ARTIGO 1</b>	<b>77</b>
	<b>APÊNDICE C – APÊNDICE C - CÓDIGOS UTILIZADOS NO ARTIGO 2</b>	<b>112</b>

# 1 Introdução

## 1.1 Tema e problema de pesquisa

A busca por modelos de equilíbrio de preços é antiga nas ciências econômicas, tendo como marco a obra de [Smith \(1776\)](#), na qual o autor argumenta que os preços na economia são formados pelo equilíbrio entre as forças de oferta e demanda por meio da intervenção da "mão invisível do mercado". A explicação de [Smith \(1776\)](#) para a formação de preços, embora inspiradora, carece do necessário grau de formalização, tão comum nas ciências econômicas atuais.

Análises de equilíbrio na economia com aplicação mais intensa da matemática podem ser vistas no trabalho de [Cournot \(1929\)](#), mas a primeira análise de equilíbrio geral é atribuída à obra de [Walras \(1874\)](#). O equilíbrio de Walras propõe um sistema de oferta e demanda em que consumidores igualam suas utilidades marginais aos preços de bens e serviços, ao passo que produtores fazem o mesmo para os fatores de produção. Assim, consumidores maximizam suas utilidades e produtores maximizam seus lucros, havendo uma relação de interdependência entre mercados, que é expressa na forma de um sistema de equações, cujo vetor de preços é a solução.

Contudo, [Walras \(1874\)](#) apresenta uma solução incorreta para o seu equilíbrio geral. O trabalho de [Arrow e Debreu \(1954\)](#), por sua vez, demonstra a existência de um vetor de preços que iguala a oferta e a demanda na economia, provando, assim, a existência do equilíbrio walrasiano e, por consequência, a existência de equilíbrios gerais na economia. A área de finanças também explorou de forma significativa equilíbrios de preços, utilizando como base as contribuições da hipótese da média variância de [Markowitz \(1952\)](#) para construir modelos que explicassem a dinâmica de preços no mercado financeiro. Essa busca por modelos de equilíbrio gerou duas correntes teóricas principais na literatura de apreçamento de ativos em finanças: modelos baseados em fatores e modelos baseados em consumo, sendo estes últimos um resultado direto do equilíbrio geral de [Arrow e Debreu \(1954\)](#).

Modelos baseados em fatores buscam explicar a formação de preços dos ativos no mercado financeiro ao eleger variáveis que capturem adequadamente essa dinâmica. Historicamente o primeiro modelo de formação de preços baseado em fatores foi o Capital Asset Pricing Model (CAPM) ([SHARPE, 1964](#); [LINTNER, 1965](#))<sup>1</sup>, que busca explicar os preços dos ativos com base na sua sensibilidade ao prêmio pelo risco de mercado. Uma

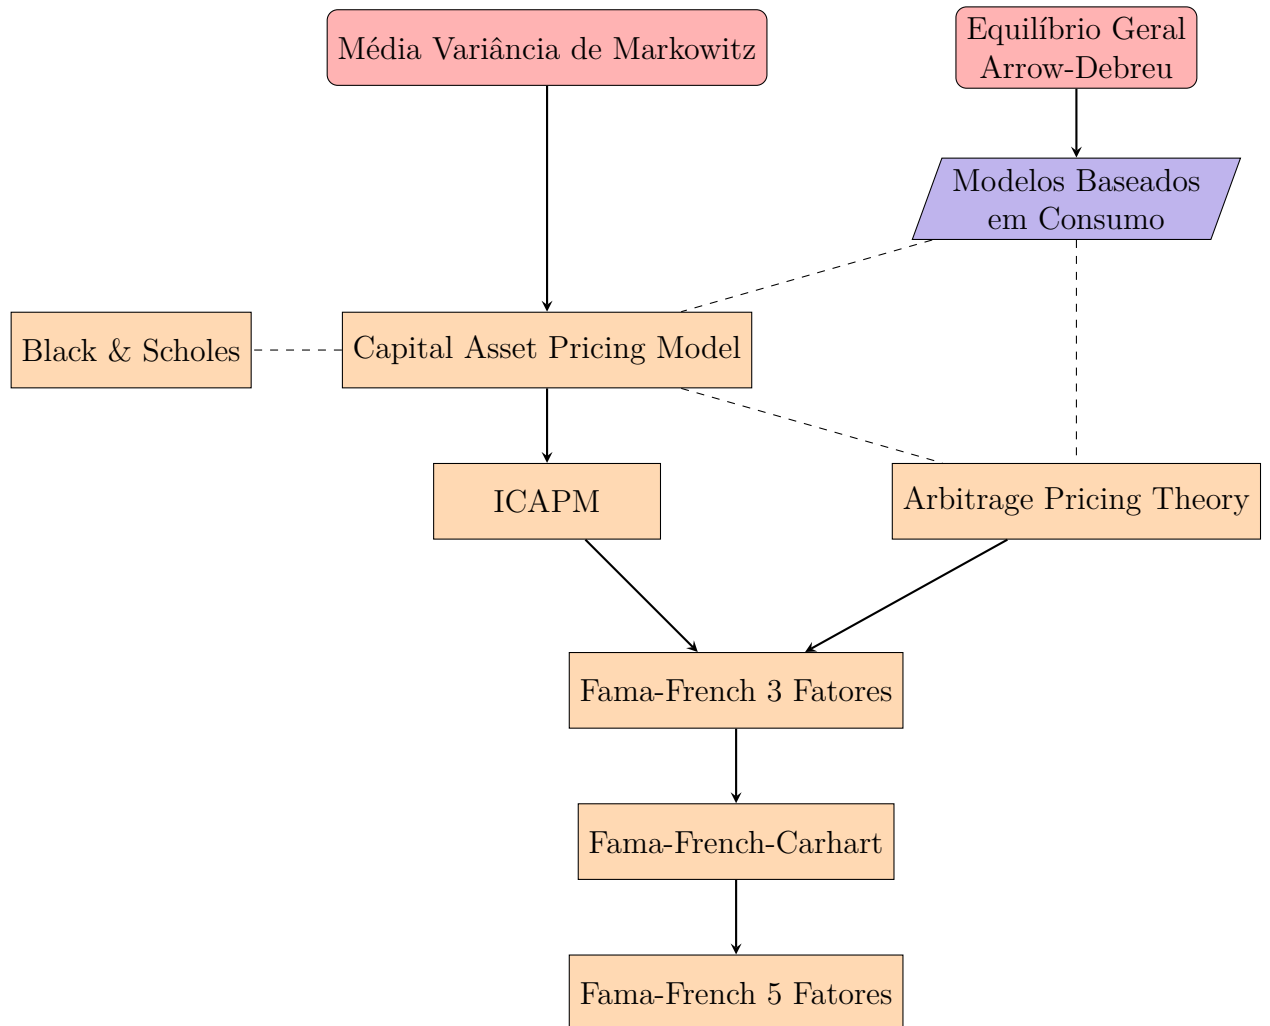
---

<sup>1</sup> Pode-se argumentar que o modelo de Gordon ([GORDON; SHAPIRO, 1956](#)) foi o primeiro modelo de precificação de ativos, mas ele não se trata de um modelo de equilíbrio. Assim sua menção nesta seção introdutória fica restrita a esta nota de rodapé.



extensão do CAPM, o Intertemporal Capital Asset Pricing Model (ICAPM) (MERTON, 1973) expande o número de períodos de análise do modelo original, mas permanece elegendo o prêmio pelo risco como fator principal de precificação de ativos.<sup>2</sup>

Figura 1 – Evolução dos modelos de precificação de ativos



Nota: Elaboração do autor.

A partir do ICAPM, outras abordagens multifatoriais surgiram, como a de Ross (1976), que propõe uma teoria de precificação de ativos que não se baseia na média-variância como no CAPM, mas num modelo multifatorial baseado no processo de arbitragem. De fato, abordagens multifatoriais apresentaram ganhos no poder explicativo na precificação de ativos, como mostra o trabalho de Fama e French (1993). Os autores se inspiram nas discussões proporcionadas pelo ICAPM e pelo APT e consideram fatores de risco sistemático como o prêmio pelo risco, o tamanho das empresas e a sua razão de valor contábil e valor de mercado. O desempenho consideravelmente superior desse modelo de

<sup>2</sup> O modelo CAPM proporciona uma análise de equilíbrio intuitiva, podendo inclusive ser utilizado para derivar modelos complexos como o modelo de precificação de opções europeias de (BLACK; SCHOLES, 1973).

precificação acabou levando a agregação de outros fatores explicativos como a tendência de preço das ações (CARHART, 1997) e lucratividade e investimento (FAMA; FRENCH, 2015).

Modelos baseados em consumo, por outro lado, começaram a ganhar popularidade com o trabalho de Lucas (1978) e apresentam uma abordagem diferente ao problema de precificação de ativos, definindo o equilíbrio de preços como fruto das decisões intertemporais de consumo dos agentes econômicos.<sup>3</sup> Isto é, qual deverá ser o consumo no período  $t = 0$  que maximiza a utilidade no período  $t = 1$  dada uma taxa de desconto qualquer? O problema levantado parece relativamente simples, mas os desafios apresentados por modelos baseados em consumo são complexos e muitas vezes fazem com que eles apresentem desempenho inferior quando comparados a modelos mais simples como o CAPM (CAMPBELL; COCHRANE, 2000).

Independente dos pressupostos que os modelos consideram para chegar nos desejados equilíbrios, todos eles utilizam como pressuposto a eficiência informacional dos agentes econômicos. Isto é, os agentes conhecem igualmente e sem custos a distribuição dos retornos dos ativos para o período seguinte. Essa hipótese têm um papel central na área de precificação de ativos em finanças e é conhecida como hipótese dos mercados eficientes (FAMA, 1970). Fama (2013) argumenta que a hipótese dos mercados eficientes leva a um problema considerável: caso um modelo falhe em explicar a dinâmica de preços de um mercado, isso acontece por ele não ser uma boa aproximação da realidade ou pelo fato de que os mercados são, na verdade, ineficientes?

Esse é um problema sério e a verificação da hipótese dos mercados eficientes é de suma importância para o desenvolvimentos de modelos de equilíbrio em finanças, pois a partir da verificação da eficiência informacional do mercado financeiro pode-se validar, aplicar e aprimorar os modelos conhecidos pela literatura. Para isso, testes envolvendo a hipótese dos mercados eficientes muitas vezes tem como foco a reação do mercado a informações não antecipadas, sendo a abordagem padrão para verificação desse tipo de ocorrência a metodologia de estudo de eventos (FAMA, 2013).

A metodologia de estudo de eventos consiste na verificação do comportamento de uma série temporal dada uma ocorrência não antecipada pelo mercado financeiro. Esse evento pode variar desde acontecimentos endógenos como emissões de dívidas ou desdobramentos de ações, até eventos exógenos como notícias macroeconômicas, ataques terroristas e desastres naturais. Estudos de eventos analisam os resíduos observados ao redor de tais acontecimentos à luz de modelos de precificação, assim, se o modelo escolhido é uma boa aproximação da realidade, a análise dos resíduos durante a ocorrência do

---

<sup>3</sup> Apesar da abordagem de modelos de fatores ser significativamente diferente da utilizada em modelos baseados em consumo, é possível demonstrar que modelos baseados em fatores são casos especiais de modelos baseados em consumo. Um exemplo envolvendo o CAPM está disponível no referencial teórico deste trabalho, mas para uma revisão extensiva sobre o tema consulte Cochrane (2001).

evento permite que se estabeleça inferência com respeito à hipótese dos mercados eficientes (MCWILLIAMS, 1997; CAMPBELL; LO; MACKINLAY, 2012).

Apesar da sua grande popularidade, a metodologia de estudo de eventos não está isenta de dificuldades que limitam o seu alcance. Muitos destes desafios estão historicamente ligados à presença de heterocedasticidade em séries temporais financeiras e ao pressuposto de que os betas das empresas analisadas são fixos (CORHAY; RAD, 1996; FAMA, 1998; REYES, 1999; SAVICKAS, 2003; YIN et al., 2018). O não controle da heterocedasticidade em um estudo de eventos pode levar a parâmetros enviesados e a testes estatísticos não confiáveis, o que prejudica interpretações com relação à eficiência de mercado (CORHAY; RAD, 1996). De igual modo, estudos de eventos que assumem betas fixos podem incorrer no erro de calcular incorretamente anormalidades de retornos, confundindo um erro do próprio modelo com uma possível reação do mercado acionário (FAMA, 1998; REYES, 1999; FAMA, 2013).

Muitas soluções para estes desafios foram apresentadas ao longo dos anos pela literatura, com alguns trabalhos apresentando testes estatísticos alternativos mais robustos (BOEHMER; MASUMECI; POULSEN, 1991; SAVICKAS, 2003), modelagem da volatilidade (CORHAY; RAD, 1996; SAVICKAS, 2003; BALABAN; CONSTANTINOU, 2006; PADULA; ALBUQUERQUE, 2018) e modelagem de betas dinâmicos (REYES, 1999; KOUTMOS et al., 2018). Soluções envolvendo o controle da heterocedasticidade e a modelagem de betas dinâmicos muitas vezes utilizam modelos univariados da família GARCH para essa tarefa. Contudo, por conta da utilização de modelos univariados, muitos destes trabalhos se limitam ou ao controle da heterocedasticidade ou a modelagem de betas dinâmicos, havendo uma dificuldade no controle destes fenômenos simultaneamente.

## 1.2 Objetivos e relevância da dissertação

Trabalhos recentes como os de Yin et al. (2018) e Avelino (2022) utilizam modelos GARCH multivariados (MGARCH) para modelagem simultânea da volatilidade em séries temporais e de betas dinâmicos, de modo a auxiliar a metodologia de estudo de eventos na obtenção de parâmetros mais precisos. Nesse sentido, o objetivo deste trabalho é a condução da metodologia de estudo de eventos considerando ocorrências pouco exploradas no contexto brasileiro, contando com modelos da família MGARCH como suporte, de modo a proporcionar uma análise mais rica e auxiliando os estudos de eventos a combater o fenômeno da heterocedasticidade e a modelar betas dinâmicos.

Como objeto de aplicação da metodologia de estudos de eventos suportada por modelos MGARCH, foram considerados dois eventos pouco explorados no mercado brasileiro, sendo um deles endógeno, isto é, gerado pelas próprias empresas da amostra e o outro exógeno, tendo sua origem em fatores externos ao mercado brasileiro. Assim, pode-se

levantar evidências a respeito de temas relevantes para o contexto brasileiro e aplicar modelos de suporte sugeridos pela literatura, que permitem além da consideração dos pontos já levantados, a análise da volatilidade das séries temporais de interesse, dando uma maior riqueza de detalhes para as análises realizadas.

O artigo relativo a eventos endógenos às empresas brasileiras diz respeito a anúncios de ofertas de debêntures e busca verificar qual a reação do mercado acionário brasileiro a esse tipo de informação. Um anúncio do aumento da alavancagem de uma firma é uma informação relevante para o mercado acionário e a análise desse tipo de evento possibilita que se verifique como tal informação é precificada pelos agentes econômicos nas datas ao redor do evento.

Dado o impacto informacional de uma emissão de debênture, como se comportam os retornos da empresa anunciante? Há alguma mudança na sua volatilidade nos dias ao redor desse tipo de evento? Caso seja verificado algum impacto, quais variáveis podem melhor explicá-lo? As respostas destas perguntas podem fornecer evidências não somente a respeito da hipótese dos mercados eficientes, mas também com relação às diversas teorias de estrutura de capital (MODIGLIANI; MILLER, 1958; MODIGLIANI; MILLER, 1963; KRAUS; LITZENBERGER, 1973; JENSEN; MECKLING, 1976; ROSS, 1977; MYERS; MAJLUF, 1984).

Por outro lado, o artigo referente a eventos exógenos ao mercado acionário brasileiro analisa anúncios monetários por parte da autoridade monetária americana, o Federal Open Market Committee (FOMC). O objetivo deste trabalho é verificar se há uma transferência de volatilidade do mercado acionário americano para o brasileiro e se essa transferência de volatilidade é realizada em casos de anúncios monetários e surpresas monetárias.

A literatura a respeito da transferência da política monetária americana para o mercado acionário americano é considerável, sendo os principais fatores ligados a essa transferência identificados como surpresas na taxa de juros (RIGOBON; SACK, 2004; BERNANKE; KUTTNER, 2005), caminho da política monetária (GÜRKAYNAK; SACK; SWANSON, 2005) e medidas de Quantitative Easing (QE) (GLICK; LEDUC, 2018; CURCURI et al., 2018). Considerando as evidências disponíveis na literatura, há uma transferência de volatilidade do mercado acionário americano para o mercado acionário brasileiro? Se sim, há alguma relação entre anúncios monetários do FOMC e anomalias de retornos no mercado acionário brasileiro? Quais variáveis explicariam essas anomalias?

### 1.3 Hipóteses da dissertação

As hipóteses da dissertação foram divididas entre os dois trabalhos que a compõem, buscando verificar qual a reação do mercado acionário brasileiro a informações públicas

disponíveis. Tomando o primeiro artigo da dissertação, que trata sobre anúncios de ofertas de debêntures, o sistema de hipóteses proposto foi o seguinte:

- H1a: Anúncios de ofertas de debêntures geram anormalidades de retornos de forma consistente nas empresas brasileiras;
- H2a: Anúncios de ofertas de debêntures alteram a sensibilidade ao risco sistemático das empresas brasileiras;
- H3a: Acréscimos na alavancagem das empresas brasileiras são notícias recebidas negativamente pelo mercado acionário brasileiro;
- H4a: Os resultados obtidos pela metodologia clássica de estudos de eventos e pela metodologia suportada por modelos MGARCH não apresentam distinções.

Para o artigo a respeito de informações monetária americanas, foi considerado o seguinte sistema de hipóteses:

- H1b: Há uma transferência de volatilidade do mercado acionário americano para o mercado acionário brasileiro;
- H2b: Anúncios do Federal Open Market Committee (FOMC) geram anormalidades de retornos de forma consistente no Ibovespa;
- H3b: Mudanças na taxa de juros americana anunciadas pelo Federal Open Market Committee (FOMC) estão associadas a maiores chances de anormalidades de retornos no Ibovespa;
- H4b: Políticas de forward guidance anunciadas pelo Federal Open Market Committee (FOMC) estão associadas a maiores chances de anormalidades de retornos no Ibovespa;
- H5b: Políticas de Quantitative Easing (QE) anunciadas pelo Federal Open Market Committee (FOMC) estão associadas a maiores chances de anormalidades de retornos no Ibovespa;
- H6b: Não há diferença nos resultados entre a metodologia clássica de estudo de eventos e a metodologia suportada por modelos MGARCH.

## 1.4 Aspectos metodológicos e estrutura da dissertação

Como evidenciado, os aspectos metodológicos da dissertação são baseados na metodologia de estudos de eventos, sendo a condução da metodologia idêntica nos dois

trabalhos. Contudo, nos dois trabalhos, a aplicação de modelos MGARCH como suporte à metodologia apresenta distinções consideráveis, de modo a adequar a análise realizada para os objetivos específicos de cada trabalho.

No artigo a respeito de anúncios de ofertas de debêntures, a análise da volatilidade se dá no sentido de verificar mudanças no risco sistemático das empresas da amostra ao redor dos eventos de interesse, não havendo ganhos significativos na verificação da transferência da volatilidade do índice de mercado para as empresas e vice-versa. Por outro lado, no artigo envolvendo anúncios monetários americanos, a verificação da transferência de volatilidade do índice de mercado americano para o índice brasileiro é de grande interesse, pois esse seria o canal de transmissão de possíveis anormalidades de retornos na ocorrência de eventos monetários.

A ordem de apresentação dos artigos passa primeiro pelos eventos endógenos, de caráter mais isolado, para os eventos exógenos, que podem apresentar efeitos sistêmicos no mercado brasileiro. Essa ordem também é influenciada pela análise de volatilidade apresentada em cada um dos trabalhos, que é feita de maneira mais superficial no primeiro trabalho dada a própria natureza da sua amostra. O segundo trabalho, no entanto, interpreta os resultados dos modelos de volatilidade estimados, não utilizando os modelos MGARCH apenas como um suporte metodológico ao estudo de eventos conduzido, mas também como um fim em si mesmo.

Após este capítulo introdutório o presente trabalho está organizado da seguinte maneira: o capítulo 2 apresenta os principais modelos de precificação de ativos em finanças, bem como a hipótese dos mercados eficientes e suas implicações. O capítulo 3 apresenta detalhadamente a metodologia de estudos de eventos e a sua combinação à modelos GARCH. O capítulo 4 é referente ao estudo de eventos sobre anúncios de ofertas de debêntures no mercado brasileiro. O capítulo 5 apresenta o estudo de eventos a respeito de anúncios monetários americanos. O capítulo 6, por fim, delinea as conclusões da dissertação, além de indicar as limitações da pesquisa realizada e futuros caminhos de pesquisa.

## 1.5 Contribuições da dissertação

Naturalmente, evidências relativas aos dois trabalhos são de caráter específico e não podem ser tomadas como forma geral e conclusiva da rejeição ou não rejeição da hipótese de eficiência de mercado na forma semi forte. A mesma lógica vale para a abordagem metodológica envolvendo modelos MGARCH, as evidências apresentadas não implicam na inadequação da metodologia de estudo de eventos clássica ou na invalidação de estudos anteriores que seguem essa linha. As evidências apresentadas servem, no entanto, para agregar evidências a respeito das temáticas propostas (eventos envolvendo mudanças

na estrutura de capital de empresas e impactos de anúncios monetários americanos) e evidenciar diferenças entre os resultados obtidos por meio da metodologia clássica e a metodologia que utiliza modelos MGARCH como suporte, além de indicar vantagens que a modelagem de volatilidade proporciona em estudos de eventos. A luz das evidências agregadas a respeito do controle da heterocedasticidade e da modelagem de betas dinâmicos, em consonância com os trabalhos de [Yin et al. \(2018\)](#) e [Avelino \(2022\)](#), este trabalho contribui para uma maior investigação a respeito dessa linha de suporte metodológico.

Feitas essas considerações, os trabalhos apresentados possuem relevância para o meio acadêmico e para investidores em geral. Saber qual a reação do mercado acionário na ocorrência de um anúncio de oferta de debênture permite que se estabeleça inferência e que sejam agregadas evidências a respeito de quais teorias de estrutura de capital melhor se ajustam ao contexto brasileiro. Além disso, se há uma reação significativa a esse tipo de evento, o sinal dessa reação é de suma importância para investidores que desejam se posicionar no mercado financeiro com base nesse tipo de evento. A mesma lógica se aplica ao trabalho sobre anúncios monetários americanos, saber se esse tipo de evento gera algum tipo de anormalidade de retorno no mercado acionário brasileiro contribuí para o desenvolvimento de novas pesquisas e para o melhor posicionamento do investidor.

## 2 Referencial Teórico

### 2.1 Modelos de precificação de ativos em finanças

#### 2.1.1 Modelos baseados em fatores

Um dos primeiros modelos de precificação de ativos foi desenvolvido por [Gordon e Shapiro \(1956\)](#), consistindo na divisão dos fluxos de caixa intermediários de uma firma qualquer  $i$  pela subtração entre o custo de capital  $k$  da firma e a taxa de crescimento dos dividendos (fluxos de caixa intermediários)  $g$ :

$$P_0 = \frac{D_0}{k - g}. \quad (2.1)$$

O modelo de Gordon possibilita ao investidor a determinação dos níveis requeridos de crescimento e custo de capital para que um investimento seja viável. No entanto, o modelo carece de um grau necessário de microfundamentação e de análise de equilíbrio de preços, necessários para o correto entendimento da dinâmica de preços no mercado financeiro.

Nesse sentido, [Markowitz \(1952\)](#) foi fundamental na definição de como o comportamento do investidor deveria ser considerado na construção de modelos de precificação de ativos. O autor argumenta que a função de utilidade dos agentes econômicos deveria considerar não somente os retornos dos ativos, mas também o nível de risco associado a eles. Para isso, assume-se um modelo de dois períodos  $t - 1$  e  $t$ , onde o retorno do portfólio escolhido no tempo  $t - 1$  será dado por uma variável aleatória no período  $t$ .

A abordagem da média-variância faz com que o agente econômico diversifique seu portfólio buscando eliminar fatores de risco idiossincrático, isto é, o risco inerente aos ativos por conta de suas características individuais. Assim, a regra da média-variância estabelecida por [Markowitz \(1952\)](#) faz com que o portfólio do investidor seja diversificado, introduzindo efetivamente uma regra objetiva sobre qual seria o comportamento racional de um agente econômico no mercado financeiro.

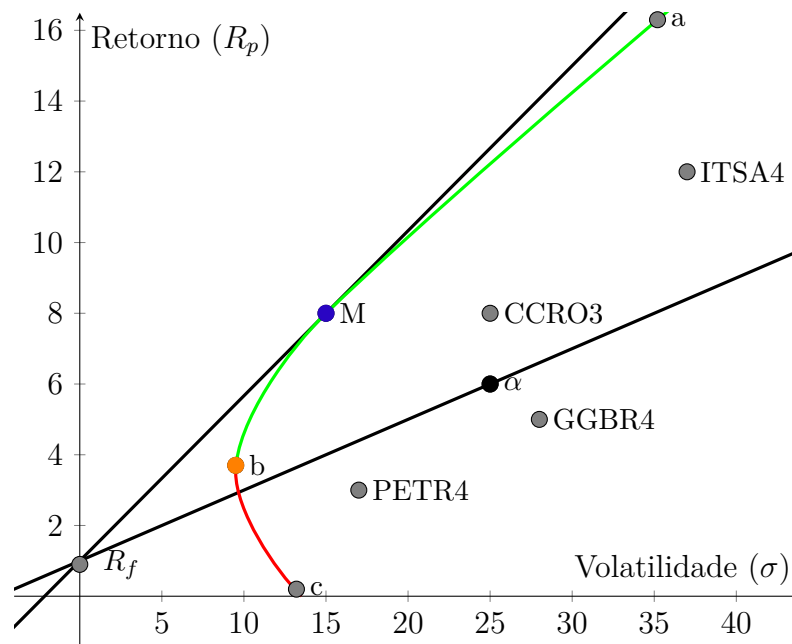
A regra da média variância se provou basilar na construção do primeiro modelo de equilíbrio de ativos no mercado financeiro, o Capital Asset Pricing Model (CAPM), desenvolvido separadamente por [Sharpe \(1964\)](#) e [Lintner \(1965\)](#). O modelo, diferente da hipótese proposta por [Markowitz \(1952\)](#), considera que os investidores possuem expectativas iguais com relação a distribuição de retornos para o período  $t$  e que é possível emprestar e tomar emprestado à taxa de juros livre de risco. Note que esse pressuposto de concordância com relação a distribuição de retornos para o período seguinte é exatamente a hipótese de



eficiência de mercado na sua forma forte (FAMA, 2013).

A figura 2 resume o CAPM e representa as oportunidades de investimento considerando portfólios com e sem a taxa de juros livre de risco. A área compreendida pela curva *abc* representa a fronteira de mínima variância para combinações de ativos com risco, note que para obter níveis maiores de retorno o investidor terá seu risco acrescido. O ponto *b* representa o portfólio de mínima variância, sendo os pontos abaixo dele ineficientes, já que os investidores podem obter o mesmo nível de retorno com volatilidades menores.

Figura 2 – Fronteira Eficiente



Nota: Elaboração do autor.

Com a inclusão da taxa de juros livre de risco, os investidores podem emprestar e tomar emprestado, desse modo, a fronteira eficiente de ativos passa a ser uma linha reta. Se um investidor alocar todos os seus recursos na taxa livre de risco o seu portfólio será o dado pelo ponto  $R_f$ , ao passo que a adição gradativa de ativos com risco fará com que ele se desloque cada vez mais próximo ao ponto  $\alpha$  e, uma vez passando o ponto, o investidor passa a tomar dinheiro emprestado para investir.

Contudo, pontos dentro da curva *abc* não são eficientes, então para obter combinações eficientes conforme a regra da média-variância, a curva deverá se deslocar para cima, tangenciando a curva *abc* no ponto  $M$ , que representa o portfólio do mercado. O CAPM considera que os retornos dos ativos são explicados por uma relação linear entre a taxa livre de risco e o prêmio pelo risco:

$$E(R_i) - r_f = \beta(R_m - r_f) \quad (2.2)$$

onde  $E(R_i)$  corresponde ao retorno do ativo  $i$ ,  $R_m$  é o retorno do mercado e  $r_f$  é o retorno da taxa livre de risco. O coeficiente  $\beta$  representa a sensibilidade do ativo em questão ao

risco sistemático da economia, não havendo remuneração pelo risco não sistemático, já que ele pode ser eliminado por meio da diversificação, um resultado obtido diretamente da hipótese da média variância. Essa relação delinea as combinações eficientes de ativos e possibilita a determinação do ponto sobre o qual haverá a maximização da utilidade dos agentes econômicos.

A grande vantagem do CAPM é a sua simplicidade, que permite interpretações relativamente diretas e aplicações práticas em meios não acadêmicos. Contudo, há custos associados a essa simplicidade que prejudicam consideravelmente o modelo, fazendo com que seus resultados sejam subestimados ou superestimados (BLUME; FRIEND, 1973; BLACK; JENSEN; SCHOLES, 1972). Nesse sentido, outros modelos buscaram relaxar algumas de suas restrições, levando a novas especificações como o Intertemporal Capital Asset Pricing Model (ICAPM) (MERTON, 1973), o Arbitrage Pricing Theory (APT) (ROSS, 1976) e os modelos multifatoriais de Fama e French e Carhart (FAMA; FRENCH, 1993; CARHART, 1997; FAMA; FRENCH, 2015).

Proposto por Merton (1973), o ICAPM relaxa o pressuposto de dois períodos do CAPM, fazendo com que o investidor ao alocar seus recursos no período  $t - 1$  se preocupe não somente com o payoff do período  $t$ , mas também com o conjunto de oportunidades de investimentos dos períodos subsequentes. As variáveis que afetam o conjunto de oportunidades de investimentos são chamadas de variáveis de estado e podem representar preços de bens de consumo ou salários, por exemplo. Dessa forma, o portfólio eficiente do ICAPM é composto pelo prêmio pelo risco visto no CAPM e por portfólios que atuam no sentido de realizar o hedge da incerteza no período  $t$ :

$$E(r_i) - r_f = \beta_{im}[E(R_m) - r_f] + \sum_{s=1}^S \beta_{is}[E(R_s) - r_f] \quad (2.3)$$

onde  $\beta_{is}$  com  $s = 1, \dots, S$  representam os betas das variáveis de estado e  $R_s$  são os retornos dos respectivos portfólios das variáveis de estado. O APT de Ross (1976), por outro lado, consiste em uma análise de equilíbrio parcial, onde os ativos têm seus riscos idiossincráticos eliminados por meio da diversificação dos investidores com relação a outros portfólios. Assim, um modelo APT com portfólios perfeitamente diversificados explicaria completamente a variação de preços de um ativo:

$$\tilde{x} = E_i + \beta_{i1}\tilde{\delta}_1 + \dots + \beta_{ik}\tilde{\delta}_k + \tilde{\varepsilon}_i \quad (2.4)$$

onde  $E_i$  é uma constante para o ativo  $i$ ,  $\tilde{\delta}_i$  representa um fator aleatório de risco sistemático e  $\beta_{ik}$  seria a sensibilidade do ativo  $i$  com relação aos fatores de risco sistemático. Apesar dos avanços proporcionados pelo ICAPM e pelo APT, os modelos não indicaram as variáveis que fariam parte das especificações multifatoriais, o que dificultou consideravelmente a transição do CAPM para modelos mais modernos.

O modelo de 3 fatores de Fama e French (1993) atua justamente no sentido de encontrar as variáveis que deveriam formar os modelos multifatoriais propostos, agregando

a literatura da época que mostrava a má especificação do CAPM quando comparado a modelos que levavam em conta outros fatores como tamanho (BANZ, 1981; BASU, 1983) e lucratividade (BASU, 1983) (estes são apenas alguns exemplos). Novos modelos envolvendo as variáveis encontradas pela literatura da época, contudo, tinham dificuldade em conciliar os resultados isolados em um modelo que de fato fosse superior ao CAPM, sendo esta a inovação do modelo de 3 fatores de Fama e French (1993):

$$R_i - r_f = \alpha + \beta_1(R_m - r_f) + \beta_2SMB + \beta_3HML + \varepsilon_i \quad (2.5)$$

onde as variáveis *SMB* (Small Minus Big) corresponde ao retorno de um portfólio que consiste na diferença entre os retornos de empresas de baixa capitalização de mercado e empresas de alta capitalização de mercado, enquanto a variável *HML* (High Minus Low) corresponde ao retorno de um portfólio composto pela diferença entre os retornos de empresas com alta razão de valor contábil e valor de mercado e empresas com baixa razão entre o valor contábil e valor de mercado.

Note que a busca por fatores que aprimorassem o CAPM culminou no modelo de 3 fatores de Fama e French (1993), que apesar de ser alicerçada nas provocações de modelo multifatoriais como o ICAPM e o APT, foi eminentemente empírica. Essa relação inversa na construção de modelos de precificação também pode ser vista nos modelo de Carhart (1997):

$$R_i - r_f = \alpha + \beta_1(R_m - r_f) + \beta_2SMB + \beta_3HML + \beta_4UMD + \varepsilon_i \quad (2.6)$$

que adiciona o fator *UMD*, que corresponde aos retornos de um portfólio da diferença entre os retornos de ações que apresentaram maior rendimento, menos ações que apresentaram menor rendimento. O modelo de Fama e French (2015), por fim, apresenta como variáveis adicionais fatores de lucratividade (RMW) e investimento (CMA):

$$R_i - r_f = \alpha + \beta_1(R_m - r_f) + \beta_2SMB + \beta_3HML + \beta_4RMW + \beta_5CMA + \varepsilon_i \quad (2.7)$$

### 2.1.2 Modelos baseados em consumo

Como dito, modelos baseados em consumo são um resultado direto do equilíbrio geral de Arrow e Debreu (1954), tendo a sua aplicação popularizada com o trabalho de Lucas (1978), mas para os objetivos deste trabalho a demonstração desse tipo de modelo será baseada na obra de Cochrane (2001). Modelos baseados em consumo estão interessados em saber qual será o valor presente de fluxos de caixa incertos, isto é, uma ação comprada no período  $t$  gerará o fluxo de caixa:

$$x_{t+1} = p_{t+1} + d_{t+1} \quad (2.8)$$

onde  $p_{t+1}$  é o preço da ação e  $d_{t+1}$  é o dividendo pago, sendo  $x_{t+1}$  uma variável aleatória. O valor deste payoff para o investidor que comprou a ação no período  $t$  será definido com

base na sua função de utilidade:

$$U(c_t, c_{t+1}) = u(c_t) + \beta E_t[u(c_{t+1})] \quad (2.9)$$

$$u(c_t) = \frac{1}{1-\gamma} c_t^{1-\gamma} \quad (2.10)$$

onde  $c_t$  e  $c_{t+1}$  representam o consumo dos períodos  $t$  e  $t+1$  e  $u(c_t)$  é a função de utilidade para o período  $t$ . A função de utilidade  $u(c_t)$  é crescente e côncava, indicando que há sempre um desejo por mais consumo, mas que a utilidade marginal do consumo é decrescente. O fator  $\beta$  representa a taxa de desconto subjetivo do agente econômico e serve para capturar a sua impaciência com relação as decisões de consumo. Definido o comportamento do investidor, é possível montar o problema de maximização de sua utilidade:

$$\max_{\xi} u(c_t) + E_t \beta u(c_{t+1}) \text{ s.a.} \quad (2.11)$$

$$c_t = e_t - p_t \xi \quad (2.12)$$

$$c_{t+1} = e_{t+1} - x_{t+1} \xi \quad (2.13)$$

onde  $e_t$  representa o consumo do investidor caso ele não compre nenhuma ação no período  $t$ ,  $p_t$  representa o preço da ação no período  $t$  e  $\xi$  é a quantidade de ações que ele compra. Quantas ações deverá o investidor comprar de modo a maximizar sua utilidade? A resposta para essa pergunta está justamente no preço da ação. Substituindo as restrições na função objetiva e igualando a derivada com respeito a  $\xi$  a zero, obtém-se a condição de primeira ordem para o consumo, que maximizará a utilidade do investidor:

$$p_t = E_t \left[ \beta \frac{u'(c_{t+1})}{u'(c_t)} x_{t+1} \right] \quad (2.14)$$

a partir da qual pode ser obtida a fórmula para apreçamento de ativos. Nota-se, portanto, que modelos baseados em consumo são problemas envolvendo decisões de consumo intertemporal, algo não tão diferente da proposta de modelos baseados em fatores. Contudo, observe que os pressupostos com relação ao comportamento do investidor vem de naturezas diferentes, enquanto modelos baseados em fatores (à exceção do APT) se baseiam na média variância, modelos baseados em consumo utilizam funções de utilidades na forma da equação 2.9, não havendo de forma inicial, por exemplo, conclusões relativas a diversificação ou fronteiras eficientes.

Contudo, isso não impede que o caráter generalista dos modelos baseados em consumo possa ser aplicado para chegar em modelos como o CAPM e o APT. Como mencionado na seção introdutória deste trabalho, modelos baseados em fatores são formas especializadas de modelos baseados em consumo. Considere uma função de utilidade quadrática de um investidor para dois períodos e sem renda de salários:

$$U(c_t, c_{t+1}) = -\frac{1}{2}(c_t - c^*)^2 - \frac{1}{2}\beta E[(c_{t+1} - c^*)^2] \quad (2.15)$$

onde  $c^*$  representa a aversão do investidor ao risco, sendo o ponto em que nenhuma oportunidade de investimento adicional pode compensar o risco incremental incorrido. A sua taxa marginal de substituição é dada por:

$$m_{t+1} = \beta \frac{u'(c_{t+1})}{u'(c_t)} = \beta \frac{(c_{t+1} - c^*)}{(c_t - c^*)}. \quad (2.16)$$

A riqueza do investidor no primeiro período é dada por  $W_t$ , sendo possível investir em ativos aos preços  $p_t^i$  com retornos  $R_{t+1}^i$ . As escolhas de consumo entre os períodos são definidas com base nos pesos dos portfólios  $\alpha_i$ , sendo a restrição de consumo dada por:

$$c_{t+1} = W_{t+1} \quad (2.17)$$

$$W_{t+1} = R_{t+1}^W (W_t - c_t) \quad (2.18)$$

$$R^W = \sum_{i=1}^N \alpha_i R^i; \sum_{i=1}^N \alpha_i = 1 \quad (2.19)$$

onde  $R^W$  é o retorno total do portfólio de mercado. Como a função de utilidade escolhida é formada somente por 2 períodos, toda a riqueza do investidor é consumida no segundo período, sendo possível substituir a riqueza do segundo período diretamente em  $c_{t+1}$ :

$$m_{t+1} = \beta \frac{R_{t+1}^W (W_t - c_t) - c^*}{(c_t - c^*)} = \frac{-\beta c^*}{(c_t - c^*)} + \frac{\beta (W_t - c_t)}{(c_t - c^*)} R_{t+1}^W \quad (2.20)$$

substituindo os termos  $\frac{-\beta c^*}{(c_t - c^*)}$  e  $\frac{\beta (W_t - c_t)}{(c_t - c^*)}$  por  $a_t$  e  $b_t$ , obtém-se a mesma relação linear do CAPM:

$$m_{t+1} = a_t + b_t R_{t+1}^W \quad (2.21)$$

## 2.2 Eficiência de mercado

A discussão a respeito da hipótese dos mercados eficientes teve sua gênese com o trabalho de [Bachelier \(2011\)](#), na qual o autor discute o comportamento aleatório dos preços no mercado financeiro, movimento este similar ao movimento Browniano discutido posteriormente pela área da física. [Fama \(1965b\)](#) e [Samuelson \(2015\)](#) foram os pioneiros na discussão sobre a hipótese dos mercados eficientes, apesar de seus trabalhos partirem de processos diferentes. Inicialmente, a eficiência de mercado discutida por [Fama \(1965b\)](#) se baseava em um processo de passeio aleatório, ao passo que o trabalho de [Samuelson \(2015\)](#) tinha como foco um processo martingale.<sup>1</sup> Posteriormente, [Fama \(1970\)](#) substituiu o processo de passeio aleatório por um processo de martingale, dado seu caráter mais generalista ([DELCEY, 2019](#)).

<sup>1</sup> Um processo martingale é um processo que descreve uma sequência de variáveis aleatórias, sendo o valor esperado da próxima variável igual ao valor da variável atual.

O que seria, no entanto, um mercado eficiente? Fama (1970) define um mercado eficiente como um mercado cujos preços dos ativos são um reflexo completo das informações disponíveis aos agente econômicos. A implicação imediata desse reflexo informacional completo nos preços dos ativos é que o caráter dessa série se torna aleatório, pois inovações nos preços dos ativos dependeriam de informações futuras, sendo este o motivo de processos como o passeio aleatório e martingale serem usados para formalizar a eficiência de mercado. Tome, por exemplo, a notação de Fama (1970):

$$E(\tilde{p}_{j,t+1}|\phi_t) = [1 + E(\tilde{r}_{j,t+1}|\phi_t)]p_{jt} \quad (2.22)$$

onde  $E(\tilde{p}_{j,t+1}|\phi_t)$  é o valor esperado do ativo  $j$  no tempo  $t + 1$ ,  $\tilde{r}_{j,t+1}$  é o retorno percentual de  $p_{jt}$  e  $\phi_t$  é o conjunto de informações disponíveis no tempo  $t$ .  $\tilde{p}_{j,t+1}$  e  $\tilde{r}_{j,t+1}$  são variáveis aleatórias. Note que independente do retorno esperado para próximo período, este retorno será um reflexo completo das informações disponíveis em  $\phi_t$ . Se os preços atuais já são um reflexo de todas as informações disponíveis, não há a possibilidade de um investidor obter ganhos com base em  $\phi_t$ , ou seja:

$$z_{j,t+1} = r_{j,t+1} - E(\tilde{r}_{j,t+1}|\phi_t) \quad (2.23)$$

onde  $z_{j,t+1}$  representaria o retorno de uma estratégia qualquer, a esperança dessa estratégia seria igual a:

$$E(\tilde{z}_{j,t+1}|\phi_t) = 0 \quad (2.24)$$

o que caracterizaria a estratégia como um jogo justo, sendo o eventual ganho ou prejuízo do investidor um reflexo do acaso. Considerando o conjunto de estratégias:

$$\alpha(\phi_t) = [\alpha_1(\phi_t), \alpha_2(\phi_t), \dots, \alpha_n(\phi_t)] \quad (2.25)$$

onde  $\alpha_j(\phi_t)$  representa uma quantidade qualquer a ser investida em  $n$  ativos com base no conjunto de informações de  $\phi_t$ , o retorno do investidor em  $t + 1$  seria igual a:

$$V_{t+1} = \sum_{j=1}^n \alpha_j(\phi_t)[r_{j,t+1} - E(\tilde{r}_{j,t+1}|\phi_t)] \quad (2.26)$$

onde, a partir da equação 2.24, nota-se que o retorno esperado será, novamente, igual a zero (jogo justo):

$$E(\tilde{V}_{t+1}|\phi_t) = \sum_{j=1}^n \alpha_j(\phi_t)E(\tilde{z}_{j,t+1}|\phi_t) = 0. \quad (2.27)$$

A definição de eficiência de mercado como o reflexo completo das informações nos preços dos ativos é demasiadamente ampla, o que dificulta a condução de testes empíricos de modo a suportá-la. Nesse sentido, Fama (1970) dividiu a hipótese dos mercados eficientes em três tipos: fraca, semi forte e forte. Na hipótese fraca, o conjunto de informações refletidas nos preços dos ativos diz respeito somente aos seus preços passados. Na hipótese

semi forte, os preços dos ativos são um reflexo de informações passadas e também de informações públicas de fácil acesso (notícias macroeconômicas, aumento de capital de uma empresa etc.). Por fim, na hipótese forte os preços dos ativos agregam até mesmo informações ocultas aos agentes econômicos, não sendo possível, por exemplo, que um investidor com informações privilegiadas obtenha ganhos anormais.

Cada subdivisão da hipótese dos mercados eficientes têm efeitos práticos em estratégias de investimentos. Caso um mercado se comporte conforme a hipótese fraca, estratégias de investimentos baseadas em análises gráficas ou padrões passados não passariam de mera adivinhação, já que as informações passadas já estão refletidas nos preços dos ativos. Um mercado que se comporta de maneira semi forte também dificulta análises baseadas em fundamentos das empresas, pois informações contábeis e macroeconômicas estariam igualmente refletidas nos preços, não havendo espaço para ganhos com base nessas informações. Isso não impediria, contudo, que analistas com insights sobre empresas obtivessem ganhos. O comportamento esperado de mercados eficientes na forma forte seria o mais próximo de um processo martingale, com investidores e fundos de investimentos dificilmente batendo os rendimentos do portfólio de mercado de forma consistente, já que ganhos e prejuízos seriam frutos da aleatoriedade ([FAMA, 1965a](#)).


## 3 Aspectos metodológicos

### 3.1 Estudos de eventos

Desenvolvida por [Ball e Brown \(1968\)](#) e [Fama et al. \(1969\)](#), a metodologia de estudo de eventos é uma das principais formas de se testar a hipótese semi forte de eficiência de mercado e consiste na identificação da reação do mercado acionário a eventos não antecipados. O trabalho de [Campbell, Lo e MacKinlay \(2012\)](#) sintetiza a metodologia de estudo de eventos em sete passos: definição da janela de eventos, critério de seleção, retornos normais e anormais, procedimento de estimação, procedimento de testes, resultados empíricos e interpretações e conclusões.

A definição da janela de eventos consiste na escolha da data de ocorrência do evento, bem como na definição de quantos dias ao redor do evento serão analisados. A escolha da janela é de grande importância, pois a reação do mercado pode ocorrer no dia do evento, antes do evento ou depois do evento. Contudo, janelas de eventos devem ser escolhidas com cautela, pois elas podem capturar a reação do mercado a outras ocorrências que não a do evento escolhido, contaminando o processo inferencial. Define-se a ocorrência de um evento como o momento  $\tau = 0$ , sendo delimitada a janela de eventos com tamanho  $L_2 = T_2 - T_1$  entre as datas  $\tau = T_1 + 1$  e  $T_2$ . Outra janela é definida sobre as datas anteriores ao evento analisado, sendo denominada janela de estimação, que tem tamanho igual a  $L_1 = T_1 - T_0$ , indo de  $\tau = T_0 + 1$  a  $T_1$ .

Figura 3 – Linha temporal de um estudo de eventos



Nota: Elaboração do autor.

Após a definição da janela de eventos, pode-se escolher a amostra que fará parte do estudo de eventos. Nesse sentido, o critério de seleção pode ter um caráter subjetivo, podendo o pesquisador escolher quais empresas farão parte do estudo, de modo a capturar efeitos setoriais ou na economia como um todo. Naturalmente, o critério de seleção deve observar empresas que possuam um mínimo de dados necessários para a condução da metodologia. A análise dos efeitos de um evento sobre os retornos de um determinado ativo é feita considerando a diferença entre o retorno real do ativo e o seu retorno esperado:

$$AR_{i,t} = R_{i,t} - E[R_{i,t}|X_t] \quad (3.1)$$



onde para o ativo  $i$  no tempo  $t$ ,  $AR_{i,t}$  representa o retorno anormal,  $R_{i,t}$  é o retorno efetivo do ativo e  $E[R_{i,t}|X_t]$  é o retorno esperado do ativo para o mesmo momento condicionado ao conjunto  $X_t$ . Isto é, a metodologia de estudo de eventos assume que o modelo de retornos normais (retorno esperado) é uma boa aproximação do retorno real do ativo escolhido. Assim, na ocorrência de um evento, o modelo escolhido apresentará resíduos de maior magnitude, pois o evento em si não é um fator previsto pelo modelo de precificação escolhido.

O modelo de retornos normais pode ser simplesmente um modelo de média constante:

$$R_{it} = \mu_i + \epsilon_{it} \quad (3.2)$$

onde o retorno do ativo  $R_{it}$  é dado por  $\mu_i$ , que representa a média dos retornos passados do ativo  $i$ . Assume-se que o modelo é homocedástico, isto é, com  $E[\epsilon_{it}] = 0$  e  $Var[\epsilon_{it}] = \sigma_\epsilon^2$ . Apesar da simplicidade do modelo de média constante, a performance dessa especificação consegue capturar razoavelmente bem anormalidades de retornos, mas essa mesma simplicidade fez com que melhores especificações para o cálculo dos retornos normais o substituíssem (BROWN; WARNER, 1980; CAMPBELL; LO; MACKINLAY, 2012).

Uma das formas mais populares de estimação de retornos normais é o modelo de mercado (SHARPE, 1963):

$$R_{it} = \alpha_i + \beta_i R_{mt} + \epsilon_{it} \quad (3.3)$$

onde o retorno  $R_{it}$  é dado por meio da sua regressão linear simples sobre  $R_{mt}$  que representa o retorno de um índice de mercado qualquer. O modelo de mercado é estimado por meio de Mínimos Quadrados Ordinários (MQO) e é assumida a homocedasticidade dos erros do modelo,  $E[\epsilon_{it}] = 0$  e  $Var[\epsilon_{it}] = \sigma_\epsilon^2$ . O modelo de mercado apresenta ganhos explicativos com relação ao modelo de médias constantes, mas a sua precisão dependerá da escolha de índices de mercado que capturem adequadamente a dinâmica de preços da variável dependente.

Corhay e Rad (1996) apresentam alternativas no processo de estimação do modelo de mercado, de modo a combater o fenômeno da heterocedasticidade. Os autores combinam o modelo de mercado com um processo GARCH (1,1) de modo a corrigir os resíduos do modelo:

$$\begin{aligned} \epsilon_{it} | \psi_{it} &\sim D(0, h_{it}, d) \\ \epsilon_{it} &= R_{it} - \alpha_i \beta_i R_{mt} \\ h_{it} &= \alpha_{i0} + \sum_{k=1}^p a_{ik} \epsilon_{it-k}^2 + \sum_{j=1}^q b_{ij} h_{it-j} \end{aligned} \quad (3.4)$$

onde  $\psi_{it}$  é o conjunto de informações até o momento  $t$  sobre a firma  $i$ ,  $h_{it}$  é a variância condicional da firma  $i$ , que é obtida a partir de um processo GARCH (1,1) e  $D$  segue uma distribuição t de student. A estimação dessa especificação do modelo de mercado é feita por meio de um estimador de máxima verossimilhança, sendo as anormalidades de

retornos apresentadas por essa especificação consideravelmente diferentes das encontradas com o modelo de mercado estimado por MQO.

Outras formas de estimação do modelo de retornos normais podem considerar modelos famosos de precificação, como o CAPM (SHARPE, 1964; LINTNER, 1965):

$$R_{it} - r_f = \alpha + \beta[R_{mt} - r_f] + \epsilon \quad (3.5)$$

onde  $R_{mt} - r_f$  representa o prêmio pelo risco, que é regredido sobre a diferença entre o retorno do ativo  $i$  e a taxa de juros livre de risco  $R_{it} - r_f$ . Outra opção é o modelo de 3 fatores de Fama e French (1993):

$$R_i - r_f = \alpha + \beta_1(R_m - r_f) + \beta_2SMB + \beta_3HML + \epsilon \quad (3.6)$$

que considera fatores adicionais mencionados na seção anterior relativos a tamanho  $SMB$  e valor contábil e de mercado  $HML$ . Apesar do modelo de 3 fatores de Fama e French (1993) capturar bem a dinâmica de preços no mercado financeiro, ele é um modelo consideravelmente mais complexo que o modelo de mercado e não apresenta ganhos relevantes de análise, sendo muitas vezes a escolha pelo modelo mais simples indicada (CAMPBELL; LO; MACKINLAY, 2012).

A estimação de modelos de retornos normais deve considerar janelas de estimação de tamanho adequado, que podem variar conforme os objetivos do estudo, mas uma janela popularmente utilizada é a de 252 dias úteis (BROWN; WARNER, 1980; MCWILLIAMS, 1997). Um cuidado essencial a ser tomado na metodologia de estudo de eventos é a não sobreposição das janelas de estimação e da janela de eventos, assim evita-se que haja a influência do evento sobre a estimação do modelo de retorno normais (não se pode modelar o evento em si, sob pena de não capturar adequadamente as anormalidades de retornos do evento).

Essa distinção entre janela de eventos e janela de estimação serve não somente para a estimação correta do modelo de retornos normais, mas também para a correta construção do teste estatístico que estabelecerá inferência se os retornos anormais da janela de eventos são diferentes de zero ou não. Para condução dos testes estatísticos em um estudo de eventos, os retorno anormais são acumulados para todos os dias da janela de eventos:

$$\begin{aligned} CAR_i &= \sum_{\tau=T_1+1}^{T_2} AR_{it} \\ CAAR &= \frac{1}{N} \sum_{i=1}^N CAR_i \end{aligned} \quad (3.7)$$

onde  $CAR_i$  são os retornos anormais acumulados da empresa  $i$  para um evento qualquer e  $CAAR$  são os retornos anormais acumulados médios de  $N$  eventos distintos. Essas duas medidas de anormalidades de retornos permitem a mensuração dos efeitos de eventos de

forma isolada e de forma agregada, sendo os testes associados a cada uma dessas medidas dados por:

$$J_1 = \frac{CAR}{(S_{CAR}^2)^{\frac{1}{2}}} \quad (3.8)$$

$$J_2 = \frac{CAAR}{\sqrt{N} (S_{CAAR}^2)^{\frac{1}{2}}} \quad (3.9)$$

onde  $J_1$  e  $J_2$  seguem uma distribuição t de Student e testam a hipótese nula de que os retornos anormais acumulados e os retornos anormais acumulados médios são iguais a zero. A variância dos retornos anormais acumulados  $S_{CAR}^2$  é obtida por meio da distribuição de retornos anormais da janela de estimação:

$$S_{CAR}^2 = L_2 S_{AR}^2$$

$$S_{AR}^2 = \frac{1}{L_1 - 1} \sum_{\tau=T_0}^{T_1} (AR_\tau - \overline{AR})^2 \quad (3.10)$$

onde  $S_{AR}^2$  é a variância dos retornos anormais para a janela de estimação. A variância dos retornos anormais acumulados médios é obtida por meio da equação:

$$S_{CAAR}^2 = \frac{1}{N - 1} \sum_{i=1}^N (CAR_i - CAAR)^2. \quad (3.11)$$

Note, portanto, a importância da separação adequada entre a janela de eventos e a janela de estimação. A sobreposição das duas janelas resultaria não somente em parâmetros viesados do modelo de retornos normais, mas também na obtenção errônea da variância dos retornos anormais, estatística fundamental para o procedimento de inferência estatística na metodologia.

Uma alternativa para teste de hipótese nula utilizando o modelo GARCH complementarmente pode ser vista no trabalho de [Savickas \(2003\)](#). O autor estima um modelo de mercado considerando um processo GARCH (1,1) associado a uma variável dummy para medir os efeitos do evento de interesse (valor 1 para datas em que há a ocorrência de um evento e valor 0 caso contrário):

$$R_{i,t} = \alpha_i + \beta_i R_{m,t} + \gamma_i D_t + \eta_{i,t} \quad (3.12)$$

$$h_{i,t} = a_i + b_i h_{i,t-1} + c_i \eta_{i,t-1}^2 + d_i D_t \quad (3.13)$$

$$\eta_{i,t} | \omega_t \sim N(0, h_{it}) \quad (3.14)$$

onde os parâmetros estimados do modelo são  $\alpha_i$ ,  $\beta_i$ ,  $\gamma_i$ ,  $a_i$ ,  $b_i$  e  $c_i$ ,  $D_i$  é a uma variável dummy correspondente à data do evento de interesse e  $\omega_t$  é o conjunto de informações disponível até o momento  $t$  para os retornos do ativo  $i$  e do índice de mercado  $m$ .  $h_{it}$  é a volatilidade estimada pelo processo GARCH (1,1), que consiste nas observações passadas da própria volatilidade estimada  $h_{i,t-1}$  e dos erros do modelo  $\eta_{i,t-1}^2$ . Essa construção de

modelo de mercado, associado a variáveis dummy, busca capturar a heterocedasticidade presente na série temporal, bem como uma possível volatilidade induzida por eventos, que pode contaminar o processo inferencial (essa associação de modelos GARCH com variáveis dummy também pode ser vista no trabalho de [Balaban e Constantinou \(2006\)](#) e [Padula e Albuquerque \(2018\)](#)).

O retorno anormal nesse especificação é dado pelo parâmetro  $\gamma_i$  que mede os efeitos do evento sobre os retornos do ativo  $i$ . A partir dessa medida de retorno anormal, o autor propõe o seguinte teste estatístico:

$$J_3 = \sum_{i=1}^N \frac{S_{i,t}}{N} \sqrt{\frac{1}{N(N-1) \sum_{i=1}^N (S_{i,t} - \sum_{j=1}^N S_{j,t}/N)^2}} \quad (3.15)$$

$$S_{i,t} = \frac{\hat{\gamma}_i}{\sqrt{\hat{h}_{it}}} \quad (3.16)$$

pelo qual [Savickas \(2003\)](#) argumenta superioridade a outros testes quando é observada volatilidade induzida por eventos.

Para modelagem dinâmica de betas na amostra, modelos GARCH podem ser vistos no trabalho de [Reyes \(1999\)](#):

$$R_{i,t} = \alpha_i + \beta_i R_{m,t} + \delta_i \left( \frac{R_{m,t}}{\hat{\sigma}_{m,t}^2} \right) + e_{i,t} \quad (3.17)$$

onde a volatilidade do índice de mercado  $\hat{\sigma}_{m,t}^2$  é obtida por meio de um processo MA(1)-GARCH(1,1) (Moving Average GARCH):

$$\begin{aligned} R_{m,t} &= \mu + \epsilon_{mt} + \theta \epsilon_{m,t-1} \\ \sigma_{m,t}^2 &= a_m + b_m \epsilon_{m,t-1}^2 + c_m \sigma_{m,t-1}^2 \end{aligned} \quad (3.18)$$

no qual  $\epsilon_{mt}$  segue uma distribuição igual a  $N(0, \sigma_{m,t}^2)$  (veja o trabalho de [Koutmos et al. \(2018\)](#) para uma aplicação alternativa de modelos GARCH na construção de betas dinâmicos).

# 4 Anúncios de Oferta de Debêntures com Abordagem MGARCH: Análise da Reação do Mercado Brasileiro no Período de 2012 a 2022

## Resumo

**Resumo** Emissões de dívidas são eventos que alteram a estrutura de capital das empresas de forma relevante, sendo a reação do mercado acionário a estes acontecimentos uma temática largamente estudada pela academia por meio de estudos de eventos. Contudo, muitos trabalhos falham ao não modelar o fenômeno da volatilidade ao calcular as anormalidades de retornos ao redor de eventos de emissão de dívidas, de modo que os resultados obtidos podem conter vieses relevantes. Este trabalho utiliza a metodologia de estudo de eventos aliada a forma bivariada do modelo BEKK-GARCH para analisar as emissões de debêntures no mercado acionário brasileiro entre 2012 e 2022. Os resultados obtidos indicam haver uma reação negativa do mercado acionário aos eventos de aprovação de emissões de debêntures no mercado brasileiro. Em análise por meio de modelos explicativos foi identificada uma correlação negativa entre o montante de dívida anunciada e os retornos anormais acumulados observados e uma relação positiva entre o retorno sobre o patrimônio e as anormalidades detectadas nas datas dos eventos.

**Palavras-chave:** Estudo de eventos; GARCH; Teorias de estrutura de capital.

**Código JEL:** G12, G14, G32.

**Abstract** Debt issues are events that change the capital structure of firms in a relevant manner, and the reaction of the market to these events is a widely researched topic using event study methodology. However, many works fail by not modeling the phenomenon of volatility when calculating return abnormalities around debt issue events, so that results obtained contain relevant biases. This work uses event study methodology allied with the bivariate form of the BEKK-GARCH model to analyze the debt issues in the brazilian stock market between 2012 and 2022. The results obtained indicate that there is a negative reaction of the stock market to the events of debt issue approvals in the brazilian market. Regression analysis reveals a negative relation between the amount of debt advertised and cumulative abnormal returns and a positive relationship between the return on equity and abnormalities on the date of the events.

**Keywords:** Event study; GARCH; Capital Structure Theories.

**JEL Code:** G12, G14, G32.

## 4.1 Introdução

O trabalho de [Modigliani e Miller \(1958\)](#) marca o início do desenvolvimento das teorias de estrutura de capital, propondo a irrelevância da estrutura de capital das firmas sobre o seu valor de mercado. Após essa proposição inicial, diversas teorias exploraram pressupostos pouco desenvolvidos na teoria da irrelevância da estrutura de capital, como o contexto de assimetria informacional e fricções de mercado.

A Trade-Off Theory, por exemplo, incorpora custos de falência e impostos na busca de um ponto ótimo para o financiamento da firma por meio de capital de terceiros ([KRAUS; LITZENBERGER, 1973](#)). Outras teorias como a Pecking Order Theory ([MYERS; MAJLUF, 1984](#)) e a Signalling Theory ([ROSS, 1977](#)) se desenvolvem no contexto de assimetria informacional. Enquanto a Pecking Order Theory propõe a existência de uma hierarquia nas decisões de financiamento da firma, a Signalling Theory argumenta que o financiamento por meio de dívida seria um sinal positivo ao mercado de que a firma possui projetos de investimento rentáveis. A Agency Theory, por outro lado, busca explicar a formação das estruturas de capital com base nos conflitos existentes entre os administradores e os donos das firmas ([JENSEN; MECKLING, 1976](#)).

As conclusões das teorias de estrutura de capital muitas vezes vão em direções opostas, não havendo uma teoria única capaz de explicar as decisões de financiamento das firmas de forma completa. De igual modo, há variabilidade na aderência empírica das teorias supracitadas sendo necessário o levantamento de evidências que deem suporte para uma determinada teoria em diferentes contextos econômicos, regulatórios e setoriais ([KUMAR; SUREKA; COLOMBAGE, 2020](#); [BAJAJ; KASHIRAMKA; SINGH, 2021](#)).

Emissões de dívidas são eventos corporativos que representam mudanças na estrutura de capital das firmas, sendo uma das formas de se verificar as conclusões das diversas teorias de estrutura de capital, a partir da reação do mercado acionário sobre o evento. Apesar da ampla pesquisa sobre o tema, os resultados são diversos, indo desde impactos negativos sobre a firma emissora ([DANN; MIKKELSON, 1984](#); [SPIESS; AFFLECK-GRAVES, 1999](#)), impactos positivos ([FUNGÁČOVÁ; GODLEWSKI; WEILL, 2020](#)) ou nenhum impacto ([DANN; MIKKELSON, 1984](#); [BEST, 1994](#)).

Estes trabalhos, bem como a maioria dos trabalhos a respeito de estrutura de capital, estão situados em mercados de economias desenvolvidas, havendo uma carência de evidências para os mercados de economias em desenvolvimento ([BAJAJ; KASHIRAMKA; SINGH, 2021](#)). [Berninger, Fiesenig e Schiereck \(2021\)](#) avançaram nessa direção ao estudar uma amostra de emissões de debêntures da América Latina, associando os retornos

anormais dos eventos ao ciclo econômico do país em que a empresa está inserida.

No contexto brasileiro, o trabalho de [Matsumoto, Baraldi e Jucá \(2018\)](#) utiliza uma amostra de 11 empresas compreendida no período entre 2014 e 2015 para analisar anúncios de emissões de debêntures, indicando haver uma reação positiva do mercado acionário aos eventos. Apesar desta tentativa recente, é necessária uma maior exploração do mercado brasileiro com trabalhos que analisem extratos temporais e amostras maiores, tirando proveito da grande expansão que o mercado de debêntures brasileiro passou nos últimos anos. No ano de 2022, por exemplo, as ofertas de debêntures representaram metade das emissões no mercado de capitais brasileiro (Conforme noticiado pela [ANBIMA](#))

Além disso, muitos estudos de eventos a respeito de emissões de dívidas estão contaminados com o fenômeno da heterocedasticidade e realizam abordagens mais simples, considerando betas fixos e desconsiderando a variabilidade do erro ao longo do tempo. A não modelagem de tais fenômenos pode contaminar de forma significativa os resultados obtidos na condução de estudos de eventos e, para obter resultados confiáveis, é interessante que trabalhos que utilizem a metodologia levem em conta tais particularidades.

O modelo GARCH, proposto por [Bollerslev \(1986\)](#), tem sido amplamente utilizado em estudos de eventos para modelar a volatilidade das séries temporais. [Corhay e Rad \(1996\)](#), por exemplo, estimam um modelo de mercado com erros corrigidos por um processo GARCH (1,1) e apresentam diferenças significantes nos retornos anormais obtidos quando comparados aos resultados calculados pela estimação clássica. [Reyes \(1999\)](#) corrobora os resultados de [Corhay e Rad \(1996\)](#) e argumenta pela necessidade da modelagem do beta ao longo do tempo, de modo a obter estimativas mais precisas de retornos anormais.

[Savickas \(2003\)](#), por sua vez, incorpora a modelagem da volatilidade na metodologia com o modelo GARCH e propõe um novo teste estatístico, argumentando pela sua superioridade. [Balaban e Constantinou \(2006\)](#) associam o modelo GARCH a variáveis dummy para estudar fusões e aquisições no Reino Unido, analisando não somente os retornos anormais relativos aos eventos, mas também a volatilidade.

A modelagem da volatilidade também pode ser empregada para identificar mudanças no risco sistemático durante a ocorrência de um evento. Esta foi a linha de raciocínio do trabalho de [Koutmos et al. \(2018\)](#) que utilizam o modelo EGARCH para modelar o risco sistemático ao longo de emissões de dívidas, mostrando variações significativas no beta das empresas durante os eventos analisados.

Abordagens mais recentes, no entanto, utilizam modelos multivariados da família GARCH para lidar tanto com o fenômeno da heterocedasticidade, quanto para modelar a dinâmica da volatilidade entre as séries temporais em um estudo de eventos (Apesar da ideia de modelar o beta com modelos MGARCH ser antiga ([BAUWENS; LAURENT; ROMBOUTS, 2006](#)), o seu uso em estudos de eventos ainda não é tão difundido).

Yin et al. (2018), por exemplo, utilizam a metodologia de estudo de eventos para analisar anúncios de lucratividade de empresas de Hong Kong. Os autores inovam a metodologia ao empregar o modelo multivariado BEKK-GARCH proporcionando que seja controlado tanto o fenômeno da heterocedasticidade, quanto o risco sistemático ao longo do estudo de eventos. Os autores mostram que a modelagem de tais fatores reduz a magnitude dos retornos anormais acumulados na amostra analisada, bem como altera sua significância estatística, quando comparado a metodologia clássica.

Outro trabalho que segue uma linha similar de correções é o de Avelino (2022) que analisa fusões e aquisições no mercado brasileiro, utilizando um modelo BEKK-GARCH assimétrico para aprimorar a metodologia de estudo de eventos. O autor compara a consistência da modelagem multivariada com outras abordagens clássicas univariadas, indicando uma maior adequação dos modelos multivariados.

Este trabalho busca contribuir com a literatura vigente ao utilizar a metodologia de estudos de eventos associada ao modelo bivariado BEKK-GARCH para analisar as emissões de debêntures no mercado brasileiro. Dessa forma, espera-se contribuir para o cenário escasso de evidências a respeito da formação da estrutura de capital em mercados de países em desenvolvimento, considerando uma abordagem empírica recente que leva em conta fragilidades relevantes não consideradas em outros trabalhos empíricos a respeito do tema.

O restante deste trabalho está estruturado da seguinte maneira: a seção 2 revisa as teorias de estrutura de capital, bem como estudos de eventos que tem como temática emissões de dívida. A seção 3 apresenta a amostra de dados do trabalho e delinea a abordagem metodológica. Na seção 4 são expostos os resultados do trabalho. Por fim, as conclusões são apresentadas na seção 5.

## 4.2 Revisão de Literatura

### 4.2.1 Teorias de estrutura de capital

Após a proposição inicial da irrelevância da estrutura de capital, Modigliani e Miller (1963) acrescentam impostos na teoria da irrelevância da estrutura de capital, indicando haver benefícios fiscais no financiamento por dívida, já que juros são uma despesa dedutível no imposto de renda. No entanto, a inclusão de impostos sem a consideração dos custos associados a níveis de alavancagem crescentes leva a conclusão pouco factível de que as firmas deveriam se financiar totalmente com capital de terceiros.

De forma complementar, Kraus e Litzenberger (1973) associam ao conceito de benefício fiscal, os custos de falência. Níveis mais altos de alavancagem estariam associados a riscos mais altos falência, o que faria com que houvesse um ponto no qual o benefício



marginal de um incremento no nível de alavancagem fosse igual ao custo marginal associado ao risco de falência. Assim, há um ponto ótimo para a alavancagem da firma, conclusão que iniciou a corrente teórica que seria posteriormente chamada de Trade-off Theory.

Ross (1977), proponente da Signalling Theory, por outro lado, leva em consideração o contexto informacional das decisões de financiamento das firmas. De modo geral, os administradores das firmas são remunerados com relação ao seu desempenho, sendo este medido pelo valor de mercado da empresa sob sua gerência. O administrador de uma firma, possui um grau de informação superior sobre a situação da firma ao dos acionistas, sendo que a emissão de uma dívida carrega informações relevantes com relação às perspectivas da firma.

Ao anunciar um aumento na alavancagem da firma (por meio da emissão de dívida), o administrador sinaliza ao mercado a perspectiva de que a empresa possui bons projetos para investir e a capacidade de honrar os pagamentos de juros no futuro. Assim, percebendo o bom posicionamento da empresa no mercado no momento, os investidores se tornam otimistas, comprando mais ações e elevando o valor de mercado da firma. Isto, como consequência, elevaria a remuneração do administrador, que seria desincentivado a mentir sobre a posição da empresa, por conta dos custos de falência e da queda nos preços incorridos quando há a descoberta da incapacidade de honrar os compromissos de pagamento de juros.

A Agency Theory, proposta por Jensen e Meckling (1976), argumenta que conflitos entre os administradores (agente) e donos da firma (principal) são fatores determinantes para a formação da sua estrutura de capital. Os conflitos entre o agente e o principal surgem dado que há diferentes interesses de cada um deles no que desejam realizar com a firma. Por um lado, o principal, por ser dono da firma, desejará que o agente tome decisões de modo a maximizar a sua utilidade, enquanto o agente possui incentivos para maximizar a própria utilidade, dada a restrição de ser demitido caso faça uma má gestão da firma.

No contexto da emissão de dívidas, o conflito entre o agente e o principal acontece no momento da emissão, onde o agente promete utilizar os recursos provenientes da dívida para financiar um projeto de baixo risco, conseguindo, assim, captar os recursos necessários e dando tranquilidade aos credores. O agente pode, no entanto, captar o dinheiro com a promessa de investir em projetos de baixo risco e, após conseguir os recursos, investir em projetos de alto risco, elevando, assim, o valor das ações da empresa. Nesse caso, há uma transferência de riqueza entre os donos da dívida e o administrador da empresa. Sabendo da possibilidade desse cenário, os credores podem estabelecer mecanismos de monitoramento e garantias contratuais, de modo a obrigar o administrador da firma a cumprir o prometido. Essas medidas constituem os custos de agência.

Myers e Majluf (1984) argumentam pela existência de uma hierarquia nas decisões de financiamento das firmas, devendo elas se financiarem primeiro por meio de caixa,

depois através de capital de terceiros e somente em última hipótese deve se levantar capital por meio da emissão de ações. Essa hierarquia é dada por conta dos custos crescente associados a assimetria de informações entre a empresa e os investidores, sendo tais custos iguais a zero no financiamento por meio de caixa (financial slack) e atingindo o maior nível no financiamento com ações.

O financiamento por meio da emissão de ações seria recebido de forma negativa pelos investidores, que por saberem que possuem um grau de informação inferior ao da administração da empresa, assumem que a oferta de ações indicaria uma sobrevalorização no preço das ações. Assim, os investidores negociariam as novas ações a um preço abaixo do esperado pela firma, acarretando em um custo de capital superior. A emissão de dívidas, por outro lado, está associada ao incremento da alavancagem da firma e dos consequências custos de financial distress associados. Assim, quanto maior o risco da dívida emitida pela firma, maior será o risco do mercado reagir negativamente.

#### 4.2.2 Estudos de eventos sobre emissão de dívida

[Dann e Mikkelson \(1984\)](#) é um dos primeiros trabalhos a analisar eventos de aprovações de emissões de debêntures e a emissão propriamente dita. Os autores utilizam uma amostra de debêntures simples e conversíveis emitidas no mercado americano, identificando retornos anormais negativos somente para debêntures conversíveis, tanto na data de anúncio de aprovação, quanto na data de emissão. Os autores acreditam que a anormalidade negativa no momento das emissões pode ser explicada por novas informações a respeito das debêntures.

De igual modo, [Best \(1994\)](#) também encontra retornos anormais estatisticamente iguais a zero para emissões de debêntures simples e negativos para debêntures conversíveis. [Howton, Howton e Perfect \(1998\)](#), por outro lado, mostram um resultado distinto do apresentado, indicando que a emissão de debêntures simples estaria associada a retornos anormais negativos no dia da emissão. Os autores associam os retornos anormais negativos a um excesso de caixa disponível na firma, o que implicaria em maiores probabilidades de conflitos de agência.

[Spiess e Affleck-Graves \(1999\)](#) também analisam eventos de emissão de debêntures simples e conversíveis no mercado americano, mas utilizando a metodologia de estudos de eventos de longo prazo. Diferente do observado por [Dann e Mikkelson \(1984\)](#) os autores observam baixa performance tanto das firmas emissoras de debêntures simples, quanto das que emitiram debêntures conversíveis. Isso estaria em harmonia com o argumento de que a emissão de dívida por parte das empresas indicaria uma sobrevalorização do seu preço no mercado acionário.

Em literatura mais recente, [Koutmos et al. \(2018\)](#) é outro trabalho que emprega

a metodologia, dessa vez para analisar emissões de dívida das empresas do FTSE 100, verificando que a reação do mercado acionário a tais eventos pode variar conforme o ciclo econômico. De forma similar, [Berninger, Fiesenig e Schiereck \(2021\)](#) realizam um estudo de eventos sobre emissões de debêntures na América Latina e mostram haver uma reação negativa a emissões de debêntures. Contudo, os autores expõem que o sinal da reação do mercado acionário pode variar conforme o ciclo econômico, sendo negativo em períodos de recessão e positivo em períodos de estabilidade.

[Mansley et al. \(2023\)](#) também associam emissões de dívida a ciclos, mas dessa vez tendo como foco o ciclo de crescimento associado às empresas da amostra. Os autores analisam emissões de dívida por parte de fundos imobiliários americanos, mostrando que eventos de emissão de dívida relacionados a períodos de crescimento virtuoso dos fundos estão associados a retornos anormais positivos, ao passo que emissões de dívida associadas a projetos de crescimento ruim estão associados a retornos anormais negativos.

Também há evidências de que o aumento do capital de terceiros na estrutura de capital de uma empresa está associado a certificação da sua saúde financeira. [Fungáčová, Godlewski e Weill \(2020\)](#) analisam eventos de emissão de dívida e de contração de empréstimo no mercado europeu identificando anormalidade positiva para os dois tipos de eventos, sendo ela de maior magnitude quando a empresa consegue um empréstimo. Isso se daria pelo fato de que o aumento da alavancagem da firma reduziria seus custos de agência e sinalizaria a disponibilidade de projetos com valor presente líquido positivo, além de certificar a saúde financeira da firma, no caso dos empréstimos com bancos.

Outros trabalhos associam eventos de emissão de dívida a elementos ESG (Environmental, Social and Governance). [Yi et al. \(2021\)](#) mostram que debêntures verdes tiveram uma menor desvalorização durante a pandemia da Covid-19, sendo o mesmo resultado inferido para as empresas emissoras, bem como para empresas com melhores estruturas de governança. De fato, há evidências que a presença de elementos que indiquem responsabilidade social e corporativa está positivamente correlacionada com reações positivas em eventos de emissão de dívida, como mostra o trabalho de [Velayutham e Ratnam \(2022\)](#).

## 4.3 Procedimentos Metodológicos

### 4.3.1 Amostra de Dados

A amostra escolhida pelo estudo foi a das empresas que compõem a metodologia de cálculo do índice Ibovespa. O Ibovespa representa cerca de 80% das negociações do mercado acionário brasileiro, sendo constituído das maiores e mais importantes empresas do Brasil. Foram coletados na base de dados da Economatica os preços diários, dados contábeis trimestrais e setoriais das 88 ações que fazem parte da metodologia de cálculo

do Ibovespa para o período entre 2012 e 2022, bem como os dados dos preços diários do índice Ibovespa para o mesmo período. A tabela 1 agrega as variáveis utilizadas no estudo.

A amostra de eventos do estudo é constituída de anúncios de aprovações de emissões de debêntures por parte dos conselhos de administração das empresas da amostra. Para coletar os dados referentes às datas dos eventos de aprovação de emissões de debêntures, foram verificados todos os fatos relevantes e os comunicados ao mercado disponíveis na base de dados da Comissão de Valores Mobiliários (CVM) e nos sites de relações institucionais das empresas da amostra, sendo considerada a data de divulgação do fato relevante referente a aprovação de emissão da debênture definida como data de ocorrência do evento.

Tabela 1 – Variáveis do Estudo

Variável	Definição
Ativo	Logaritmo do Ativo Total
Emissão	Valor anunciado/Ativo Total
Liquidez Corrente	Ativo Circulante/Passivo Circulante
Retorno sobre o Patrimônio Líquido (ROE)	Lucro Líquido/Patrimônio Líquido
Endividamento	Endividamento Bruto/Ativo Total
Caixa	Fluxo de Caixa/Ativo Total
Custo da Emissão	Taxa Percentual acumulada de 12 meses do IDA
CAR	Retorno Anormal Acumulado
Retornos diários da empresa <i>i</i>	$R_{i,t} = \ln \frac{P_t}{P_{t-1}}$
Retornos diários da Ibovespa	$R_{m,t} = \ln \frac{P_t}{P_{t-1}}$

Nota: Testes de estacionariedade dos retornos das empresas e do índice Ibovespa disponíveis em anexo. Dados obtidos na base de dados da Economatica. Elaboração do autor.

Os seguintes critérios foram aplicados aos dados coletados: i) Somente foram considerados eventos relativos a debêntures simples; ii) Somente foram considerados eventos as datas de aprovação de emissão de debêntures, e não a emissão em si; iii) Eventos com menos de 500 retornos diários anteriores a sua ocorrência foram excluídos; iv) Na ocorrência de sobreposição de eventos para uma mesma empresa, foi considerada como data do evento a data do primeiro evento na sobreposição. Após a aplicação dos filtros foi obtida uma amostra de 54 empresas, que podem ser consultadas no apêndice. No total foram identificados 200 anúncios de aprovação de emissão de debêntures entre 2012 e 2022.

A tabela 2 apresenta a evolução temporal nos anúncios de emissões de debêntures. Até o ano de 2016, emissões de debêntures não foram a alternativa de financiamento mais popular entre as firmas da amostra, no período de 5 anos foram 54 eventos de aprovações de emissões correspondendo a aproximadamente 43,1 bilhões de reais. A partir do ano de 2019 há um incremento expressivo, havendo 110 eventos no período e atingindo um máximo de quase 60 bilhões de reais anunciados em 2022.

A tabela 3 expõe o número de aprovações de emissões por setor econômico. Os

Tabela 2 – Evolução anual dos anúncios de emissão de debêntures

Ano	Eventos	Total Anunciado (Milhões de R\$)
2012	13	11.905
2013	12	6.120
2014	9	5.640
2015	15	13.900
2016	5	5.461
2017	22	19.020
2018	14	12.355
2019	29	34.828,7
2020	20	22.412
2021	23	29.381,31
2022	38	57.226

Nota: Dados obtidos nos sistemas CVM. Elaboração do autor.

setores de Utilidade Pública e Consumo Cíclico se destacam do restante, correspondendo a mais de 40% das emissões da amostra, ao passo que os setores de Comunicações e Tecnologia da Informação apresentam a menor participação, emitindo 5% das debêntures da amostra.

Tabela 3 – Emissões de debêntures por setor econômico

Setor	Eventos	Percentual
Bens Industriais	21	10,50%
Comunicações	6	3,00%
Consumo Cíclico	43	21,50%
Consumo Não Cíclico	19	9,50%
Financeiro	18	9,00%
Materiais Básicos	17	8,50%
Petróleo, Gás e Biocombustíveis	8	4,00%
Saúde	24	12,00%
Tecnologia da Informação	4	2,00%
Utilidade Pública	40	20,00%
Total	200	100,00%

Nota: Definição setorial realizada com base nos dados da B3. Elaboração do autor.

## 4.3.2 Metodologia

### 4.3.2.1 Estudo de eventos

A metodologia utilizada pelo trabalho é a de estudo de eventos, que está bem documentada em [Campbell, Lo e MacKinlay \(2012\)](#). De modo geral, um estudo de eventos busca estimar o impacto de um evento não antecipado sobre os retornos de uma série

temporal. O nome dado ao efeito de um evento sobre os retornos de um ativo é retorno anormal, que consiste na subtração entre o retorno real do ativo e o retorno esperado para o mesmo momento no tempo:

$$AR_{i,t} = R_{i,t} - E[R_{i,t}|X_t] \quad (4.1)$$

onde  $AR_{i,t}$  representa o retorno anormal do ativo  $i$  no tempo  $t$ ,  $R_{i,t}$  é o retorno observado do ativo  $i$  no tempo  $t$  e  $E[R_{i,t}|X_t]$  é o retorno esperado para o ativo  $i$  no tempo  $t$ , condicionado a  $X_t$ . Define-se  $\tau = 0$  como o momento da ocorrência do evento analisado. Sobre esta data é delimitado um intervalo, denominado de janela de eventos, que vai de  $\tau = T_1 + 1$  até  $\tau = T_2$ .

De modo a estabelecer se o evento teve efeitos sobre os retornos da firma estudada, a metodologia de estudo de eventos estima o comportamento esperado para a ação na ausência do evento, por meio de um modelo de retornos normais. A estimação dos retornos normais é feita considerando uma janela de estimação anterior ao evento estudado, indo desde  $\tau = T_0 + 1$  até  $\tau = T_1$ . Assim, o tamanho da janela de estimação é igual a  $L_1 = T_1 - T_0$  e o tamanho da janela de eventos é igual a  $L_2 = T_2 - T_1$ .

A lógica da estimação dos retornos normais para uma ação consiste na suposição que o modelo escolhido é uma boa aproximação para os retornos reais do ativo estudado. Na presença de um evento não antecipado, no entanto, o modelo de retornos normais deixa de ser uma boa explicação para o comportamento dos retornos da firma de interesse, já que o modelo não captura informações relativas ao evento. Desse modo, é possível mensurar o efeito do evento desejado sobre a série temporal estudada.

O modelo mais popular para estimação de retornos normais, dada a sua simplicidade, é o modelo de mercado (SHARPE, 1963; MCWILLIAMS, 1997; CAMPBELL; LO; MACKINLAY, 2012). O modelo consiste na regressão linear simples do ativo de interesse  $i$  sobre um índice de mercado  $m$ , que no caso do estudo é representado pelo índice Ibovespa:

$$R_{i,t} = \alpha_i + \beta_i R_{m,t} + \varepsilon_{i,t} \quad (4.2)$$

onde  $R_{i,t}$  representa os retornos para o ativo  $i$ ,  $R_{m,t}$  corresponde aos retornos do índice de mercado e  $\varepsilon_{i,t}$  é o termo de erro. Esse modelo, no entanto, não leva em conta a presença de heterocedasticidade nas séries temporais e pressupõe que o  $\beta$  estimado é fixo ao longo da condução do estudo de eventos.

Para lidar com as problemáticas supracitadas o artigo utilizou o modelo bivariado BEKK-GARCH, proposto por (ENGLE; KRONER, 1995a):

$$R_{it} = \mu_i + \varepsilon_{it} \quad (4.3)$$

$$R_{mt} = \mu_m + \varepsilon_{mt} \quad (4.4)$$

$$\mathbf{H}_t = \mathbf{C}'_0 \mathbf{C}_0 + \mathbf{A}' \varepsilon_{t-1} \varepsilon'_{t-1} \mathbf{A} + \mathbf{B}' \mathbf{H}_{t-1} \mathbf{B} \quad (4.5)$$

onde  $(R_{i,t}, R_{m,t})$  representam os retornos das  $i$  empresas da amostra e os retornos do índice de mercado Ibovespa, representado por  $m$ , ambos no tempo  $t$ .  $\mu_i = E[R_{it}|\Omega_{t-1}]$  e  $\mu_m = E[R_{mt}|\Omega_{t-1}]$ , são as médias incondicionais dos retornos do ativo  $i$  e do índice de mercado  $m$  condicionados ao conjunto de informações  $\Omega_{t-1}$ .  $H_t$  é uma matriz 2x2 contendo as variâncias e as covariâncias do ativo  $i$  e o do índice de mercado  $m$  e  $\mathbf{C}_0$ ,  $\mathbf{A}$  e  $\mathbf{B}$  são matrizes 2x2 contendo os parâmetros estimados pelo modelo.

A matriz  $\varepsilon_{t-1}$  representa os resíduos passados da empresa  $i$  e do índice de mercado  $m$ , ao passo que a matriz  $\mathbf{H}_{t-1}$  representa os valores passados de suas variâncias e covariâncias. A matriz de variâncias e covariâncias  $\mathbf{H}_t = \begin{bmatrix} h_{11} & h_{12} \\ h_{21} & h_{22} \end{bmatrix}$  é o resultado do modelo BEKK, a partir da qual foi calculado o beta variante no tempo:

$$\hat{\beta}_{i,t} = \frac{h_{12,t}}{h_{22,t}} \quad (4.6)$$

sendo a especificação do modelo de retornos normais utilizada:

$$R_{i,t} = \mu_i + \beta_{i,t} R_{m,t} + \varepsilon_{i,t} \quad (4.7)$$

que foi estimada considerando uma janela de estimação de 500 dias. Classicamente, a janela de estimação em estudos de eventos é de 252 dias úteis (BROWN; WARNER, 1980; MCWILLIAMS, 1997). No entanto, Hwang e Valls Pereira (2006) mostram a necessidade de janelas de estimação de pelo menos 500 dias para modelar processos GARCH adequadamente, sendo essa a escolha feita pelo presente trabalho. Após a estimação dos modelos, foram calculados os retornos anormais:

$$AR_{i,t} = R_{i,t} - \hat{\mu}_i - \hat{\beta}_{i,t} R_{m,t} \quad (4.8)$$

Para realizar o processo inferencial sobre os eventos como um todo, são calculados os retornos anormais acumulados e os retornos anormais acumulados médios:

$$CAR_i = \sum_{\tau=T_1+1}^{T_2} AR_{i,t} \quad (4.9)$$

$$CAAR = \frac{1}{N} \sum_{\tau=T_1+1}^{T_2} CAR_{i,t} \quad (4.10)$$

onde  $CAR_i$  representa os retornos anormais acumulados para a empresa  $i$  na janela de eventos compreendida entre  $T_1$  e  $T_2$  e  $CAAR$  são os retornos anormais acumulados médios para os  $N$  eventos analisados. Para testar as hipóteses de que os retornos anormais acumulados ou os retornos anormais acumulados médios são diferentes de zero, são empregados os seguintes testes:

$$J_1 = \frac{CAR_{i,t}}{(S_{CAR}^2)^{\frac{1}{2}}} \quad (4.11)$$

$$J_2 = \frac{CAAR}{\frac{(S_{CAAR}^2)^{\frac{1}{2}}}{\sqrt{N}}} \quad (4.12)$$

onde  $J_1$  e  $J_2$  seguem distribuições t de Student.  $S_{CAR}^2$  é a variância dos retornos anormais acumulados e  $S_{CAAR}^2$  a variância dos retornos anormais acumulados médios, calculados da seguinte maneira:

$$S_{CAR}^2 = L_2 S_{AR}^2 \quad (4.13)$$

$$S_{AR}^2 = \frac{1}{L_1 - 1} \sum_{\tau=T_0}^{T_1} (AR_{\tau} - \overline{AR})^2 \quad (4.14)$$

$$S_{CAAR}^2 = \frac{1}{N - 1} \sum_{i=1}^N (CAR_i - CAAR)^2 \quad (4.15)$$

#### 4.3.2.2 Análise de regressão

Para explicar as anormalidades de retornos observadas nos eventos de aprovações de emissão de debêntures, foi realizada a regressão dos retornos anormais acumulados conforme o seguinte modelo:

$$\begin{aligned} CAR_i = & \alpha_i + \beta_1 Ativo + \beta_2 Emissao + \beta_3 ROE + \\ & \beta_4 Endividamento + \beta_5 Caixa + \\ & \beta_6 LiquidezCorrente + \beta_7 CustoEmissao + \\ & \sum_{k=1}^N \gamma_k Setor_k \end{aligned} \quad (4.16)$$

onde a regressão proposta é composta de variáveis de controle de características específicas das firmas, bem como de variáveis de controle setorial. As variáveis Ativo e Liquidez Corrente foram definidas conforme observado em [Kumar, Colombage e Rao \(2017\)](#). A variável Ativo controla o tamanho das empresas da amostra, conforme os autores há uma relação positiva entre o tamanho da empresa e o endividamento dela. Também há evidências de que a liquidez de uma firma está negativamente correlacionada a sua estrutura de capital, dado que empresas com alto nível de liquidez não precisam recorrer a fontes de financiamento externo.

As variáveis Caixa e Emissão foram incluídas com base no trabalho de [Howton, Howton e Perfect \(1998\)](#). O caixa da empresa serve como medida para possíveis conflitos de agência, isto é, se uma empresa já possui um nível alto nível de recursos em caixa, a alavancagem adicional não seria uma boa notícia, pois os recursos adicionais representariam uma maior probabilidade de conflitos de agência. A variável Emissão controla o tamanho da debênture anunciada, identificando o grau de mudança na estrutura de capital da firma, ao passo que a variável Custo Emissão é uma proxy para o custo associado à debênture ofertada. Para controlar a lucratividade e a rentabilidade das empresas da amostra, foi utilizada a variável de retorno sobre o patrimônio líquido (ROE). A variável  $Setor_k$  controla as especificidades setoriais das empresas do trabalho.



## 4.4 Resultados

A tabela 4 apresenta os CAR's, bem como os testes estatísticos associados de modo a verificar a reação do mercado acionário aos eventos de aprovações de emissões de debêntures. A primeira coluna representa as diversas combinações de janelas de eventos utilizadas, indo desde 3 dias ( $T_1 = -1, T_2 = +1$ ) até 41 dias, buscando capturar tanto antecipações ao evento, quanto ajustes posteriores do mercado à nova informação disponível.

Pelo percentual de retornos anormais acumulados positivos nos eventos de anúncio de emissão de debêntures nota-se que, de modo geral, a reação a este tipo de evento no mercado brasileiro é negativa. Esta linha de raciocínio é reforçada ao se verificar os resultados dos testes estatísticos com relação aos retornos anormais acumulados médios (CAAR's), representados pela média dos retornos anormais acumulados. Em todas as janelas de eventos analisadas a anormalidade nos retornos foi negativa, sendo verificada significância estatística nas janelas de 15 e 21 dias ao nível de 5% e nas janelas de 31 e 41 dias, ao nível de 1%.

Tabela 4 – Estatísticas descritivas e testes estatísticos dos CAR's, BEKK bivariado

Janela de Eventos	Média	Mediana	Máximo	Mínimo	Desvio Padrão	Percentual Positivo
$T_1 = -1, T_2 = +1$	-0,001	-0,003	0,135	-0,159	0,033	0,470
$T_1 = -2, T_2 = +2$	-0,001	-0,004	0,176	-0,105	0,041	0,445
$T_1 = -3, T_2 = +3$	-0,003	-0,006	0,195	-0,134	0,052	0,435
$T_1 = -4, T_2 = +4$	-0,006	-0,008	0,220	-0,176	0,057	0,425
$T_1 = -5, T_2 = +5$	-0,005	-0,011	0,222	-0,196	0,063	0,430
$T_1 = -7, T_2 = +7$	-0,011**	-0,013	0,282	-0,239	0,077	0,370
$T_1 = -10, T_2 = +10$	-0,016**	-0,017	0,356	-0,250	0,095	0,405
$T_1 = -15, T_2 = +15$	-0,023***	-0,032	0,367	-0,319	0,107	0,380
$T_1 = -20, T_2 = +20$	-0,032***	-0,046	0,410	-0,546	0,134	0,405

Nota: Esta tabela apresenta as estatísticas descritivas dos retornos anormais acumulados (CAR's) calculados considerando como modelo de retornos normais a forma bivariada do modelo BEKK GARCH. A coluna da média é referente aos retorno anormais acumulados médios (CAAR's). \*, \*\*, \*\*\* indicam os níveis de significância estatística aos níveis de 10%, 5% e 1%, respectivamente. Elaboração do autor.

Em média, anúncios de aprovação de debêntures geraram retornos de  $-3,2\%$  considerando uma janela de eventos de 41 dias. O valor mínimo de anormalidade capturada pela abordagem metodológica realizada foi a de um anúncio de emissão de debênture da empresa Hapvida, em um anúncio ocorrido no dia 19/04/2022, totalizando um retorno anormal acumulado negativo de  $-54,68\%$  ao longo de 41 dias e estatisticamente significativo ao nível de 1%. O evento com valor máximo de anormalidade foi uma emissão de debênture aprovada pela Gol no dia 11/10/2018, correspondendo a um retorno anormal acumulado de  $41,04\%$  para a janela de 41 dias, sendo estatisticamente significativo ao nível de 5% (Os resultados relativos aos retornos anormais acumulados individuais para as empresas da amostra do trabalho podem ser obtidos sob demanda.).

Os resultados apresentados indicam haver uma reação negativa do mercado acionário brasileiro a eventos que indiquem incrementos na alavancagem das empresas. Estes resultados estão em conformidade com os trabalhos de Best (1994) e Spiess e Affleck-Graves (1999) e vão de encontro ao que foi encontrado por Matsumoto, Baraldi e Jucá (2018), que indicou uma reação positiva do mercado acionário brasileiro a eventos de anúncios de emissão de debêntures.

A reação negativa do mercado acionário brasileiro pode ser interpretada à luz da Agency Theory, dado que o aumento das disponibilidades da empresa aumentaria os conflitos de agência entre acionistas e administradores. A possibilidade de captura dos recursos provenientes da emissão levaria os investidores a reagirem negativamente aos anúncios, dado que tais recursos podem ser aplicados em projetos pouco rentáveis ou para expandir a empresa além do ponto ótimo, de modo a beneficiar o administrador.

#### 4.4.1 Medidas alternativas de anormalidade

De forma alternativa, nesta seção são apresentados os resultados de modelos univariados para cálculo de retornos normais em estudos de eventos. Foram implementadas duas especificações do modelo de mercado, uma estimada por meio de Mínimos Quadrados Ordinários (MQO) conforme feito em Campbell, Lo e MacKinlay (2012) e outra considerando erros corrigidos por um processo GARCH (1,1), implementado por Corhay e Rad (1996).

Tabela 5 – Estatísticas descritivas e testes estatísticos dos CAR's, Modelo de Mercado

Janela de Eventos	Média	Mediana	Máximo	Mínimo	Desvio Padrão	Percentual Positivo
$T_1 = -1, T_2 = +1$	-0,001	-0,003	0,137	-0,161	0,033	0,465
$T_1 = -2, T_2 = +2$	0,000	-0,001	0,174	-0,133	0,041	0,485
$T_1 = -3, T_2 = +3$	-0,002	-0,004	0,203	-0,137	0,052	0,460
$T_1 = -4, T_2 = +4$	-0,004	-0,008	0,231	-0,179	0,057	0,445
$T_1 = -5, T_2 = +5$	-0,004	-0,009	0,224	-0,200	0,063	0,445
$T_1 = -7, T_2 = +7$	-0,009	-0,012	0,279	-0,246	0,077	0,410
$T_1 = -10, T_2 = +10$	-0,013*	-0,013	0,357	-0,239	0,093	0,430
$T_1 = -15, T_2 = +15$	-0,017**	-0,027	0,383	-0,304	0,108	0,405
$T_1 = -20, T_2 = +20$	-0,023**	-0,025	0,429	-0,544	0,133	0,420

Nota: Esta tabela apresenta as estatísticas descritivas dos retornos anormais acumulados (CAR's) calculados considerando como modelo de retornos normais o modelo de mercado na sua forma padrão  $R_{i,t} = \alpha_i + \beta_i R_{m,t} + \varepsilon$ . A janela de estimação foi a mesma utilizada pela abordagem com o modelo BEKK GARCH. A coluna da média é referente aos retornos anormais acumulados médios (CAAR's). \*, \*\*, \*\*\* indicam os níveis de significância estatística aos níveis de 10%, 5% e 1%, respectivamente. Elaboração do autor.

Considerando os resultados do modelo de mercado estimado por MQO, expostos na tabela 5, as anormalidades são similares as obtidas com a abordagem multivariada. Em todas as janelas de eventos os retornos anormais acumulados médios permaneceram negativos, sendo possível observar significância estatística nas janelas de 21 dias ao nível

de 10% e 31 e 41 dias ao nível de 5%. Houve uma redução na magnitude da anormalidade percebida nos retornos, medida tanto pela média, quanto pela mediana.

De modo geral, os resultados apresentados com a modelagem clássica são de menor magnitude quando comparados a abordagem multivariada, mas continuam estatisticamente significantes. Isso mostra que há diferenças significantes na metodologia de estudos de eventos quando não é considerado o fenômeno da heterocedasticidade e assume-se que o beta das empresas é fixo durante os eventos.

Por fim, a tabela 6 expõe os resultados obtidos com o modelo de mercado que considera a presença de heterocedasticidade nos retornos. Apesar da anormalidade percebida nos retornos permanecer negativa, nenhuma janela de eventos apresentou significância estatística, com a exceção da janela de 31 dias que é significativa ao nível de 10%. A magnitude da anormalidade também é menor quando comparada às abordagens clássica e multivariada, apesar de os valores máximos e mínimos de anormalidade acumulada serem sensivelmente maiores do que nas outras especificações utilizadas.

Tabela 6 – Estatísticas descritivas e testes estatísticos dos CAR's, Modelo de Mercado com erros corrigidos GARCH

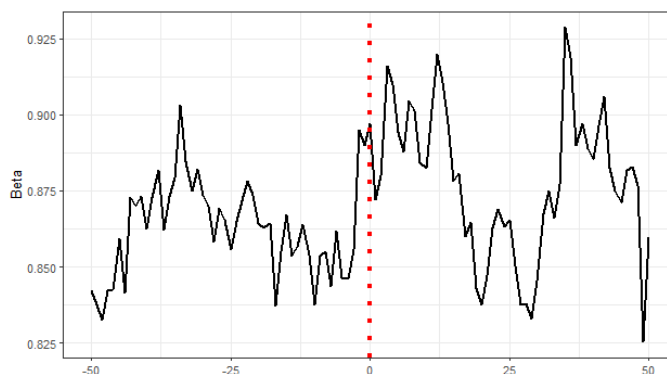
Janela de Eventos	Média	Mediana	Máximo	Mínimo	Desvio Padrão	Percentual Positivo
$T_1 = -1, T_2 = +1$	-0,003	-0,002	0,129	-0,175	0,038	0,465
$T_1 = -2, T_2 = +2$	-0,001	-0,001	0,204	-0,162	0,047	0,475
$T_1 = -3, T_2 = +3$	-0,001	-0,002	0,221	-0,152	0,057	0,485
$T_1 = -4, T_2 = +4$	-0,003	-0,004	0,244	-0,165	0,062	0,470
$T_1 = -5, T_2 = +5$	-0,002	0,002	0,257	-0,195	0,068	0,515
$T_1 = -7, T_2 = +7$	-0,007	-0,004	0,355	-0,261	0,086	0,470
$T_1 = -10, T_2 = +10$	-0,012	-0,012	0,391	-0,319	0,106	0,450
$T_1 = -15, T_2 = +15$	-0,016*	-0,022	0,532	-0,369	0,122	0,435
$T_1 = -20, T_2 = +20$	-0,017	-0,009	0,612	-0,575	0,148	0,470

Nota: Esta tabela apresenta as estatísticas descritivas dos retornos anormais acumulados (CAR's) calculados considerando como modelo de retornos normais o modelo de mercado com erros corrigidos por um processo GARCH (1,1)  $R_{i,t} = \alpha_i + \beta_i R_{m,t} + \varepsilon$ , estimado via Máxima Verossimilhança. A janela de estimação foi a mesma utilizada pela abordagem com o modelo BEKK GARCH. A coluna da média é referente aos retorno anormais acumulados médios (CAAR's). \*, \*\*, \*\*\* indicam os níveis de significância estatística aos níveis de 10%, 5% e 1%, respectivamente. Elaboração do autor.

#### 4.4.2 Análise de volatilidade

A análise da volatilidade observada ao longo dos eventos foi feita considerando uma medida indireta da volatilidade das séries temporais analisadas, na forma do beta variante no tempo calculado por meio do modelo BEKK GARCH bivariado. A figura 4 representa o beta médio das empresas da amostra do estudo ao redor de eventos de aprovações de debêntures e mostra que o pressuposto frequentemente utilizado em estudos de eventos de que a sensibilidade ao risco sistemático das empresas é fixo com o passar do tempo e, em especial, durante a ocorrência de eventos, não se concretiza.

Figura 4 – Beta médio ao longo de 101 dias ao redor dos anúncios de emissão



Nota: Elaboração do autor.

De modo a estabelecer inferência se os eventos analisados possuíam efeitos sobre o risco sistemática das empresas da amostra, foram conduzidos testes paramétricos e não paramétricos com relação aos valores da sua média e mediana, antes e depois dos eventos analisados. Os resultados, disponíveis na tabela 7 indicam não haver diferenças significantes no valor do beta antes da ocorrência dos eventos relativos aprovações de emissões de debêntures, não havendo diferença estatisticamente significativa tanto na média, quanto na mediana para os intervalos explorados.

Tabela 7 – Beta médio ao redor dos anúncios

Intervalo do Beta	Média	p-valor	Mediana	p-valor
Beta [-50,-1]	0,862	-	0,863	-
Beta [-50,-25]	0,865	0,501	0,859	0,258
Beta [-25,-1]	0,860	0,436	0,859	0,258
Beta [0,+1]	0,884	0,330	0,884	0,500
Beta [0,+2]	0,882	0,110	0,879	0,250
Beta [0,+3]	0,891*	0,061	0,888	0,125
Beta [0,+4]	0,895***	0,018	0,897*	0,062
Beta [0,+5]	0,894***	0,005	0,895**	0,031
Beta [0,+50]	0,878***	0,000	0,879***	0,000

Nota: Nesta tabela é apresentada a média dos betas ao redor de todos os eventos da amostra. Os betas foram estimados considerando 500 observações anteriores à ocorrência dos eventos e 50 observações posteriores. O teste estatístico associado a coluna da média é o teste t de diferença de médias, enquanto o teste da coluna de mediana é o teste de Wilcoxon. \*, \*\*, \*\*\* indicam os níveis de significância estatística aos níveis de 10%, 5% e 1%, respectivamente. Elaboração do autor.

Após os anúncios de aprovações de emissões de debêntures, no entanto, observa-se uma mudança substancial na média e na mediana do beta, o que indica que os eventos analisados possuem efeitos não somente sobre os retornos das séries temporais, mas também sobre a sensibilidade delas ao risco sistemático e, por consequência, sobre a sua volatilidade.

Estes resultados estão em harmonia com os achados de Yin et al. (2018) e Koutmos et al. (2018), sendo um indicativo da necessidade da modelagem do risco sistemático durante todo o extrato temporal da metodologia de estudo de eventos.

De fato, os resultados apresentados indicam que a desconsideração de um beta variante no tempo pode fazer com que haja uma perda relevante de informações, principalmente no momento de calcular os retornos anormais. Essa variação significativa no beta das empresas da amostra ao redor dos eventos analisados é uma possível explicação do porquê os retornos anormais obtidos com o modelo BEKK GARCH foram sensivelmente diferentes dos obtidos com o modelo de mercado clássico e com o modelo de mercado que considera erros GARCH (1,1).

### 4.4.3 Resultados das regressões MGARCH

Para analisar qualitativamente as anormalidades de retornos detectadas, 4 modelos explicativos foram empregados, considerando todas as janelas de eventos estatisticamente significantes obtidas por meio do modelo BEKK. Os modelos representados pelas colunas 2, 3, 4 e 5 tem como variável dependente os retornos anormais acumulados dos eventos da amostra nas janelas de 15, 21, 31 e 41 dias.

Os resultados da regressão considerando o CAR para a janela de 15 dias mostram que a reação do mercado acionário aos eventos de ofertas de debêntures apresentou uma correlação negativa com o tamanho da emissão, resultado significativo ao nível de 5%. As variáveis ROE e Endividamento Total apresentaram uma correlação positiva com as anormalidades de retornos na amostra ao nível de 1%, enquanto a variável Liquidez apresentou um sinal positivo, mas ao nível de 10% apenas, não sendo possível estabelecer inferência de forma robusta com relação a esta variável. Nenhuma das outras variáveis apresentou significância estatística.

Os resultados obtidos por meio da regressão sobre a janela de 15 dias são de certa forma repetidos para as regressões sobre as janelas de 21 e 31 dias, apesar de haver uma queda no nível de significância para a variável relativa a magnitude da debênture anunciada e a perda da significância estatística para a variável de mede o endividamento das firmas. Na regressão sobre os retornos anormais acumulados de 41 dias não são observadas variáveis estatisticamente significantes. O resultado positivo e persistente da variável ROE apresenta alguma evidência de suporte à hipótese levantada pela Signalling Theory. Empresas com ROE's altos podem sinalizar aos investidores bons prospectos de investimentos, o que ensinaria uma reação positiva do mercado acionário, apesar do incremento na alavancagem da firma.

Um resultado interessante é que enquanto o endividamento total está positivamente correlacionado com anormalidades de retornos, aumento adicionais apresentam um sinal

Tabela 8 – Resultados dos modelos explicativos

	CAR_15	CAR_21	CAR_31	CAR_41
Intercepto	-0,074 (-0,685)	-0,042 (-0,297)	0,093 (0,507)	-0,251 (-0,980)
Ativo	-0,0004 (-0,080)	0,001 (0,134)	-0,004 (-0,515)	0,014 (1,068)
Emissão	-0,106** (-2,117)	-0,134* (-1,882)	-0,125* (-1,777)	-0,083 (-0,871)
ROE	0,020*** (5,270)	0,012*** (3,125)	0,023*** (4,435)	-0,0007 (-0,113)
Endividamento	0,066*** (2,657)	0,019 (0,562)	-0,038 (-1,111)	-0,018 (-0,390)
Caixa	-0,146 (-1,084)	-0,836 (-0,466)	0,002 (0,356)	-0,003 (-0,012)
Liquidez Corrente	0,009* (1,775)	0,010 (1,474)	0,002 (-0,356)	-0,005 (-0,565)
Custo da Emissão	0,196 (1,151)	0,024 (0,117)	0,072 (0,296)	0,083 (0,278)
Efeitos fixos setoriais	Sim	Sim	Sim	Sim
Observações	182	182	182	182
R2	0,121	0,075	0,095	0,080

Nota: Nesta tabela são apresentados os resultados da estimação de 4 modelos de regressão sobre os retornos anormais acumulados obtidos por meio da metodologia de estudo de eventos considerando o modelo bivariado BEKK GARCH. Os modelos 1, 2, 3 e 4 são referentes aos retornos anormais acumulados de 15, 21, 31 e 41 dias, respectivamente, como variáveis dependentes. Os modelos foram estimados considerando erros padrão robustos, conforme White (1980). Foram omitidos 18 eventos por ausência de dados contábeis para as datas. \*, \*\*, \*\*\* indicam os níveis de significância estatística aos níveis de 10%, 5% e 1%, respectivamente. Elaboração do autor.

contrário. A Trade-off Theory e a Agency Theory podem de certa forma explicar este fenômeno, já que algum nível de alavancagem é desejável, por conta do tax shield, mas níveis adicionais de endividamento podem ultrapassar o ponto ótimo da firma e aumentar custos relacionados a falência ou custos de agência.

## 4.5 Conclusões

Este trabalho teve como objetivo avaliar a reação do mercado acionário brasileiro a eventos de aprovações emissões de debêntures por parte do conselho de administração das empresas, no período compreendido entre 2012 e 2022. Para isso, foi utilizada metodologia de estudos de eventos aliada a forma bivariada do modelo BEKK GARCH, de modo a considerar tanto a presença de heterocedasticidade nas séries temporais, quanto a modelar um beta variante no tempo.

Os resultados do trabalho apontam para uma reação estatisticamente significativa e negativa do mercado acionário aos eventos analisados, correspondendo o retorno anormal acumulado médio a -3,2% durante 41 dias ao redor das datas de aprovações de emissões de debêntures. Além disso, foram observadas variações significativas no beta das empresas da amostra ao redor dos eventos analisados, em especial após a ocorrência dos eventos, indicando que eventos relacionados a debêntures no mercado brasileiro possuem efeitos não somente sobre os retornos das empresas, mas também sobre as suas sensibilidades ao risco sistemático.

Foram observadas diferenças significativas entre os resultados obtidos por meio da modelagem clássica, a modelagem considerando a presença de heterocedasticidade e a forma multivariada empregada pelo trabalho. A magnitude dos retornos anormais acumulados obtidos por meio do modelo BEKK GARCH foi significativamente maior, quando comparada aos resultados dos outros modelos, sendo o mesmo observado para o nível de significância estatística. Estes resultados sugerem a necessidade da correta modelagem da heterocedasticidade em estudos de eventos, bem como indicam haver uma inadequação no pressuposto de um beta fixo. Contudo, uma maior investigação é necessária para verificar se esse tipo de suporte metodológico é de fato superior à abordagem clássica.

A reação negativa do mercado acionário brasileiro aos eventos estudados dá suporte às conclusões da teoria da agência, apontando que incrementos no caixa das empresas brasileiras por meio de dívida poderiam aumentar os conflitos de agência. Além disso, foram identificadas duas variáveis capazes de explicar a anormalidade de retornos nos eventos de aprovações de emissões de debêntures: montante anunciado de dívida (negativamente correlacionada) e retorno sobre o patrimônio líquido (positivamente correlacionada).

As contribuições deste trabalho vão no sentido de fornecer evidências a respeito de eventos relativos à debêntures no mercado brasileiro, que foi pouco explorado pela literatura nesse sentido. A reação negativa do mercado acionário brasileiro está em harmonia com outros trabalhos da literatura internacional como [Best \(1994\)](#) e [Spiess e Affleck-Graves \(1999\)](#). Contudo, os resultados apresentados diferem de forma significativa aos obtidos por [Matsumoto, Baraldi e Jucá \(2018\)](#), provavelmente pela amostra significativamente maior e por diferenças no extrato temporal e na abordagem metodológica.

# 5 Reação do Mercado Acionário Brasileiro a Anúncios do FOMC: um estudo de eventos com abordagem MGARCH no período entre 2012 e 2022

## Resumo

**Resumo** A investigação dos efeitos da política monetária americana sobre o mercado acionário é uma temática amplamente documentada pela literatura. Contudo, trabalhos mais recentes buscam determinar os efeitos da transmissão da política monetária americana para o mercado financeiro de outros países, em especial, para países emergentes. Este trabalho busca contribuir com essa corrente da literatura ao associar a metodologia de estudo de eventos a modelos GARCH multivariados para verificar a reação do mercado acionário brasileiro a anúncios de política monetária por parte do Federal Open Market Committee (FOMC), buscando lidar com fragilidades conhecidas da metodologia e fornecer evidências a respeito do pouco explorado contexto brasileiro. Os resultados do trabalho mostram que apesar de ser verificada a presença de anormalidades de retornos no mercado brasileiro em alguns anúncios do FOMC, a reação do mercado brasileiro é, em geral, eficiente, sendo os agentes econômicos brasileiros capazes de se antecipar às notícias monetárias americanas. Contudo, nas ocorrências em que há uma reação estatisticamente significativa do mercado brasileiro aos comunicados do FOMC, verificou-se que tal reação pode ser explicada pela presença de informações relativas à forward guidance.

**Palavras-chave:** Estudo de eventos; GARCH; Transbordamento da política monetária.

**Código JEL:** G12, G14, G15.

**Abstract** The investigation of the effects of US monetary policy on the stock market is widely documented in the literature. However, recent works seek to determine the effects of the transmission of US monetary policy to the financial markets of other economies, in particular, to emerging economies. This work seeks to contribute to the literature by associating the event study methodology with multivariate GARCH models to verify the reaction of the Brazilian stock market to monetary policy announcements by the Federal Open Market Committee (FOMC), seeking to deal classical problems of the methodology and provide evidence about the underexplored Brazilian context. The results of the work show that despite the presence of abnormal returns in the Brazilian market in some FOMC



announcements, the market reaction is, in general, efficient, being the Brazilian market able to anticipate American monetary news. However, in cases where there is a statistically significant reaction by the Brazilian market to the FOMC announcements, it was found that such reaction can be explained by the presence of information related to forward guidance.

**Keywords:** Event study; GARCH; Monetary policy spillover.

**JEL Code:** G12, G14, G15.

## 5.1 Introdução

Mudanças na política monetária de um país são informações relevantes para os agentes econômicos do mercado financeiro, dado que variáveis como a taxa de juros e câmbio possuem influências diretas sobre seus rendimentos. De fato, o mercado financeiro é o primeiro setor da economia a reagir a mudanças na taxa de juros e o mercado acionário em especial possui uma sensibilidade considerável a variações na política monetária, dado que mudanças na taxa de desconto da economia alteram de forma significativa o valor de seus ativos, alterando o fluxo de caixa descontado de firmas e títulos de renda fixa (THORBECKE, 1997; BERNANKE; KUTTNER, 2005).

Thorbecke (1997) evidencia o efeito da política monetária sobre o mercado financeiro por meio de estudos de eventos, indicando que políticas monetárias expansionistas do banco central americano estariam associadas a maiores retornos do mercado financeiro americano. Rigobon e Sack (2003), por outro lado, mostram que a relação entre taxas de juros e retornos do mercado acionário também ocorre na via inversa e mostram que um aumento hipotético de 5% no índice S&P500 levaria a uma contração monetária de 25 pontos base na taxa de juros americana.

A relação entre política monetária e mercado financeiro é bem documentada na literatura e, de modo especial, no caso de decisões sobre a política monetária americana. Veja, por exemplo, os trabalhos a respeito de surpresas monetárias observadas em anúncios do Federal Open Market Committee (FOMC) de Rigobon e Sack (2004) e Bernanke e Kuttner (2005). Os dois trabalhos apresentam resultados semelhantes indicando que mudanças não antecipadas na taxa de juros por parte da autoridade monetária americana possuem efeitos consideráveis sobre os retornos do mercado acionário. Não somente as medidas convencionais de política monetária anunciadas pelo FOMC possuem efeitos sobre os retornos do mercado acionário dos Estados Unidos, mas também medidas não convencionais como o forward guidance, isto é, o caminho da política monetária (GÜRKAYNAK; SACK; SWANSON, 2005).

Dada a importância da economia americana no contexto global e da miríade de

evidências a respeito do impacto da sua política monetária sobre os retornos do seu mercado financeiro, investigações a respeito dos efeitos de suas decisões de política monetária sobre outros países foram outra linha de pesquisa explorada. Veja os trabalhos de Rosa (2011) e Hausman e Wongswan (2011), que analisam surpresas monetárias em anúncios do FOMC em conjuntos de países, apresentando resultados similares aos observados localmente na economia americana: surpresas monetárias americanas possuem efeitos significativos sobre os retornos dos mercados financeiros globais.

Uma parte da literatura mais recente dá uma atenção maior para a influência da política monetária de economias desenvolvidas sobre mercados de economias emergentes. Cavaca e Meurer (2021) analisam transmissões de política monetária entre os Estados Unidos e economias da América do Sul e mostram que a economia americana permanece dominante na transmissão da sua política monetária sobre as curvas de juros dos outros países da amostra. Eterovic e Eterovic (2022) investigam a transmissão de choques econômicos americanos para a economia chilena e mostram que choques monetários são um dos principais meios de transmissão de volatilidade entre as duas economias.

Não somente a política monetária convencional americana é transmitida às economias emergentes, mas também a política monetária não convencional. Barroso, Silva e Sales (2016), por exemplo, mostram que o Quantitative Easing americano levou a um aumento de fluxo de capitais à economia brasileira, bem como a uma apreciação cambial e a elevação de retornos no mercado acionário. Lubys e Panda (2021) apresentam evidências de que anúncios de políticas monetárias não convencionais por parte dos bancos centrais dos Estados Unidos e da União Europeia estão ligados a presença de anormalidades de retornos nos países do BRICS.

Uma abordagem metodológica comum para identificar os efeitos de anúncios monetários por parte do FOMC é a de estudo de eventos (THORBECKE, 1997; BERNANKE; KUTTNER, 2005; HAUSMAN; WONGSWAN, 2011; LUBYS; PANDA, 2021). Apesar da sua alta popularidade e aceitação acadêmica, a metodologia de estudo de eventos sofre de problemas relacionados a presença de heterocedasticidade durante o cálculo de anormalidades de retornos, o que pode contaminar de forma significativa as conclusões obtidas com a metodologia. Essa fragilidade observada em estudos de eventos vem sendo corrigida ao longo dos anos por meio da modelagem da própria volatilidade das séries temporais com modelos GARCH (CORHAY; RAD, 1996; SAVICKAS, 2003; BALABAN; CONSTANTINOU, 2006; PADULA; ALBUQUERQUE, 2018).

Trabalhos mais recentes como os de Yin et al. (2018) e Avelino (2022) vão além e utilizam modelos multivariados da família GARCH (MGARCH) para lidar não somente com a presença de heterocedasticidade nas séries temporais, mas também para modelar de forma dinâmica o risco sistemático das empresas em estudos de eventos ( $\beta$ ). Por meio de modelos MGARCH os autores são capazes de relaxar o pressuposto de betas fixos tanto

na janela de estimação, quanto na janela de eventos, solucionando um problema antigo na metodologia (REYES, 1999; FAMA, 2013).

Considerando a literatura crescente a respeito da transmissão da política monetária americana para mercados emergentes e a possibilidade da correção de fragilidades observadas na metodologia de estudos de eventos, há a oportunidade para ampliar a pesquisa acerca da temática analisando a economia brasileira, cuja reação do mercado acionário a eventos de anúncios monetários não foi explorada de forma extensiva. Dessa forma, o presente trabalho analisa a transmissão da política monetária americana ao mercado acionário brasileiro por meio da análise dos comunicados do FOMC, utilizando, para isso, a metodologia de estudos de eventos associada a modelos multivariados da família GARCH.

Por meio da condução de um estudo de eventos com correções metodológicas considerando abordagens atuais, o presente trabalho busca suprir lacunas de pesquisa no sentido de quantificar a reação do mercado acionário brasileiro à política monetária americana, a modelagem da volatilidade entre os mercados acionários dos dois países e a verificação de variáveis que expliquem corretamente a transmissão de informações do mercado americano para o mercado brasileiro.

O restante do trabalho está estruturado da seguinte maneira: a seção 2 faz um revisão dos principais trabalhos a respeito de efeitos de políticas monetárias convencionais e não convencionais sobre o mercado acionário, além de levantar a literatura a respeito de estudos de eventos que utilizam modelos GARCH. A seção 3 apresenta a metodologia do trabalho e os dados utilizados. A seção 4 expõe os resultados do trabalho. A seção 5, por fim, apresenta as conclusões e a aderência dos resultados obtidos à literatura vigente.

## 5.2 Revisão de literatura

### 5.2.1 Reação do mercado financeiro à política monetária

Os resultados apresentados por Rigobon e Sack (2004) e Bernanke e Kuttner (2005) popularizaram consideravelmente a investigação de impactos monetários sobre o mercado financeiro, incentivando a pesquisa por outros fatores anunciados pelo FOMC que ensejam a reação do mercado financeiro, além da taxa de juros. Gürkaynak, Sack e Swanson (2005), por exemplo, identificam que muitas vezes a maior parte da anormalidade observada em reuniões do FOMC está ligada ao forward guidance da autoridade monetária americana, mostrando que o caminho da política monetária, por vezes, é mais importante que a própria mudança na taxa de juros. Guo, Hung e Kontonikas (2022), por outro lado, mostram que os efeitos de surpresas monetárias sobre o mercado acionário podem variar consideravelmente quando se leva em conta o sentimento dos investidores.

Glick e Leduc (2018) dividem a reação do mercado acionário americano a anúncios

monetários em três variáveis: surpresas à taxa de juros, informações ligadas a forward guidance e presença de políticas de Quantitative Easing. Os autores apresentam evidências que mudanças nos preços de títulos longos ao redor de anúncios do FOMC estão associadas a presença de políticas de Quantitative Easing. [Curcuru et al. \(2018\)](#) usam variáveis similares as de [Glick e Leduc \(2018\)](#) para identificar o transbordamento da política monetária americana para as economias da Alemanha, Reino Unido, Canada, Brasil, Coreia do Sul e México, mostrando uma significativa transferência da política monetária americana convencional e não convencional para as economias dos países emergentes da amostra.

De fato, há consideráveis evidências de que a informações relativas a política monetária americana afetam consideravelmente outros países. [Azad e Serletis \(2022\)](#), por exemplo, mostram que a incerteza com relação à política monetária americana possui um efeito negativo sobre as taxas de juros de países com metas de inflação, incluindo o Brasil. [Lodge e Manu \(2022\)](#) mostram que apesar de notícias provenientes do contexto global afetarem economias emergentes de forma mais intensa, choques monetários americanos ainda possuem grande influência nos retornos dos mercados financeiros destas economias.

### 5.2.2 Estudos de eventos com modelos GARCH

O primeiro trabalho a tratar o fenômeno da heterocedasticidade em estudos de eventos foi o de [Corhay e Rad \(1996\)](#), no qual os autores utilizam um modelo de mercado associado a um processo GARCH (1,1) para corrigir a variabilidade do erro. Os autores mostram que os retornos anormais e as estatísticas de testes obtidos com o modelo corrigido são significativamente diferentes dos calculados pela metodologia clássica. [Reyes \(1999\)](#) também utiliza processos GARCH na metodologia de estudo de eventos, não só argumentando pela necessidade do controle da heterocedasticidade, mas indicando que a modelagem da volatilidade pode ser útil na obtenção de betas variantes no tempo.

Processos GARCH também foram propostos de modo a estabelecer novos testes estatísticos na metodologia, conforme mostra o trabalho de [Savickas \(2003\)](#). O autor associa o modelo de mercado à modelagem de volatilidade com variáveis dummies para testar a significância estatística de eventos, mostrando que o teste estatístico é superior quando comparado a outras formas paramétricas e não paramétricas classicamente utilizadas em estudos de eventos.

A associação de dummies a modelos corrigidos por processos GARCH não se limita a testes estatísticos, também podendo ser utilizada para mensurar os efeitos de um evento sobre os retornos e a volatilidade de um série de retornos financeira. [Balaban e Constantinou \(2006\)](#) fazem essa associação de modelos para análise de fusões e aquisições, ao passo que [Padula e Albuquerque \(2018\)](#) combinam o modelo Capital Asset Pricing Model e um processo GARCH-in-mean para analisar os efeitos de anúncios de investigações

da polícia federal sobre as empresas brasileiras.

A utilização de modelos multivariados GARCH em estudos de eventos, vista em Yin et al. (2018), possibilita ao pesquisador o controle do fenômeno da heterocedasticidade e a modelagem de betas dinâmicos. Os trabalhos anteriores só controlaram um desses aspectos, o que, apesar de proporcionar resultados mais confiáveis, ainda é insuficiente para obter a informação correta sobre o comportamento das séries temporais analisadas ao redor dos eventos de interesse.

A problemática envolvendo modelos univariados, bem como modelos univariados com processos GARCH, na explicação da dinâmica dos retornos de empresas em estudos de eventos é bem evidenciada por Avelino (2022), que compara diversos modelos univariados com modelos BEKK simétricos e assimétricos, mostrando a superioridade dos últimos em estudos de eventos.

## 5.3 Metodologia

### 5.3.1 Amostra de Dados

De modo a verificar o impacto de anúncios monetários do FOMC sobre o mercado brasileiro, foram selecionados os principais índices de cada mercado, sendo o índice S&P500 o representante do mercado americano e o índice Ibovespa o representante do mercado brasileiro. A amostra do estudo foi obtida por meio da base de dados da Economatica e consiste nos retornos diários dos dois índices no período entre janeiro de 2012 e dezembro de 2022. Além disso, foi coletada a variação diária dos contratos futuros das taxas de depósito interbancário brasileiro (DI) de um dia, bem como a variação diária do Índice de Mercado ANBIMA-Geral. Essas variáveis foram incluídas na análise para capturar possíveis surpresas monetárias e foram obtidas por meio da plataforma Ipeadata e das bases de dados da ANBIMA.

Tabela 9 – Estatísticas descritivas das variáveis do estudo

Variável	Média	Mediana	Máximo	Mínimo	Desvio Padrão	CV	ADF	Obs
Ibovespa	0,0002	0,0003	0,1302	-0,1599	0,0159	79,5	-13,04***	2653
S&P500	0,0004	0,0006	0,0896	-0,1276	0,0110	26,38	-13,87***	2653
IMA-G	0,0003	0,0004	0,0204	-0,0374	0,0024	6,48	-13,048***	2653
DI Futuro t+1	0,0002	0,0000	0,2329	-0,1516	0,0115	46,58	-11,88***	2653

Nota: Estatísticas descritivas das variáveis do estudo. Nas colunas 7 e 8 estão representados, respectivamente, os coeficientes de variação e as estatísticas de teste de estacionariedade. \*, \*\*, \*\*\* indicam os níveis de significância estatística aos níveis de 10%, 5% e 1%, respectivamente. Elaboração do autor.

A tabela 9 agrega as estatísticas descritivas das séries temporais, na qual nota-se que os retornos dos índices tem médias próximas a zero e que o coeficiente de variação

observado nos retornos do Ibovespa é consideravelmente superior ao calculado para o S&P500, sendo este um indício inicial de uma maior volatilidade no mercado acionário brasileiro. Os testes de estacionariedade em todas as séries rejeitaram a hipótese nula de elas não são estacionárias ao nível de 1%.

Os anúncios relativos a política monetária americana foram obtidos por meio do site do Federal Reserve, no qual foram coletadas todas as datas de anúncios de política monetária entre janeiro de 2012 e junho de 2022. Para cada reunião foi verificada a presença de medidas de política monetária não convencional, isto é, se houve a indicação do caminho a ser seguido pela autoridade monetária (forward guidance) ou a presença de programas de compra de ativos em larga escala, política popularmente conhecida como Quantitative Easing (QE).

De modo a mitigar possíveis confusões com relação a definição da presença de forward guidance ou não, foi considerada a classificação do próprio Federal Reserve (FED), a qual está disponível para o período entre 2012 e 2019 (Veja a classificação utilizada pelo FED [aqui](#)). Para anos posteriores a esse período a análise dos anúncios foi feita manualmente, o mesmo valendo para medidas de Quantitative Easing, cuja análise foi manual para toda a amostra do estudo.

### 5.3.2 Estudo de eventos

Conforme [Campbell, Lo e MacKinlay \(2012\)](#), a metodologia de estudo de eventos busca identificar o impacto de um acontecimento inesperado sobre os retornos de uma série financeira. Para isso, são calculados os retornos anormais, que consistem simplesmente na subtração do retorno observado em um dia qualquer, do retorno esperado para aquele dia. Formalmente, têm-se:

$$AR_{i,t} = R_{i,t} - E[R_{i,t}|X_t] \quad (5.1)$$

onde, para os fins deste trabalho,  $AR_{i,t}$  é o retorno anormal do índice Ibovespa, denotado por  $i$ . A data dos retornos é denotada por  $t$ ,  $R_{i,t}$  é o retorno observado do Ibovespa e  $E[R_{i,t}|X_t]$  é o retorno esperado do Ibovespa. Para conduzir a metodologia de estudo de eventos, são definidos alguns marcos temporais, de modo a permitir a correta estimação das anormalidades de retornos.  $\tau = 0$  é definido como o momento de ocorrência do evento e sobre esta data é delimitado um intervalo, indo de  $\tau = T_1 + 1$  até  $\tau = T_2$ .

O retorno esperado é calculado mediante um modelo de retorno normais e, para isso, é delimitado um intervalo para a estimação desse modelo, indo de  $\tau = T_0 + 1$  até  $\tau = T_1$ . A partir desses marcos são definidas as janelas de estimação e de eventos, que são iguais a  $L_1 = T_1 - T_0$  e  $L_2 = T_2 - T_1$ , respectivamente. A abordagem do presente trabalho empregou janelas de eventos consideravelmente menores do que as vistas em outros estudos de eventos não monetários, de modo a seguir a tendência observada em outros trabalhos a

respeito de surpresas monetárias (NEELY, 2015; JAROCIŃSKI; KARADI, 2020; LODGE; MANU, 2022).

A escolha do modelo de retornos normais é de grande importância para a condução de um estudo de eventos, pois deseja-se que o modelo explicativo escolhido possa capturar a dinâmica observada na série temporal estudada da melhor maneira possível. Popularmente, o modelo de mercado tem sido a escolha principal para a estimação dos retornos normais em estudos de eventos, consistindo na regressão linear simples de um ativo sobre um índice de mercado qualquer (SHARPE, 1963; MCWILLIAMS, 1997; CAMPBELL; LO; MACKINLAY, 2012):

$$R_{i,t} = \alpha_i + \beta_i R_{m,t} + \varepsilon_{i,t} \quad (5.2)$$

onde  $R_{i,t}$  está definido conforme anteriormente e  $R_{m,t}$  são os retornos do índice de mercado. No caso do presente trabalho, o ativo  $i$  consiste no índice Ibovespa e o índice de mercado  $m$  consiste no índice S&P500. Para lidar com os problemas relacionados a presença de heterocedasticidade nas séries temporais em estudos de eventos e relaxar o pressuposto de betas fixos, foram consideradas duas especificações de modelos GARCH bivariados: o modelo BEKK (ENGLE; KRONER, 1995b) e o modelo Dynamic Conditional Correlation (DCC) (ENGLE, 2002).

Bauwens, Laurent e Rombouts (2006) avaliam diferentes especificações de modelos multivariados GARCH (MGARCH), mostrando que modelos desta classe são bons candidatos para verificar como a volatilidade de um mercado pode ser transferida para outros mercados e como a correlação entre séries temporais pode variar com o passar do tempo. Os autores apontam modelos MGARCH como sendo bons candidatos para a modelagem de betas variantes no tempo, sendo essa a motivação da escolha de tais modelos para o presente estudo.

O modelo BEKK-GARCH (1,1) consiste em uma generalização da forma univariada do modelo GARCH:

$$R_{it} = \mu_i + \varepsilon_{it} \quad (5.3)$$

$$R_{mt} = \mu_m + \varepsilon_{mt} \quad (5.4)$$

$$\mathbf{H}_t = \mathbf{C}'_0 \mathbf{C}_0 + \mathbf{A}' \varepsilon_{t-1} \varepsilon'_{t-1} \mathbf{A} + \mathbf{B}' \mathbf{H}_{t-1} \mathbf{B} \quad (5.5)$$

onde para abordagem metodológica proposta, os retornos do ativo  $i$  (Ibovespa) e do mercado  $m$  (S&P500) são definidos a partir de suas médias incondicionais. Assim, as médias são calculadas como  $\mu_i = E[R_{it}|\Omega_{t-1}]$  e  $\mu_m = E[R_{mt}|\Omega_{t-1}]$ , ambas condicionadas ao conjunto de informações  $\Omega$  disponíveis até o momento  $t - 1$ , que é dado como o último dia antes do início da janela de eventos. A variância  $\mathbf{H}_t$  é modelada conforme os valores passados dos resíduos das séries temporais, representados pela matriz  $\varepsilon_{t-1}$ , e pelos valores das variâncias passadas observadas  $\mathbf{H}_{t-1}$ . As matrizes 2x2  $\mathbf{C}_0$ ,  $\mathbf{A}$  e  $\mathbf{B}$  representam os parâmetros estimados dos modelos.

De forma matricial a variância do modelo BEKK-GARCH (1,1) pode ser representada da seguinte forma:

$$\begin{bmatrix} h_{11} & h_{12} \\ h_{21} & h_{22} \end{bmatrix} = \mathbf{C}\mathbf{0}\mathbf{C}' + \begin{bmatrix} a_{11} & a_{21} \\ a_{12} & a_{22} \end{bmatrix} \varepsilon_{t-1} \varepsilon_{t-1}' \begin{bmatrix} a_{11} & a_{12} \\ a_{21} & a_{22} \end{bmatrix} + \begin{bmatrix} b_{11} & b_{21} \\ b_{12} & b_{22} \end{bmatrix} \mathbf{H}_{t-1} \begin{bmatrix} b_{11} & b_{12} \\ b_{21} & b_{22} \end{bmatrix} \quad (5.6)$$

A partir dos valores de variância e covariância estimados, foi calculado o beta dinâmico:

$$\hat{\beta}_{i,t}^{BEKK} = \frac{h_{12,t}}{h_{22,t}} \quad (5.7)$$

Desse modo, o modelo de retornos anormais estimado considerando a especificação BEKK-GARCH foi:

$$AR_{i,t} = R_{i,t} - \hat{\mu}_i - \hat{\beta}_{i,t}^{BEKK} R_{m,t} \quad (5.8)$$

Como alternativa de modelo multivariado para cálculo das anormalidades de retornos ao redor dos anúncios de política monetária foi utilizado o modelo dinâmico de correlações condicionais (DCC) de Engle (2002). O modelo DCC, de forma distinta do modelo BEKK-GARCH, não é uma extensão do modelo GARCH, mas sim uma combinação de volatilidades estimadas por modelos GARCH univariados. Há uma menor estimação de parâmetros no modelo DCC, fazendo com que ele seja mais facilmente estimado que seu irmão BEKK-GARCH (Veja Bauwens, Laurent e Rombouts (2006) para revisão extensiva de modelos multivariados GARCH). A volatilidade no modelo DCC é estimada conforme as seguinte equações:

$$\mathbf{H}_t = \mathbf{D}_t \mathbf{R}_t \mathbf{D}_t \quad (5.9)$$

$$\mathbf{D}_t = \text{diag}(h_{11t}^{1/2} \dots h_{NNt}^{1/2}) \quad (5.10)$$

$$\mathbf{R}_t = (\text{diag} \mathbf{Q}_t)^{-1/2} \mathbf{Q}_t (\text{diag} \mathbf{Q}_t)^{-1/2} \quad (5.11)$$

onde  $h_{iit}$  é definida como a variância estimada por um processo GARCH univariado qualquer e  $\mathbf{Q}_t$  é uma matriz  $N \times N$  simétrica definida dada por:

$$\mathbf{Q}_t = (1-a-b)\bar{\mathbf{Q}} + a u_{t-1} u_{t-1}' + b \mathbf{Q}_{t-1} \quad (5.12)$$

$u_t = \mathbf{D}_t^{-1} \varepsilon_t$ ,  $\bar{\mathbf{Q}}$  representa a matriz de variâncias incondicionais de  $u_t$  e  $a$  e  $b$  são escalares não negativos que satisfazem  $a+b < 1$ . Da mesma forma que no modelo BEKK-GARCH (1,1), o processo DCC considerou processos GARCH (1,1) na sua estimação. Note que a matriz  $\mathbf{D}_t$  possui os modelos GARCH univariados, enquanto a matriz  $\mathbf{R}_t$  representa as correlações condicionais, na qual cada elemento é representado por:

$$\rho_{imt} = \frac{q_{imt}}{\sqrt{q_{ii}q_{mm}}} \quad (5.13)$$



onde  $q_{imt}$  é a covariância entre o ativo  $i$  (Ibovespa) e o índice de mercado  $m$  (S&P500),  $q_{ii}$  é a variância do ativo  $i$  e  $q_{mm}$  é a variância do ativo  $m$ . Assim, também é possível obter um beta dinâmico com o modelo DCC:

$$\hat{\beta}_{i,t}^{DCC} = \frac{q_{imt}}{q_{mm}} \quad (5.14)$$

assim, o modelo de retornos anormais estimado considerando a especificação do modelo DCC foi:

$$AR_{i,t} = R_{i,t} - \hat{\mu}_i - \hat{\beta}_{i,t}^{DCC} R_{m,t} \quad (5.15)$$

Artigos clássicos da literatura de estudos de eventos recomendam janelas de estimação de 252 dias úteis (BROWN; WARNER, 1980; MCWILLIAMS, 1997). Contudo, para a estimação precisa de processos GARCH, Hwang e Valls Pereira (2006) indicam a necessidade de pelo menos 500 observações, sendo essa a escolha feita para as duas especificações de modelos MGARCH estimadas no presente trabalho. A estimação dos modelos MGARCH foi feita por meio de estimadores de máxima verossimilhança, conforme Bauwens, Laurent e Rombouts (2006). Após o cálculo dos retornos anormais eles foram acumulados para a janela de eventos delimitada, originando os retornos anormais acumulados:

$$CAR_i = \sum_{\tau=T_1+1}^{T_2} AR_{i,t} \quad (5.16)$$

onde  $CAR_n$  são os retornos anormais acumulados para o evento  $n$ . De modo a estabelecer inferência sobre a significância dos eventos em geral, foi calculada a média de retornos anormais acumulados para todos os eventos da amostra:

$$CAAR = \frac{1}{N} \sum_{i=1}^N CAR_i \quad (5.17)$$

onde  $CAAR$  representa os retornos anormais acumulados médios para os  $N$  eventos da amostra. O teste da hipótese nula de que os anúncios de política monetária do FOMC não possuíram efeitos sobre os retornos do Ibovespa foi feito conforme a seguinte especificação:

$$J_1 = \frac{CAR_{i,t}}{(S_{CAR}^2)^{\frac{1}{2}}} \quad (5.18)$$

$$J_2 = \frac{CAAR}{\frac{(S_{CAAR}^2)^{\frac{1}{2}}}{\sqrt{N}}} \quad (5.19)$$

Os teste seguem a distribuição t de Student e as variâncias  $S_{CAR}^2$  e  $S_{CAAR}^2$  foram calculadas conforme as seguintes fórmulas:

$$S_{CAR}^2 = L_2 S_{AR}^2 \quad (5.20)$$

$$S_{AR}^2 = \frac{1}{L_1 - 1} \sum_{\tau=T_0}^{T_1} (AR_t - \overline{AR})^2 \quad (5.21)$$

$$S_{CAAR}^2 = \frac{1}{N - 1} \sum_{i=1}^N (CAR_i - CAAR)^2 \quad (5.22)$$

### 5.3.2.1 Modelo de regressão probit

De modo geral, a literatura a respeito de surpresas monetárias indica que tais eventos não são recorrentes, tendo como característica uma relativa escassez na sua ocorrência. Desse modo, para capturar adequadamente quais variáveis explicariam tais eventos no mercado acionário brasileiro, foi utilizado um modelo de regressão com variável dependente binária, o modelo Probit. Foi atribuído o valor de 1 para cada evento de anúncio do FOMC em que foram detectados CAR's estatisticamente significantes diferentes de zero ao nível de 5% ou inferior, de modo a indicar a presença de uma surpresa monetária. De igual modo, os valores de eventos com CAR's com significância em níveis superiores a 5% foram considerados eventos em que não houve surpresa monetária, sendo atribuído o valor de zero à ocorrência. O modelo probit utilizado no trabalho seguiu a seguinte especificação:

$$CAR_i = \alpha + \beta_1 Forward + \beta_2 QE + \beta_3 DI + \beta_4 IMA \quad (5.23)$$

onde  $CAR_i$  é o retorno anormal acumulado do evento  $i$  considerando uma janela de eventos compreendida entre o dia anterior ao evento e a data do evento. A variável *Forward* é uma dummy que assume valor igual a 1 para os eventos em que o anúncio do FOMC teve elementos de forward guidance e 0 caso contrário, buscando capturar elementos ligados ao caminho da política monetária, conforme visto em [Gürkaynak, Sack e Swanson \(2005\)](#). A variável *QE* é uma dummy que assume valor igual a 1 em anúncios em que houve a indicação de políticas de quantitative easing e 0 caso contrário. As variáveis *DI* e *IMA* buscam capturar surpresas com relação a taxa de juros anunciada pelo FED ([RIGOBON; SACK, 2004](#); [BERNANKE; KUTTNER, 2005](#)) e correspondem às variações diárias do DI futuro com vencimento de 1 dia e do Índice de Mercado ANBIMA, respectivamente.

## 5.4 Resultados

### 5.4.1 Modelos de volatilidade estimados

Antes de analisar os eventos em si, é interessante verificar qual a relação entre o índice Ibovespa e o índice S&P500, para entender como a volatilidade dos dois índices se comporta, se há uma transmissão de volatilidade entre os índices e qual a direção dessa transmissão, caso ela exista. As tabelas 2 e 3 apresentam os valores dos parâmetros estimados pelos modelos BEKK-GARCH (1,1) e DCC (1,1), considerando todas as observações da amostra.

A tabela 10 mostra os parâmetros estimados pelo modelo DCC (1,1). Os coeficientes  $\mu$ ,  $\omega$ ,  $\alpha$  e  $\beta$  dizem respeito aos processos GARCH (1,1) utilizados para modelar a volatilidade, que faz parte do cálculo das covariâncias e correlações condicionais. Observa-se que os parâmetros dos modelo GARCH (1,1) conseguem explicar de forma satisfatória a dinâmica do Ibovespa e do S&P500, sendo seus valores governados principalmente pelas suas

Tabela 10 – Parâmetros estimados do modelo DCC

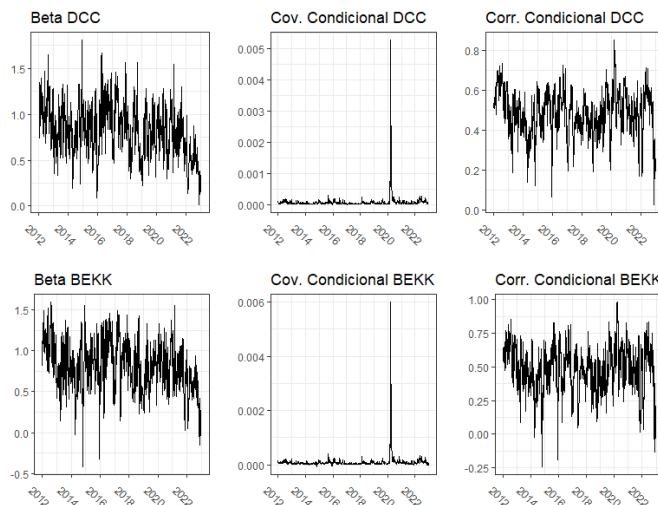
Coeficiente	Ibovespa		S&P500	
	Estimativa	p-valor	Estimativa	p-valor
$\mu$	0,000	0,052	0,000	0,017
$\omega$	0,000	0,000	0,000	0,430
$\alpha$	0,076	0,000	0,230	0,000
$\beta$	0,874	0,000	0,741	0,000
a	0,048	0,000		
b	0,904	0,000		

Nota: Esta tabela apresenta os parâmetros estimados de um modelo DCC-GARCH considerando todas as observações do Ibovespa e do S&P500. Os parâmetros  $\mu$ ,  $\omega$ ,  $\alpha$  e  $\beta$  dizem respeito aos parâmetros estimados por modelos GARCH (1,1) para obtenção das estimativas do modelo DCC. Elaboração do autor.

volatilidades e resíduos passados. Os valores de  $a+b < 1$  o que garante a estacionariedade do modelo.

A figura 5 apresenta os betas dinâmicos, as covariâncias condicionais e as correlações condicionais estimados a partir dos dois modelos multivariados propostos. Visualmente é possível notar que o pressuposto de que os betas são fixos durante a ocorrência de um evento ou durante a sua janela de estimação não se sustenta. Para os dois modelos propostos há uma variação significativa da sensibilidade ao risco sistemático do Ibovespa ao S&P500, sendo essa relação negativa em alguns momentos, como nos anos de 2014 e 2015. A covariância condicional dos dois modelos apresenta o seu maior valor no ano da

Figura 5 – Beta do Ibovespa e covariâncias e correlações condicionais entre o Ibovespa e o S&P500



Nota: Este gráfico representa os betas, as covariâncias e as correlações considerando todas as observações do Ibovespa e do S&P500. O beta calculado representa a sensibilidade ao risco sistemático do Ibovespa com relação ao índice S&P500. Elaboração do autor.

ocorrência da pandemia do coronavírus e, assim como o beta, a correlação das séries variou de forma significativa no período analisado, havendo ocorrências de correlação condicional negativa para o modelo BEKK-GARCH (1,1), assim como no caso do beta.

Nota-se a partir das estimativas do modelo BEKK-GARCH (1,1), disponíveis na tabela 11, que a maior parte da volatilidade do índice Ibovespa, é gerada pela sua própria volatilidade passada, medida pelo parâmetro  $b_{11}$ , significativa ao nível de 1%. Os resíduos passados do Ibovespa, medidos pelo parâmetro  $a_{11}$ , também desempenham um papel significativo na formação da sua volatilidade, apresentando significância estatística ao nível de 1% igualmente. A mesma interpretação pode ser feita para o S&P500, no qual seus parâmetros de volatilidade e resíduos também são significantes ao nível de 1%.

Tabela 11 – Parâmetros estimados do modelo BEKK

Coefficiente	Estimativa	Estatística t
$c_{11}$	0,003***	10,652
$c_{12}$	0,000	0,000
$c_{21}$	0,001***	6,586
$c_{22}$	0,001***	8,404
$a_{11}$	0,237***	14,280
$a_{12}$	-0,008	-0,792
$a_{21}$	0,091***	3,244
$a_{22}$	0,413***	22,202
$b_{11}$	0,949***	117,219
$b_{12}$	-0,005	-0,850
$b_{21}$	-0,028**	-2,145
$b_{22}$	0,896***	96,154

Nota: Esta tabela apresenta os parâmetros estimados do modelo BEKK-GARCH considerando todas as observações do Ibovespa e do S&P500. Elaboração do autor.

Há, no entanto, um resultado interessante no modelo estimado: a volatilidade do S&P500 explica consideravelmente a volatilidade observada no Ibovespa, note que o parâmetro  $b_{21}$ , que mede a volatilidade do S&P500 para o Ibovespa é estatisticamente significativa ao nível de 5%. O mesmo vale para a transmissão de resíduos, isto é, de choques passados do S&P500 para o Ibovespa, havendo significância no nível de 1%. A significância da transferência dos resíduos do S&P500 para o mercado brasileiro é importante, já que notícias ou surpresas que possam causar ruído no mercado americano apresentam grande potencial de vazamento para o mercado brasileiro, como mostra o modelo.

Logo, havendo uma surpresa monetária no mercado americano, que conforme documentado pela literatura reflete de forma significativa no mercado americano (RIGOBON; SACK, 2004; BERNANKE; KUTTNER, 2005; GÜRKAYNAK; SACK; SWANSON, 2005), a volatilidade proveniente desse choque monetário seria transferida à bolsa brasileira. Essa interpretação, bem como o resultado verificado no modelo BEKK estimado são importantes,

pois o índice S&P500 é utilizado como o gerador de anormalidades a serem transferidas ao mercado brasileiro.

Essa transferência de volatilidade do mercado americano para o brasileiro identificada pelo modelo BEKK-GARCH (1,1) está em concordância com outros trabalhos que investigam efeitos de transferência de volatilidade do mercado americano para o resto do mundo, como Hausman e Wongswan (2011), Lubys e Panda (2021) e Eterovic e Eterovic (2022). Todavia, os trabalhos mencionados ligam essa transferência de volatilidade a eventos monetários, desse modo, resta saber se essa transferência de volatilidade da bolsa americana para a bolsa brasileira é observada em eventos relacionados à anúncios monetários, que serão investigados nas próximas seções.

### 5.4.2 Estudo de Eventos

A tabela 12 resume os resultados encontrados para os retornos anormais calculados, considerando além dos dois modelos MGARCH propostos, a especificação clássica do modelo de mercado e o modelo de mercado com erros corrigidos por um processo GARCH (1,1), conforme visto em Corhay e Rad (1996).

Tabela 12 – Estatísticas descritivas e testes de significância dos CAR's

	CAAR	Estatística t	Mediana	Máximo	Mínimo	Desvio Padrão	CV
<b>BEKK</b>							
$T_1 = -3, T_2 = 0$	-0,003	-1,479	-0,003	0,048	-0,060	0,022	-6,37
$T_1 = -2, T_2 = 0$	0,001	0,971	0,0001	0,052	-0,046	0,017	9,70
$T_1 = -1, T_2 = 0$	-0,0002	-0,120	-0,001	0,109	-0,061	0,022	-78,18
<b>DCC</b>							
$T_1 = -3, T_2 = 0$	-0,004*	-1,802	-0,002	0,044	-0,116	0,023	-5,23
$T_1 = -2, T_2 = 0$	0,001	0,936	0,001	0,049	-0,047	0,016	10,07
$T_1 = -1, T_2 = 0$	-0,0007	-0,338	-0,001	0,085	-0,065	0,022	-27,84
<b>Modelo de Mercado</b>							
$T_1 = -3, T_2 = 0$	-0,002	-1,062	-0,002	0,054	-0,113	0,024	-8,88
$T_1 = -2, T_2 = 0$	0,002	-1,306	0,001	0,048	-0,048	0,017	7,21
$T_1 = -1, T_2 = 0$	-0,0002	-0,085	0,0003	0,064	-0,064	0,022	-109,76
<b>Modelo de Mercado GARCH</b>							
$T_1 = -3, T_2 = 0$	-0,003	-1,181	-0,002	0,047	-0,126	0,025	-7,98
$T_1 = -2, T_2 = 0$	0,002	1,188	0,0009	0,048	-0,049	0,017	7,93
$T_1 = -1, T_2 = 0$	-0,0005	-0,216	0,0005	0,069	-0,080	0,022	-43,59

Nota: Nesta tabela estão contidas as estatísticas descritivas dos retornos anormais acumulados (CAR's) ao redor dos anúncios do FOMC, considerando os modelos GARCH multivariados discutidos na seção metodológica e dois modelos univariados: a especificação clássica do modelo de mercado e o modelo de mercado com erros corrigidos por um processo GARCH (1,1), conforme Corhay e Had (1996). A coluna dos retornos anormais acumulados médios (CAAR's) representa a média dos CAR's. \*, \*\*, \*\*\* indicam os níveis de significância estatística aos níveis de 10%, 5% e 1%, respectivamente. Elaboração do autor.

Um primeiro olhar sobre a coluna de retornos anormais acumulados médios indica

uma reação eficiente do mercado acionário brasileiro aos anúncios de política monetária americana, não sendo observada significância estatística em nenhum modelo, para nenhuma das janelas, exceto para a janela de eventos de 4 dias para o modelo DCC. Contudo, o nível de significância estatística de 10% não é suficiente para prover evidências robustas de que os anúncios monetários do FOMC estão relacionados de forma consistente à anormalidades de preços no mercado acionário brasileiro.

É interessante notar que considerando os coeficientes de variação dos retornos anormais de todos os modelos, os modelos que controlam o fenômeno da heterocedasticidade proporcionaram a menor variabilidade de retornos anormais acumulados dentre as janelas calculadas. O modelo de mercado apresentou a maior variabilidade nas anormalidades entre as janelas calculadas, enquanto o modelo DCC apresentou os menores coeficientes de variação.

Os resultados apresentados mostram que o mercado brasileiro se comporta de maneira eficiente com relação aos anúncios monetários do FOMC. De fato, essa reação eficiente por parte do mercado acionário é bem documentada pela literatura (RIGOBON; SACK, 2004; BERNANKE; KUTTNER, 2005; ROSA, 2011; HAUSMAN; WONGSWAN, 2011), sendo este o motivo pelo qual o foco dos trabalhos que investigam essa temática não são os anúncios monetários de forma generalizada, mas sim as ocorrências em que o mercado acionário não precificou todas as informações da reunião em questão, as ocorrências de surpresa monetária.

Na ocorrência dessas surpresas, as novas informações recebidas pelos agentes econômicos, ensejam uma nova precificação dos ativos no mercado financeiros, levando a anormalidades de preços, até que haja um novo ponto de equilíbrio. Essas anormalidades foram detectadas no presente trabalho, havendo casos tanto de reações positivas estatisticamente significantes, quanto de reações negativas. As tabelas 13 e 14 expõem todos os casos em que houve anormalidades de retornos estatisticamente significantes no índice Ibovespa em datas ao redor de anúncios do FOMC.

Considerando o extrato de 10 anos da amostra, em 12 anúncios do FOMC foram observadas anormalidades de retornos ao nível de 5% pelo menos para alguma janela de eventos em algum dos modelos utilizados, sendo 6 eventos associados a reações positivas e 6 eventos ligados a reações negativas do mercado brasileiro. No anúncio do dia 13/09/2012 foram observados CAR's positivos, apesar de não haver mudança na taxa de juros americana. Contudo, foi anunciado o início do terceiro programa de Quantitative Easing americano, bem como a indicação de forward guidance, quando a autoridade monetária americana indicou que uma posição acomodativa da política monetária seria apropriada por um tempo considerável.

No dia 30/01/2013, apesar da reação negativa do mercado acionário brasileiro, não foram anunciadas mudanças na política monetária do FED, nem mesmo medidas de

Quantitative Easing ou forward guidance. Na reunião do dia 19/06/2013, a reação do mercado acionário brasileiro foi negativa e houve um anúncio por parte do Ben Bernanke indicando a possibilidade de uma redução no ritmo de compra de ativos por parte do banco central americano.

No anúncio do dia 19/03/2014, a reação verificada para o mercado brasileiro foi positiva, sendo verificado na ata do FOMC a intenção do Federal Reserve em manter a taxa de juros americanas no mesmo patamar por um tempo considerável. Na reação positiva verificada na reunião do dia 18/03/2015, foi igualmente observada a manutenção da taxa de juros e o fornecimento de informações sobre o futuro da política monetária por meio do comunicado do FOMC, havendo mais uma ocorrência de forward guidance. Apesar da reação negativa verificada no Ibovespa nos dias 16/03/2016 e 08/11/2018 e positiva no dia 27/04/2016, não houve informações relativas a política monetária nos comunicados destas reuniões.

As anormalidades de retornos observadas no dia 16/03/2020 foram as de maior magnitude da amostra, sendo a reação do mercado acionário brasileiro consideravelmente negativa. A reunião correspondente a esta data ocorreu no mesmo período em que foi deflagrada a pandemia do Coronavírus, além de ser a reunião com o maior número de medidas de política monetária de toda a amostra, com uma queda de 1% na taxa de juros americana, além da indicação do caminho a ser seguido pela política monetária e do início de mais um programa de Quantitativa Easing.

Essas medidas tiveram a sua manutenção no comunicado do dia 29/04/2020, data na qual houve uma reação positiva por parte do mercado brasileiro. Por fim, na reunião do dia 03/11/2022 além do aumento da taxa de juros houve a indicação de políticas de Quantitative Easing, ao passo que no comunicado do dia 14/12/2022 houve o aumento da taxa de juros e a indicação da intenção do FED em continuar os incrementos.

Tabela 13 – Retornos anormais acumulados (CAR's) positivos dos eventos estatisticamente significantes

BEKK-GARCH				DCC				Modelo de Mercado				Modelo de Mercado GARCH			
Reação Positiva				Reação Positiva				Reação Positiva				Reação Positiva			
Data	Janela	CAR	t-stat	Data	Janela	CAR	t-stat	Data	Janela	CAR	t-stat	Data	Janela	CAR	t-stat
13/09/2012	T <sub>1=-3, T<sub>2=0</sub></sub>	0,044	2,276	13/09/2012	T <sub>1=-3, T<sub>2=0</sub></sub>	0,04	2,098	13/09/2012	T <sub>1=-3, T<sub>2=0</sub></sub>	0,046	2,339	13/09/2012	T <sub>1=-3, T<sub>2=0</sub></sub>	0,047	2,401
13/09/2012	T <sub>1=-2, T<sub>2=0</sub></sub>	0,04	2,38	13/09/2012	T <sub>1=-2, T<sub>2=0</sub></sub>	0,04	2,174	13/09/2012	T <sub>1=-2, T<sub>2=0</sub></sub>	0,042	2,461	13/09/2012	T <sub>1=-2, T<sub>2=0</sub></sub>	0,042	2,469
18/03/2015	T <sub>1=-2, T<sub>2=0</sub></sub>	0,05	2,094	29/04/2020	T <sub>1=-2, T<sub>2=0</sub></sub>	0,09	3,463	29/04/2020	T <sub>1=-2, T<sub>2=0</sub></sub>	0,064	2,603	29/04/2020	T <sub>1=-2, T<sub>2=0</sub></sub>	0,069	2,75
29/04/2020	T <sub>1=-2, T<sub>2=0</sub></sub>	0,109	4,668	19/03/2014	T <sub>1=-1, T<sub>2=0</sub></sub>	0,03	2,07	03/11/2022	T <sub>1=-2, T<sub>2=0</sub></sub>	0,046	2,359	03/11/2022	T <sub>1=-2, T<sub>2=0</sub></sub>	0,046	2,362
19/03/2014	T <sub>1=-1, T<sub>2=0</sub></sub>	0,032	2,067	18/03/2015	T <sub>1=-1, T<sub>2=0</sub></sub>	0,05	2,52	19/03/2014	T <sub>1=-1, T<sub>2=0</sub></sub>	0,033	2,126	13/09/2012	T <sub>1=-1, T<sub>2=0</sub></sub>	0,027	1,982
18/03/2015	T <sub>1=-1, T<sub>2=0</sub></sub>	0,051	2,596	27/04/2016	T <sub>1=-1, T<sub>2=0</sub></sub>	0,04	2,058	18/03/2015	T <sub>1=-1, T<sub>2=0</sub></sub>	0,048	2,472	19/03/2014	T <sub>1=-1, T<sub>2=0</sub></sub>	0,033	2,123
27/04/2016	T <sub>1=-1, T<sub>2=0</sub></sub>	0,044	2,067	29/04/2020	T <sub>1=-1, T<sub>2=0</sub></sub>	0,05	2,384	27/04/2016	T <sub>1=-1, T<sub>2=0</sub></sub>	0,046	2,183	18/03/2015	T <sub>1=-1, T<sub>2=0</sub></sub>	0,048	2,449
16/03/2020	T <sub>1=-1, T<sub>2=0</sub></sub>	0,037	2,179	-	-	-	-	29/04/2020	T <sub>1=-1, T<sub>2=0</sub></sub>	0,04	2,009	27/04/2016	T <sub>1=-1, T<sub>2=0</sub></sub>	0,046	2,168
29/04/2020	T <sub>1=-1, T<sub>2=0</sub></sub>	0,052	2,703	-	-	-	-	26/01/2022	T <sub>1=-1, T<sub>2=0</sub></sub>	0,046	2,321	29/04/2020	T <sub>1=-1, T<sub>2=0</sub></sub>	0,043	2,111
-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-
-	-	-	-	-	-	-	-	-	-	-	-	-	-	-	-

Nota: Nesta tabela estão contidas as datas das reuniões do FOMC em que foram detectados retornos anormais acumulados positivos estatisticamente significantes. Nas reuniões do FOMC em que houve ausência de retornos (feriados, por exemplo) foi considerado o retorno do dia seguinte. Para dar robustez a análise empreendida, foram desconsiderados eventos estatisticamente significantes ao nível de 10%. \*\* e \*\*\* indicam os níveis de significância estatística aos níveis de 5% e 1%, respectivamente. Elaboração do autor.



Tabela 14 – Retornos anormais acumulados (CAR's) negativos dos eventos estatisticamente significantes

BEKK-GARCH			DCC			Modelo de Mercado			Modelo de Mercado GARCH		
Reação Negativa			Reação Negativa			Reação Negativa			Reação Negativa		
Data	Janela	CAR	t-stat	Data	Janela	CAR	t-stat	Data	Janela	CAR	t-stat
30/01/2013	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,047	-2,419	30/01/2013	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,047	-2,397	30/01/2013	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,045	-2,28
19/06/2013	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,045	-2,213	19/06/2013	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,045	-2,223	19/06/2013	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,043	-2,118
16/03/2016	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,06	-2,06	16/03/2020	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,116	-4,719	08/11/2018	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,051	-2,048
16/03/2020	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,049	-2,037	30/01/2013	T <sub>1=-2, T<sub>2=0</sub></sub>	-0,034	-2,041	16/03/2020	T <sub>1=-3, T<sub>2=0</sub></sub>	-0,113	-4,614
30/01/2013	T <sub>1=-2, T<sub>2=0</sub></sub>	-0,035	-2,058	08/11/2018	T <sub>1=-2, T<sub>2=0</sub></sub>	-0,049	2,762	08/11/2018	T <sub>1=-2, T<sub>2=0</sub></sub>	-0,064	-2,979
08/11/2018	T <sub>1=-2, T<sub>2=0</sub></sub>	-0,061	-2,875	16/03/2020	T <sub>1=-2, T<sub>2=0</sub></sub>	-0,065	-3,025	16/03/2020	T <sub>1=-2, T<sub>2=0</sub></sub>	-0,066	-3,099
08/11/2018	T <sub>1=-1, T<sub>2=0</sub></sub>	-0,046	-2,63	14/12/2022	T <sub>1=-2, T<sub>2=0</sub></sub>	-0,04	-2,038	14/12/2022	T <sub>1=-2, T<sub>2=0</sub></sub>	-0,042	-2,107
-	-	-	-	08/11/2018	T <sub>1=-1, T<sub>2=0</sub></sub>	-0,047	-2,662	08/11/2018	T <sub>1=-1, T<sub>2=0</sub></sub>	-0,048	-2,768

Nota: Nesta tabela estão contidas as datas das reuniões do FOMC em que foram detectados retornos anormais acumulados negativos estatisticamente significantes. Nas reuniões do FOMC em que houve ausência de retornos (feriados, por exemplo) foi considerado o retorno do dia seguinte. Para dar robustez a análise empreendida, foram desconsiderados eventos estatisticamente significantes ao nível de 10%. \*\* e \*\*\* indicam os níveis de significância estatística aos níveis de 5% e 1%, respectivamente. Elaboração do autor.

### 5.4.3 Modelos Probit MGARCH

De modo a explicar as 12 ocorrências de anormalidades de retornos observadas foram considerados 4 modelos probit distintos, cada um considerando uma especificação de modelo de retornos normais para estimar as anormalidades dos eventos analisados. Em todos os casos foram considerados os CAR's calculados considerando janelas de eventos de 2 dias. A tabela 15 expõe os resultados obtidos com os modelos, na qual é possível observar que as variáveis ligadas a variações na taxa de juros, bem como a dummy de Quantitative Easing não são capazes de explicar a ocorrência de surpresas monetárias no mercado brasileiro para a amostra.

Tabela 15 – Modelos probit com CAR's para a janela de 2 dias

	$CAR_{BEKK}$	$CAR_{DCC}$	$CAR_{MM}$	$CAR_{MMG}$
Intercepto	-2,122*** (-4,995)	-2,078*** (-4,934)	-2,056*** (-4,895)	-2,109*** (-4,967)
Forward	0,935* (1,799)	0,882* (1,687)	1,093** (2,120)	1,178** (2,347)
QE	-0,026 (-0,046)	-0,149 (0,250)	-0,342 (-0,571)	0,028 (0,055)
DI	-33,915 (-1,573)	8,697 (0,320)	9,412 (0,354)	9,006 (0,408)
IMA	-65,264 (-0,508)	-60,365 (-0,459)	-83,459 (-0,640)	-83,250 (-0,712)

Nota: Nesta tabela são apresentados os resultados de 4 modelos probit, considerado os retornos anormais acumulados calculados para janelas de 2 dias como variável dependente. Para eventos estatisticamente significantes aos níveis de 5% ou inferior foi atribuído o valor de 1, para eventos com significância superior a 5% foi atribuído o valor de 0. A primeira coluna é referente às variáveis dos modelos, as colunas 2, 3, 4 e 5 apresentam os valores dos parâmetros estimados considerando os CAR's calculados conforme os modelos BEKK, DCC, modelo de mercado clássico e modelo de mercado com erros corrigidos GARCH. \*, \*\*, \*\*\* indicam os níveis de significância estatística aos níveis de 10%, 5% e 1%, respectivamente. Elaboração do autor.

Contudo, em todos os modelos estimados verifica-se que a variável de dummy que controla fatores ligados a forward guidance consegue capturar parte dos efeitos relacionados à ocorrência de anormalidades de preços no mercado brasileiro em eventos de anúncios monetários americanos. Apesar do método de identificação ser distinto, estes resultados estão em conformidade com os apresentados por [Gürkaynak, Sack e Swanson \(2005\)](#), tanto no sentido de que o forward guidance explica a surpresa monetária, quanto no sentido que ele explica a maior parte da reação do mercado (no caso deste trabalho, é a única variável

capaz de explicar a reação do mercado brasileiro satisfatoriamente).

Somando-se os resultados observados nesta seção, aos dos estudos de eventos conduzidos e aos modelos de volatilidade estimados é possível perceber que há de fato uma transferência de volatilidade entre o mercado acionário americano e o brasileiro. Contudo, as evidências apontam que, para o caso de anúncios monetários do FOMC, essa transferência só ocorre em casos em que há informações adicionais na comunicação do Federal Reserve, em especial quando há a presença de forward guidance. Estes resultados se somam à crescente literatura a respeito de transmissão da política monetária americana e estão em conformidade com outros estudos de eventos sobre surpresas monetárias como os de Rosa (2011) e Hausman e Wongswan (2011) e transferência de volatilidade observada em Eterovic e Eterovic (2022).

## 5.5 Conclusões

Este trabalho buscou verificar a reação do mercado acionário brasileiro aos anúncios de política monetária do FOMC por meio da metodologia de estudos de eventos e de modelos GARCH multivariados. Os resultados apresentados mostram que, de modo geral, não há uma reação estatisticamente significativa do mercado acionário brasileiro às notícias monetárias americanas, indicando que o mercado acionário brasileiro se comporta de maneira eficiente com relação a esse tipo de evento. Essa reação eficiente está em linha com trabalhos clássicos da literatura como Rigobon e Sack (2004) e o estudo de eventos de Bernanke e Kuttner (2005).

Contudo, apesar da eficiência verificada, há casos em que o mercado brasileiro não antecipa completamente as informações monetárias dos comunicados do FOMC, sendo possível verificar anormalidades de preços nessas datas. Por meio de modelos probit, foi identificado que a indicação de forward guidance nos comunicados do FOMC é responsável por um incremento na probabilidade de ocorrência de surpresas monetárias no mercado brasileiro, um resultado que está em conformidade com os achados de Gürkaynak, Sack e Swanson (2005).

Esses resultados são complementados pela estimação de modelos de volatilidade que indicam haver uma significativa transferência de volatilidade do mercado acionário americano para o mercado brasileiro. Tais resultados relacionados à transferência da volatilidade do mercado americano para o brasileiro em eventos monetários se somam à crescente literatura a respeito do tema, cujos resultados deste trabalho estão em conformidade com os trabalhos de Rosa (2011), Hausman e Wongswan (2011), Curcucu et al. (2018), Lubys e Panda (2021).

Por fim, a abordagem metodológica proposta apresentou resultados significativamente diferentes da metodologia clássica de estudos de eventos, indo na mesma direção dos

trabalhos de [Yin et al. \(2018\)](#) e [Avelino \(2022\)](#). Contudo, é necessária uma maior investigação para verificar se de fato de modelos MGARCH capturam corretamente anormalidades de retornos, sendo este um caminho de pesquisa possível. Além disso, a identificação de variáveis que melhor capturem a reação das taxas de juros brasileiras aos comunicados do FOMC seria de grande benefício.

## 6 Considerações Finais

O objetivo deste trabalho foi avaliar eventos endógenos e exógenos ao mercado acionário brasileiro por meio da metodologia de estudo de eventos, usando modelos MGARCH como forma de complementação e suporte da análise. Os resultados apresentados mostram relevantes diferenças entre as anormalidades de retorno calculados por meio do modelo de mercado clássico e por modelos que consideram processos MGARCH na sua estimação. Nesse sentido, as hipóteses relativas a diferenças entre a abordagem clássica e a abordagem com modelos MGARCH dos dois artigos (H4a e H6b) foram rejeitadas, isto é, há diferenças significantes entre elas. Essa diferença de resultados não implica, contudo, na invalidação da metodologia de estudo de eventos clássica, mas enseja, na verdade, uma maior investigação a respeito dos benefícios e da precisão de resultados que modelam a volatilidade como parte do processo de cálculo de anormalidades.

Feita essa observação, há ganhos consideráveis na utilização de modelos MGARCH em estudos de eventos. Considerando os resultados do trabalho a respeito de anúncios de ofertas de debêntures, a modelagem da volatilidade permitiu que fossem detectadas diferenças relevantes no risco sistemático das empresas ao redor dos anúncios, implicando na não rejeição da hipótese H2a, estabelecida no capítulo introdutório. Também foram detectadas anormalidades de retornos negativas (não rejeição de H3a) e estatisticamente significantes (não rejeição de H1a), sendo as maiores anormalidades de retornos observadas na especificação que considerou a especificação BEKK-GARCH como modelos de retornos normais.

O artigo a respeito de anúncios monetários americanos também se beneficiou da modelagem da volatilidade proporcionada pelos modelos BEKK-GARCH e DCC. A partir destes modelos foi possível verificar a transferência da volatilidade do índice acionário americano para o índice acionário brasileiro (não rejeição de H1b), o que justificou uma maior investigação a respeito da transferência dos anúncios monetários americanos para a economia brasileira. Apesar das evidências apontarem que não há uma transferência de volatilidade persistente na maioria dos anúncios do FOMC (rejeição de H2b), nos momentos em que há uma prevalência de anormalidades de retornos, a sua ocorrência pode ser explicada pela presença de elementos de forward guidance nos anúncios realizados (não rejeição de H4b e rejeição de H3b e H5b).

Todos os resultados calculados consideraram várias abordagens da metodologia de estudo de eventos: a forma clássica de [Campbell, Lo e MacKinlay \(2012\)](#), controlando somente a heterocedasticidade como visto em [Corhay e Rad \(1996\)](#), utilizando o modelo BEKK-GARCH no espírito dos trabalhos de [Yin et al. \(2018\)](#) e [Avelino \(2022\)](#) e uma

proposta de aplicação do modelo DCC feita pelo autor deste trabalho. Assim, caso haja dúvidas com relação aos resultados apresentados pelos modelos MGARCH, ainda são apresentados resultados na forma mais popularmente utilizada pela literatura.

A reação do mercado acionário brasileiro aos anúncios de ofertas de debêntures entre 2021 e 2022 mostra que o mercado precificou o aumento da alavancagem na empresa anunciante no primeiro impacto informacional do evento, uma reação que está em consonância com a hipótese semi forte de eficiência de mercado. No caso dos anúncios monetários americanos, em muitos anúncios, apesar de serem apresentadas novas informações (mudanças na taxa de juros, compras de ativos etc.) não houve uma reação do mercado acionário brasileiro, uma ocorrência provavelmente ocasionada pela antecipação dos agentes econômicos às informações proporcionadas pelo FOMC. Contudo, em casos de surpresa com relação ao conteúdo informacional da autoridade monetária americana, há uma reação relevante do mercado acionário brasileiro, um movimento que também vai no sentido da hipótese de eficiência na forma semi forte.

Apesar dos resultados apresentados não possibilitarem conclusões gerais a respeito da eficiência do mercado brasileiro (é necessária uma literatura avassaladora para tal), eles estão em consonância com a miríade de evidências a respeito da hipótese semi forte de mercado que são expostas desde o século passado por Fama (1970) e que contribuíram para a sua premiação com o prêmio Nobel (FAMA, 2013).

Há limitações relevantes nos trabalhos desta dissertação, que poderiam levar a futuras linhas de pesquisa. A primeira e mais evidente limitação é a dificuldade em apresentar evidências que deem suporte mais conclusivo à abordagem metodológica que considera modelos MGARCH. Há muita literatura que aponta para a necessidade de correções na metodologia de eventos envolvendo a presença de heterocedasticidade e betas fixos, mas esta dissertação se limita a aplicação de modelos que, baseados na literatura de suporte, corrigem essas fragilidades. Comparações envolvendo testes e métodos estatísticos entre a modelagem clássica e a proposta não foram conduzidos, sendo um possível caminho de pesquisa a ser seguido, que poderia inclusive se beneficiar de técnicas de machine learning como alternativa para cálculo de anormalidades de retornos.

Uma dificuldade relevante na condução do estudo de eventos a respeito de anúncios de ofertas de debêntures foi a identificação de variáveis que pudessem medir adequadamente empresas que possuem bons projetos para investir, no sentido do artigo de Ross (1977). A variável ROE nem sempre é a melhor medida, podendo apresentar distorções relevantes caso empresas da amostra apresentem a situação de passivo a descoberto. Idealmente, a variável a ser utilizada para media oportunidades de investimentos seria o  $q$  de Tobin, mas a estimação dessa variável é desafiadora. Um caminho de pesquisa ser seguido é a verificação da reação do mercado acionário brasileiro à emissão das debêntures em si, de modo a verificar se informações adicionais são precificadas pelos agentes econômicos nestes

eventos.

Obstáculos na obtenção de uma proxy que mensurasse corretamente a surpresa na taxa de juros americana dificultaram a identificação precisa de surpresas monetárias na taxa de juros do mercado americano. Normalmente, a estimação da surpresa na taxa de juros americana é feita com base na mudança das taxas dos contratos futuros das federal funds rate, como visto nos trabalhos de [Rigobon e Sack \(2004\)](#) e [Bernanke e Kuttner \(2005\)](#). A obtenção desses dados, no entanto, não foi possível o que prejudicou severamente a agregação desse impacto informacional ao cálculo dos modelos probabilísticos explicativos. A identificação de uma variável do mercado brasileiro que capture essa informação seria de grande benefício para pesquisas futuras que busquem investigar a transferência da política monetária americana ao mercado brasileiro.

## Referências

- ARROW, K. J.; DEBREU, G. Existence of an Equilibrium for a Competitive Economy. *Econometrica*, [Wiley, Econometric Society], v. 22, n. 3, p. 265–290, jan 1954. ISSN 00129682, 14680262. Disponível em: <<http://www.jstor.org/stable/1907353>>. Citado 2 vezes nas páginas 1 e 12.
- AVELINO, R. R. G. Impact of Merger Announcements on the Stock Returns of Brazilian Acquiring Firms. *Estudos Econômicos (São Paulo)*, Scielo, v. 52, p. 397–428, jun 2022. ISSN 0101-4161. Disponível em: <<https://www.scielo.br/j/ee/a/q4K7WLksNNKjK85nPnmQFxx/>>. Citado 7 vezes nas páginas 4, 8, 25, 43, 46, 61 e 62.
- AZAD, N. F.; SERLETIS, A. Spillovers of u.s. monetary policy uncertainty on inflation targeting emerging economies. *Emerging Markets Review*, v. 51, p. 100875, 2022. ISSN 1566-0141. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1566014121000832>>. Citado na página 45.
- BACHELIER, L. Louis Bachelier’s theory of speculation: The origins of modern finance. *Louis Bachelier’s Theory of Speculation: The Origins of Modern Finance*, p. 1–188, jan 2011. Citado na página 14.
- BAJAJ, Y.; KASHIRAMKA, S.; SINGH, S. Application of capital structure theories: a systematic review. *Journal of Advances in Management Research*, Emerald Publishing Limited, v. 18, n. 2, p. 173–199, jan 2021. ISSN 0972-7981. Disponível em: <<https://doi.org/10.1108/JAMR-01-2020-0017>>. Citado na página 23.
- BALABAN, E.; CONSTANTINOU, C. T. Volatility clustering and event-induced volatility: Evidence from UK mergers and acquisitions. *The European Journal of Finance*, v. 12, n. 5, p. 449–453, 2006. Disponível em: <<https://econpapers.repec.org/RePEc:taf:eurjfi:v:12:y:2006:i:5:p:449-453>>. Citado 5 vezes nas páginas 4, 21, 24, 43 e 45.
- BALL, R.; BROWN, P. An Empirical Evaluation of Accounting Income Numbers. *Journal of Accounting Research*, [Accounting Research Center, Booth School of Business, University of Chicago, Wiley], v. 6, n. 2, p. 159–178, oct 1968. ISSN 00218456, 1475679X. Disponível em: <<http://www.jstor.org/stable/2490232>>. Citado na página 17.
- BANZ, R. W. The relationship between return and market value of common stocks. *Journal of Financial Economics*, v. 9, n. 1, p. 3–18, 1981. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304405X81900180>>. Citado na página 12.
- BARROSO, J. B. R. B.; SILVA, L. A. P. da; SALES, A. S. Quantitative easing and related capital flows into Brazil: Measuring its effects and transmission channels through a rigorous counterfactual evaluation. *Journal of International Money and Finance*, v. 67, p. 102–122, 2016. ISSN 0261-5606. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0261560615001138>>. Citado na página 43.



- BASU, S. The relationship between earnings' yield, market value and return for nyse common stocks: Further evidence. *Journal of Financial Economics*, v. 12, n. 1, p. 129–156, 1983. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304405X83900314>>. Citado na página 12.
- BAUWENS, L.; LAURENT, S.; ROMBOUTS, J. V. K. Multivariate GARCH models: a survey. *Journal of Applied Econometrics*, John Wiley Sons, Ltd, v. 21, n. 1, p. 79–109, jan 2006. ISSN 0883-7252. Disponível em: <<https://doi.org/10.1002/jae.842>>. Citado 4 vezes nas páginas 24, 48, 49 e 50.
- BERNANKE, B. S.; KUTTNER, K. N. What Explains the Stock Market's Reaction to Federal Reserve Policy? *The Journal of Finance*, v. 60, n. 3, p. 1221–1257, 2005. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-6261.2005.00760.x>>. Citado 9 vezes nas páginas 5, 42, 43, 44, 51, 53, 55, 60 e 64.
- BERNINGER, M.; FIESENIG, B.; SCHIERECK, D. The performance of corporate bond issuers in times of financial crisis: empirical evidence from Latin America. *The Journal of Risk Finance*, Emerald Publishing Limited, v. 22, n. 1, p. 78–92, jan 2021. ISSN 1526-5943. Disponível em: <<https://doi.org/10.1108/JRF-06-2020-0129>>. Citado 2 vezes nas páginas 23 e 28.
- BEST, R. W. Relative information asymmetry as a determinant of the market reaction to corporate financing announcements. *Journal of Economics and Finance*, v. 18, n. 2, p. 231–240, 1994. ISSN 1938-9744. Disponível em: <<https://doi.org/10.1007/BF02920525>>. Citado 4 vezes nas páginas 23, 27, 35 e 40.
- BLACK, F.; JENSEN, M. C.; SCHOLES, M. The capital asset pricing model: Some empirical tests. 1972. Citado na página 11.
- BLACK, F.; SCHOLES, M. The pricing of options and corporate liabilities. *Journal of Political Economy*, University of Chicago Press, v. 81, n. 3, p. 637–654, 1973. ISSN 00223808, 1537534X. Disponível em: <<http://www.jstor.org/stable/1831029>>. Citado na página 2.
- BLUME, M. E.; FRIEND, I. A new look at the capital asset pricing model. *The Journal of Finance*, [American Finance Association, Wiley], v. 28, n. 1, p. 19–33, 1973. ISSN 00221082, 15406261. Disponível em: <<http://www.jstor.org/stable/2978165>>. Citado na página 11.
- BOEHMER, E.; MASUMECI, J.; POULSEN, A. B. Event-study methodology under conditions of event-induced variance. *Journal of Financial Economics*, v. 30, n. 2, p. 253–272, 1991. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304405X9190032F>>. Citado na página 4.
- BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. *Journal of Econometrics*, v. 31, n. 3, p. 307–327, 1986. ISSN 0304-4076. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304407686900631>>. Citado na página 24.
- BROWN, S. J.; WARNER, J. B. Measuring security price performance. *Journal of Financial Economics*, v. 8, n. 3, p. 205–258, 1980. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304405X80900021>>. Citado 4 vezes nas páginas 18, 19, 32 e 50.

CAMPBELL, J.; LO, A.; MACKINLAY, A. The Econometrics of Financial Markets / J.Y. Campbell, A.W. Lo, A.C. MacKinlay. *The Econometrics of Financial Markets*, jun 2012. Citado 10 vezes nas páginas 4, 17, 18, 19, 30, 31, 35, 47, 48 e 62.

CAMPBELL, J. Y.; COCHRANE, J. H. Explaining the poor performance of consumption-based asset pricing models. *The Journal of Finance*, v. 55, n. 6, p. 2863–2878, 2000. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/0022-1082.00310>>. Citado na página 3.

CARHART, M. M. On Persistence in Mutual Fund Performance. *The Journal of Finance*, v. 52, n. 1, p. 57–82, 1997. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-6261.1997.tb03808.x>>. Citado 3 vezes nas páginas 3, 11 e 12.

CAVACA, I. B.; MEURER, R. International monetary policy spillovers: Linkages between U.S. and South American yield curves. *International Review of Economics Finance*, v. 76, p. 737–754, 2021. ISSN 1059-0560. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1059056021001507>>. Citado na página 43.

COCHRANE, J. *Asset pricing*. Princeton [u.a.]: Princeton Univ. Press, 2001. ISBN 0691074984. Disponível em: <[http://gso.gbv.de/DB=2.1/CMD?ACT=SRCHA&SRT=YOP&IKT=1016&TRM=ppn+322224764&sourceid=fbw\\_bibsonomy](http://gso.gbv.de/DB=2.1/CMD?ACT=SRCHA&SRT=YOP&IKT=1016&TRM=ppn+322224764&sourceid=fbw_bibsonomy)>. Citado 2 vezes nas páginas 3 e 12.

CORHAY, A.; RAD, A. Conditional heteroskedasticity adjusted market model and an event study. *The Quarterly Review of Economics and Finance*, v. 36, n. 4, p. 529–538, 1996. ISSN 1062-9769. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1062976996900502>>. Citado 8 vezes nas páginas 4, 18, 24, 35, 43, 45, 54 e 62.

COURNOT. Augustin Cournot. The Mathematical Principles of the Theory of Wealth, 1838. *The Economic Journal*, v. 39, n. 153, p. 91–92, mar 1929. ISSN 0013-0133. Disponível em: <<https://doi.org/10.2307/2224222>>. Citado na página 1.

CURCURU, S. E. et al. *International Spillovers of Monetary Policy : Conventional Policy vs. Quantitative Easing*. [S.l.], 2018. Disponível em: <<https://ideas.repec.org/p/fip/fedgif/1234.html>>. Citado 3 vezes nas páginas 5, 45 e 60.

DANN, L. Y.; MIKKELSON, W. H. Convertible debt issuance, capital structure change and financing-related information: Some new evidence. *Journal of Financial Economics*, v. 13, n. 2, p. 157–186, 1984. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304405X84900229>>. Citado 2 vezes nas páginas 23 e 27.

DELCEY, T. Samuelson vs Fama on the Efficient Market Hypothesis: The Point of View of Expertise. *Economia - History/Methodology/Philosophy*, NecPlus/Association (Economia), v. 9, n. 1, p. 37–58, 2019. Disponível em: <<https://hal.science/hal-01618347>>. Citado na página 14.

ENGLE, R. Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models. *Journal of Business Economic Statistics*, [American Statistical Association, Taylor Francis, Ltd.], v. 20, n. 3, p. 339–350, 2002. ISSN 07350015. Disponível em: <<http://www.jstor.org/stable/1392121>>. Citado 2 vezes nas páginas 48 e 49.

- ENGLE, R. F.; KRONER, K. F. Multivariate Simultaneous Generalized Arch. *Econometric Theory*, Cambridge University Press, v. 11, n. 1, p. 122–150, jan 1995. ISSN 02664666, 14694360. Disponível em: <<http://www.jstor.org/stable/3532933>>. Citado na página 31.
- ENGLE, R. F.; KRONER, K. F. Multivariate simultaneous generalized arch. *Econometric Theory*, Cambridge University Press, v. 11, n. 1, p. 122–150, 1995. ISSN 02664666, 14694360. Disponível em: <<http://www.jstor.org/stable/3532933>>. Citado na página 48.
- ETEROVIC, N. A.; ETEROVIC, D. S. Stock, Bonds and the US Dollar - Measuring Domestic and International Market Developments in an Emerging Market. 2022. Disponível em: <<https://dx.doi.org/10.2139/ssrn.4350827>>. Citado 3 vezes nas páginas 43, 54 e 60.
- FAMA, E. F. Random walks in stock market prices. *Financial Analysts Journal*, CFA Institute, v. 21, n. 5, p. 55–59, 1965. ISSN 0015198X. Disponível em: <<http://www.jstor.org/stable/4469865>>. Citado na página 16.
- FAMA, E. F. The Behavior of Stock-Market Prices. *The Journal of Business*, University of Chicago Press, v. 38, n. 1, p. 34–105, jan 1965. ISSN 00219398, 15375374. Disponível em: <<http://www.jstor.org/stable/2350752>>. Citado na página 14.
- FAMA, E. F. Efficient Capital Markets: A Review of Theory and Empirical Work. *The Journal of Finance*, [American Finance Association, Wiley], v. 25, n. 2, p. 383–417, oct 1970. ISSN 00221082, 15406261. Disponível em: <<http://www.jstor.org/stable/2325486>>. Citado 4 vezes nas páginas 3, 14, 15 e 63.
- FAMA, E. F. Market efficiency, long-term returns, and behavioral finance the comments of brad barber, david hirshleifer, s.p. kothari, owen lamont, mark mitchell, hersh shefrin, robert shiller, rex sinquefeld, richard thaler, theo vermaelen, robert vishny, ivo welch, and a referee have been helpful. kenneth french and jay ritter get special thanks.1. *Journal of Financial Economics*, v. 49, n. 3, p. 283–306, 1998. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304405X98000269>>. Citado na página 4.
- FAMA, E. F. *Two Pillars of Asset Pricing*. [S.l.], 2013. Disponível em: <[https://ideas.repec.org/p/ris/nobelp/2013\\_008.html](https://ideas.repec.org/p/ris/nobelp/2013_008.html)>. Citado 5 vezes nas páginas 3, 4, 10, 44 e 63.
- FAMA, E. F. et al. The Adjustment of Stock Prices to New Information. *International Economic Review*, [Economics Department of the University of Pennsylvania, Wiley, Institute of Social and Economic Research, Osaka University], v. 10, n. 1, p. 1–21, oct 1969. ISSN 00206598, 14682354. Disponível em: <<http://www.jstor.org/stable/2525569>>. Citado na página 17.
- FAMA, E. F.; FRENCH, K. R. Common risk factors in the returns on stocks and bonds. *Journal of Financial Economics*, v. 33, n. 1, p. 3–56, 1993. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304405X93900235>>. Citado 4 vezes nas páginas 2, 11, 12 e 19.
- FAMA, E. F.; FRENCH, K. R. A five-factor asset pricing model. *Journal of Financial Economics*, v. 116, n. 1, p. 1–22, 2015. ISSN 0304-405X. Disponível em:

<<https://www.sciencedirect.com/science/article/pii/S0304405X14002323>>. Citado 3 vezes nas páginas 3, 11 e 12.

FUNGÁČOVÁ, Z.; GODLEWSKI, C. J.; WEILL, L. Does the type of debt matter? Stock market perception in Europe. *The Quarterly Review of Economics and Finance*, v. 75, p. 247–256, 2020. ISSN 1062-9769. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1062976917303800>>. Citado 2 vezes nas páginas 23 e 28.

GLICK, R.; LEDUC, S. Unconventional Monetary Policy and the Dollar: Conventional Signs, Unconventional Magnitudes. *International Journal of Central Banking*, v. 14, n. 5, p. 103–152, December 2018. Disponível em: <<https://ideas.repec.org/a/ijc/ijcjou/y2018q4a3.html>>. Citado 3 vezes nas páginas 5, 44 e 45.

GORDON, M. J.; SHAPIRO, E. Capital equipment analysis: The required rate of profit. *Management Science*, INFORMS, v. 3, n. 1, p. 102–110, 1956. ISSN 00251909, 15265501. Disponível em: <<http://www.jstor.org/stable/2627177>>. Citado 2 vezes nas páginas 1 e 9.

GUO, H.; HUNG, C.-H. D.; KONTONIKAS, A. The Fed and the stock market: A tale of sentiment states. *Journal of International Money and Finance*, v. 128, n. C, 2022. Disponível em: <<https://ideas.repec.org/a/eee/jimfin/v128y2022ics0261560622001103.html>>. Citado na página 44.

GÜRKAYNAK, R.; SACK, B.; SWANSON, E. Do Actions Speak Louder Than Words? The Response of Asset Prices to Monetary Policy Actions and Statements. *International Journal of Central Banking*, v. 1, n. 1, 2005. Disponível em: <<https://econpapers.repec.org/RePEc:ijc:ijcjou:y:2005:q:2:a:2>>. Citado 7 vezes nas páginas 5, 42, 44, 51, 53, 59 e 60.

HAUSMAN, J.; WONGSWAN, J. Global asset prices and FOMC announcements. *Journal of International Money and Finance*, v. 30, n. 3, p. 547–571, 2011. ISSN 0261-5606. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0261560611000180>>. Citado 4 vezes nas páginas 43, 54, 55 e 60.

HOWTON, S. D.; HOWTON, S. W.; PERFECT, S. B. THE MARKET REACTION TO STRAIGHT DEBT ISSUES: THE EFFECTS OF FREE CASH FLOW. *Journal of Financial Research*, John Wiley Sons, Ltd, v. 21, n. 2, p. 219–228, jun 1998. ISSN 0270-2592. Disponível em: <<https://doi.org/10.1111/j.1475-6803.1998.tb00681.x>>. Citado 2 vezes nas páginas 27 e 33.

HWANG, S.; Valls Pereira, P. L. Small sample properties of GARCH estimates and persistence. *The European Journal of Finance*, Routledge, v. 12, n. 6-7, p. 473–494, oct 2006. ISSN 1351-847X. Disponível em: <<https://doi.org/10.1080/13518470500039436>>. Citado 2 vezes nas páginas 32 e 50.

JAROCIŃSKI, M.; KARADI, P. Deconstructing Monetary Policy Surprises—The Role of Information Shocks. *American Economic Journal: Macroeconomics*, v. 12, n. 2, p. 1–43, 2020. Disponível em: <<https://econpapers.repec.org/RePEc:aea:aejmac:v:12:y:2020:i:2:p:1-43>>. Citado na página 48.

JENSEN, M. C.; MECKLING, W. H. Theory of the firm: Managerial behavior, agency costs and ownership structure. *Journal of Financial Economics*, v. 3, n. 4, p. 305–360, 1976. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304405X7690026X>>. Citado 3 vezes nas páginas 5, 23 e 26.

KOUTMOS, D. et al. The timing of new corporate debt issues and the risk-return tradeoff. *Review of Quantitative Finance and Accounting*, v. 50, n. 4, p. 943–978, 2018. ISSN 1573-7179. Disponível em: <<https://doi.org/10.1007/s11156-017-0651-z>>. Citado 5 vezes nas páginas 4, 21, 24, 27 e 38.

KRAUS, A.; LITZENBERGER, R. H. A State-Preference Model of Optimal Financial Leverage. *The Journal of Finance*, [American Finance Association, Wiley], v. 28, n. 4, p. 911–922, sep 1973. ISSN 00221082, 15406261. Disponível em: <<http://www.jstor.org/stable/2978343>>. Citado 3 vezes nas páginas 5, 23 e 25.

KUMAR, S.; COLOMBAGE, S.; RAO, P. Research on capital structure determinants: a review and future directions. *International Journal of Managerial Finance*, Emerald Publishing Limited, v. 13, n. 2, p. 106–132, jan 2017. ISSN 1743-9132. Disponível em: <<https://doi.org/10.1108/IJMF-09-2014-0135>>. Citado na página 33.

KUMAR, S.; SUREKA, R.; COLOMBAGE, S. Capital structure of SMEs: a systematic literature review and bibliometric analysis. *Management Review Quarterly*, v. 70, n. 4, p. 535–565, 2020. ISSN 2198-1639. Disponível em: <<https://doi.org/10.1007/s11301-019-00175-4>>. Citado na página 23.

LINTNER, J. The valuation of risk assets and the selection of risky investments in stock portfolios and capital budgets. *The Review of Economics and Statistics*, The MIT Press, v. 47, n. 1, p. 13–37, 1965. ISSN 00346535, 15309142. Disponível em: <<http://www.jstor.org/stable/1924119>>. Citado 3 vezes nas páginas 1, 9 e 19.

LODGE, D.; MANU, A.-S. Eme financial conditions: Which global shocks matter? *Journal of International Money and Finance*, v. 120, p. 102479, 2022. ISSN 0261-5606. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0261560621001303>>. Citado 2 vezes nas páginas 45 e 48.

LUBYS, J.; PANDA, P. US and EU unconventional monetary policy spillover on BRICS financial markets: an event study. *Empirica*, v. 48, n. 2, p. 353–371, 2021. ISSN 1573-6911. Disponível em: <<https://doi.org/10.1007/s10663-020-09480-8>>. Citado 3 vezes nas páginas 43, 54 e 60.

LUCAS, R. E. Asset prices in an exchange economy. *Econometrica*, [Wiley, Econometric Society], v. 46, n. 6, p. 1429–1445, 1978. ISSN 00129682, 14680262. Disponível em: <<http://www.jstor.org/stable/1913837>>. Citado 2 vezes nas páginas 3 e 12.

MANSLEY, N. et al. Good growth, bad growth: Market reaction to capital raising for REIT expansion. *International Review of Financial Analysis*, v. 86, p. 102499, 2023. ISSN 1057-5219. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1057521923000157>>. Citado na página 28.

MARKOWITZ, H. Portfolio Selection. *The Journal of Finance*, [American Finance Association, Wiley], v. 7, n. 1, p. 77–91, jan 1952. ISSN 00221082, 15406261. Disponível em: <<http://www.jstor.org/stable/2975974>>. Citado 2 vezes nas páginas 1 e 9.

- MATSUMOTO, G. S.; BARALDI, G. P.; JUCá, M. N. Estudo de eventos sobre o anúncio da emissão de debêntures. *Revista Brasileira de Finanças*, v. 16, n. 3, p. 493–520, 2018. ISSN 1679-0731. Disponível em: <<http://www.spell.org.br/documentos/ver/51716/estudo-de-eventos-sobre-o-anuncio-da-emissao-de-debentures>>. Citado 3 vezes nas páginas 24, 35 e 40.
- MCWILLIAMS, A. Event Studies in Management Research: Theoretical and Empirical Issues. *The Academy of Management Journal*, v. 40, p. 626–657, 1997. Disponível em: <<https://journals.aom.org/doi/abs/10.5465/257056>>. Citado 6 vezes nas páginas 4, 19, 31, 32, 48 e 50.
- MERTON, R. C. An intertemporal capital asset pricing model. *Econometrica*, [Wiley, Econometric Society], v. 41, n. 5, p. 867–887, 1973. ISSN 00129682, 14680262. Disponível em: <<http://www.jstor.org/stable/1913811>>. Citado 2 vezes nas páginas 2 e 11.
- MODIGLIANI, F.; MILLER, M. H. The Cost of Capital, Corporation Finance and the Theory of Investment. *The American Economic Review*, American Economic Association, v. 48, n. 3, p. 261–297, sep 1958. ISSN 00028282. Disponível em: <<http://www.jstor.org/stable/1809766>>. Citado 2 vezes nas páginas 5 e 23.
- MODIGLIANI, F.; MILLER, M. H. Corporate Income Taxes and the Cost of Capital: A Correction. *The American Economic Review*, American Economic Association, v. 53, n. 3, p. 433–443, sep 1963. ISSN 00028282. Disponível em: <<http://www.jstor.org/stable/1809167>>. Citado 2 vezes nas páginas 5 e 25.
- MYERS, S. C.; MAJLUF, N. S. Corporate financing and investment decisions when firms have information that investors do not have. *Journal of Financial Economics*, v. 13, n. 2, p. 187–221, 1984. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0304405X84900230>>. Citado 3 vezes nas páginas 5, 23 e 26.
- NEELY, C. J. Unconventional monetary policy had large international effects. *Journal of Banking Finance*, v. 52, p. 101–111, 2015. ISSN 0378-4266. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0378426614003859>>. Citado na página 48.
- PADULA, A. J. A.; ALBUQUERQUE, P. H. M. Government corruption on Brazilian capital markets: A study on Lava Jato (Car Wash) investigation. *RAE Revista de Administracao de Empresas*, Fundacao Getulio Vargas, v. 58, n. 4, p. 405–417, 2018. ISSN 00347590. Disponível em: <<https://www.scopus.com/inward/record.uri?eid=2-s2.0-85054626975&doi=10.1590%2FS0034-759020180406&partnerID=40&md5=2bc3129282ee61c11322323eb2d674db>>. Citado 4 vezes nas páginas 4, 21, 43 e 45.
- REYES, M. G. Size, time-varying beta, and conditional heteroscedasticity in UK stock returns. *Review of Financial Economics*, v. 8, n. 1, p. 1–10, 1999. ISSN 1058-3300. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1058330099000075>>. Citado 5 vezes nas páginas 4, 21, 24, 44 e 45.
- RIGOBON, R.; SACK, B. Measuring The Reaction of Monetary Policy to the Stock Market\*. *The Quarterly Journal of Economics*, v. 118, n. 2, p. 639–669, may 2003. ISSN 0033-5533. Disponível em: <<https://doi.org/10.1162/003355303321675473>>. Citado na página 42.

- RIGOBON, R.; SACK, B. The impact of monetary policy on asset prices. *Journal of Monetary Economics*, v. 51, n. 8, p. 1553–1575, 2004. ISSN 0304-3932. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304393204001138>>. Citado 8 vezes nas páginas 5, 42, 44, 51, 53, 55, 60 e 64.
- ROSA, C. The Validity of the Event-study Approach: Evidence from the Impact of the Fed's Monetary Policy on US and Foreign Asset Prices. *Economica*, Wiley, v. 78, n. 311, p. 429–439, aug 2011. ISSN 00130427, 14680335. Disponível em: <<http://www.jstor.org/stable/41236141>>. Citado 3 vezes nas páginas 43, 55 e 60.
- ROSS, S. A. The arbitrage theory of capital asset pricing. *Journal of Economic Theory*, v. 13, n. 3, p. 341–360, 1976. ISSN 0022-0531. Disponível em: <<https://www.sciencedirect.com/science/article/pii/0022053176900466>>. Citado 2 vezes nas páginas 2 e 11.
- ROSS, S. A. The Determination of Financial Structure: The Incentive-Signalling Approach. *The Bell Journal of Economics*, [RAND Corporation, Wiley], v. 8, n. 1, p. 23–40, mar 1977. ISSN 0361915X. Disponível em: <<http://www.jstor.org/stable/3003485>>. Citado 4 vezes nas páginas 5, 23, 26 e 63.
- SAMUELSON, P. Proof that Properly Anticipated Prices Fluctuate Randomly. In: . World Scientific Publishing Co. Pte. Ltd., 2015. p. 25–38 BT – THE WORLD SCIENTIFIC HANDBOOK OF FUTUR. Disponível em: <[https://econpapers.repec.org/RePEc:wsi:wschap:9789814566926\\_0002](https://econpapers.repec.org/RePEc:wsi:wschap:9789814566926_0002)>. Citado na página 14.
- SAVICKAS, R. Event-Induced Volatility and Tests for Abnormal Performance. *Journal of Financial Research*, John Wiley Sons, Ltd, v. 26, n. 2, p. 165–178, jun 2003. ISSN 0270-2592. Disponível em: <<https://doi.org/10.1111/1475-6803.00052>>. Citado 6 vezes nas páginas 4, 20, 21, 24, 43 e 45.
- SHARPE, W. CAPITAL ASSET PRICES: A THEORY OF MARKET EQUILIBRIUM UNDER CONDITIONS OF RISK. *Journal of Finance*, v. 19, n. 3, p. 425–442, 1964. Disponível em: <<https://econpapers.repec.org/RePEc:bla:jfinan:v:19:y:1964:i:3:p:425-442>>. Citado 3 vezes nas páginas 1, 9 e 19.
- SHARPE, W. F. A simplified model for portfolio analysis. *Management Science*, INFORMS, v. 9, n. 2, p. 277–293, 1963. ISSN 00251909, 15265501. Disponível em: <<http://www.jstor.org/stable/2627407>>. Citado 3 vezes nas páginas 18, 31 e 48.
- SMITH, A. *An Inquiry into the Nature and Causes of the Wealth of Nations*. McMaster University Archive for the History of Economic Thought, 1776. Disponível em: <<https://econpapers.repec.org/RePEc:hay:hetboo:smith1776>>. Citado na página 1.
- SPIESS, D.; AFFLECK-GRAVES, J. The long-run performance of stock returns following debt offerings. *Journal of Financial Economics*, v. 54, n. 1, p. 45–73, 1999. ISSN 0304-405X. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0304405X99000318>>. Citado 4 vezes nas páginas 23, 27, 35 e 40.
- THORBECKE, W. On stock market returns and monetary policy. *The Journal of Finance*, v. 52, n. 2, p. 635–654, 1997. Disponível em: <<https://onlinelibrary.wiley.com/doi/abs/10.1111/j.1540-6261.1997.tb04816.x>>. Citado 2 vezes nas páginas 42 e 43.

VELAYUTHAM, E.; RATNAM, V. Corporate social responsibility, business group affiliation and shareholder wealth: evidence from an emerging market. *Social Responsibility Journal*, Emerald Publishing Limited, v. 18, n. 4, p. 723–743, jan 2022. ISSN 1747-1117. Disponível em: <<https://doi.org/10.1108/SRJ-08-2020-0337>>. Citado na página 28.

Walras, L. *Elements d'économie politique pure, ou, Théorie de la richesse sociale [electronic resource] / par Leon Walras*. Lausanne: L. Corbaz, 1874. (Making of the modern world. Part 2 (1851-1914)). Citado na página 1.

YI, X. et al. The impacts of the COVID-19 pandemic on China's green bond market. *Finance Research Letters*, v. 42, p. 101948, 2021. ISSN 1544-6123. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1544612321000295>>. Citado na página 28.

YIN, S. et al. Stock price reaction to profit warnings: the role of time-varying betas. *Review of Quantitative Finance and Accounting*, v. 50, n. 1, p. 67–93, 2018. ISSN 1573-7179. Disponível em: <<https://doi.org/10.1007/s11156-017-0623-3>>. Citado 8 vezes nas páginas 4, 8, 25, 38, 43, 46, 61 e 62.



# Apêndices

# APÊNDICE A – Apêndice A - Amostra de empresas do artigo 1

Tabela 16 – Empresas da amostra e testes de estacionariedade

Empresa	Ticker	Setor	Dickey-Fuller	Lag Order	P value
Alianscsonae	ALSO3	Financeiro	-6,834	6	0,01
Alpargatas	ALPA4	Consumo Cíclico	-7,159	6	0,01
AMBEV	ABEV3	Consumo Não Cíclico	-7,786	6	0,01
AZUL	AZUL4	Bens Industriais	-6,387	6	0,01
B3	B3SA3	Financeiro	-7,187	6	0,01
BRF S.A.	BRFS3	Consumo Não Cíclico	-6,126	6	0,01
Carrefour Br	CRFB3	Consumo Não Cíclico	-6,008	6	0,01
CCR S.A.	CCRO3	Bens Industriais	-6,072	6	0,01
Cia Saneamento São Paulo	SBSP3	Utilidade Pública	-7,117	6	0,01
Cia Siderúrgica Nacional	CSNA3	Materiais Básicos	-7,223	6	0,01
CIEL3	CIEL3	Financeiro	-6,003	6	0,01
COGNA ON	COGN3	Consumo Cíclico	-5,777	6	0,01
COPEL	CPLE6	Utilidade Pública	-6,545	6	0,01
CVC Brasil	CVCB3	Consumo Cíclico	-6,786	6	0,01
Cyrela Realtec	CYRE3	Consumo Cíclico	-6,686	6	0,01
DEXCO	DXCO3	Materiais Básicos	-7,577	6	0,01
Ecorodovias	ECOR3	Bens Industriais	-6,323	6	0,01
EDP - Energias do Brasil S.A.	ENBR3	Utilidade Pública	-6,017	6	0,01
Eletrobras	ELET3	Utilidade Pública	-6,423	6	0,01
ENERGISA S.A.	EGIE3	Utilidade Pública	-6,386	6	0,01
ENEVA S.A.	ENEV3	Utilidade Pública	-6,653	6	0,01
ENGIE Energias Brasil S,A	ENGI11	Utilidade Pública	-5,805	6	0,01
Euatorial Energia S.A.	EQTL3	Utilidade Pública	-6,537	6	0,01
EZ TEC S.A.	EZTC3	Consumo Cíclico	-6,380	6	0,01
Fleury S.A.	FLRY3	Saúde	-7,624	6	0,01
Gerdau S.A.	GGBR4	Materiais Básicos	-6,363	6	0,01
GOL Linhas Aéreas S.A.	GOLL4	Bens Industriais	-6,735	6	0,01
HAPVIDA S.A.	HAPV3	Saúde	-6,416	6	0,01
HYPERA S.A.	HYPE3	Saúde	-7,506	6	0,01
ITAUSA S.A.	ITSA4	Financeiro	-6,339	6	0,01
JBS S.A.	JBSS3	Consumo Não Cíclico	-6,984	6	0,01
Localiza Rent a Car S.A.	RENT3	Consumo Cíclico	-6,768	6	0,01
Lojas Renner	LREN3	Consumo Cíclico	-7,034	6	0,01
Magazine Luiza S.A.	MGLU3	Consumo Cíclico	-5,769	6	0,01
Marfrig Global Foods S.A.	MRFG3	Consumo Não Cíclico	-5,979	6	0,01
Minerva S.A.	BEEF3	Consumo Não Cíclico	-6,351	6	0,01
MRV Engenharia S.A.	MRVE3	Consumo Cíclico	-6,092	6	0,01
Petro Rio S.A.	PRIO3	Petróleo, Gás e Biocombustíveis	-7,779	6	0,01
Petróleo Brasileiro S.A.	PETR3	Petróleo, Gás e Biocombustíveis	-5,975	6	0,01
Qualicorp S.A.	QUAL3	Saúde	-8,009	6	0,01
Raia Drogasil S.A.	RADL3	Saúde	-7,147	6	0,01
RUMO S.A.	RAIL3	Bens Industriais	-6,121	6	0,01
São Martinho S.A.	SMTO3	Consumo Não Cíclico	-6,612	6	0,01
Telefônica Brasil S.A.	VIVT3	Comunicações	-6,320	6	0,01
TOTVS S.A.	TOTS3	Tecnologia da Informação	-6,375	6	0,01
Transmissora Aliança S.A.	TAEE11	Utilidade Pública	-7,118	6	0,01
Usiminas	USIM5	Materiais Básicos	-7,126	6	0,01
Vale S.A.	VALE3	Materiais Básicos	-7,282	6	0,01
VIBRA Energia S.A.	VBBR3	Petróleo, Gás e Biocombustíveis	-7,157	6	0,01
YDUQS Participações S.A.	YDUQ3	Consumo Cíclico	-6,727	6	0,01
Ibovespa	IBOV	Índice	-6,702	6	0,01

Nota: Nesta tabela são apresentadas as empresas que fizeram parte da amostra do estudo, seus códigos de negociação e setores econômicos. Foram realizados os testes de estacionariedade para todas as empresas da amostra, considerando todas as observações obtidas na Economatica. Em todos os casos, a hipótese nula de que as séries temporais não são estacionárias foi rejeitada. Elaboração do autor.

# APÊNDICE B – Apêndice B - Códigos utilizados no artigo 1

## Cálculo do beta médio

```
““{r setup, include=FALSE}
library(readxl)
library(xts)
library(dplyr)
library(xlsx)
library(BEKKs)
library(ggplot2)
library(tidyr)
library(purrr)

#Janela de estimao
L1 <- 500

myFunction <- function(x, y) {

  if (identical(which(as.Date(x) == as.Date(y)), integer(0)) == FALSE){

    return(which(as.Date(x) == as.Date(y)))

  } else {

    return(myFunction(x,as.Date(y+1)))

  }
}

datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/
↪ V2/Base de Dados.xlsx", sheet = 6)

#datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital
↪ /V2/economica - Emissoes Debentures.xlsx", sheet = 3)
```

```
empresa <- unique(datas$Codigo)

lista_indices <- list()

for (i in 1:length(empresa)) {

  Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↳ Capital/V2/COTACOES SOMENTE DAS EMPRESAS DO ESTUDO.xlsx")

  Dados <- subset(Dados, select = c("Data", empresa[i], "IBOV")) #
    ↳ Selecionando somente a empresa e o indice de mercado

  qxts <- xts(Dados[,-1], order.by=Dados$Data) #Transformando em serie
    ↳ temporal

  qxts <- na.omit(qxts) #Omitindo NAs. Caso as NAs nao sejam omitidas
    ↳ haveria problemas por todas a programao

  datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↳ Capital/V2/Base de Dados.xlsx", sheet = 6)

  #datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↳ Capital/V2/economica - Emisses Debntures.xlsx", sheet = 3)

  datas <- datas[datas$Codigo == empresa[i], ] #Filtrando os eventos para
    ↳ a empresa de interesse

  datas <- datas[order(datas$'Data do Evento', decreasing = TRUE),] #
    ↳ Ordenando as datas

  achar_index <- data.frame(date=index(qxts), coredata(qxts))

  vetor_indices <- c()

  for (j in 1:length(datas$'Data do Evento')) {

    d1 <- achar_index$date

    d2 <- datas$'Data do Evento'[j]
```

```
vetor_indices[j] <- myFunction(d1,d2)

}

cat(empresa[i],": ",vetor_indices,"\n-----\n")

lista_indices[[i]] <- vetor_indices

}

names(lista_indices) <- empresa

lista_indices <- lapply(lista_indices, unique)

lista_indices <- lapply(lista_indices, function(x) x[x > L1])

lista_indices <- Filter(function(x) !is.null(x) && length(x) > 0,
  ↪ lista_indices)

empresa <- NULL

empresa <- names(lista_indices)

rm(achar_index, Dados, datas, qxts, i, j, vetor_indices, d1, d2)

#Desabilitando a notao cienttifica
options(scipen=999)

lista_suprema <- list()

for (o in 1:length(empresa)) {

  #Carregando a base de dados e removendo NA's
  Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↪ Capital/V2/COTAES SOMENTE DAS EMPRESAS DO ESTUDO.xlsx")

  Dados <- subset(Dados, select = c("Data", empresa[o], "IBOV"))
```

```
qxts <- xts(Dados[,-1], order.by=Dados$Data)

qxts <- na.omit(qxts)

#Vetor de ndices que correspondentes s datas de ocorrencia dos eventos
indices_event <- lista_indices[[empresa[o]]]
indices_estimation <- c(indices_event-1)

#Listas para salvar os resultados dos clculos
result_beta <- list()

days_before <- 50

days_forward <- 50

beta_real <- list()

for (i in 1:length(indices_event)) {

  #Definindo as datas das janelas de eventos e de estimao
  event_start = as.character(index(qxts[indices_event[i]-days_before])
  ↪ )

  event_end = as.character(index(qxts[indices_event[i]+days_forward]))

  estimation_start = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-L1])))

  estimation_end = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-1])))

  #####
  ↪
  #BETA REAL DURANTE OS EVENTOS
  event_qxts2 <- window(qxts, start = estimation_start, end =
  ↪ event_end)

  obj_spec <- bekk_spec()
```

```

    bekk_model2 <- bekk_fit(obj_spec, as.matrix(event_qxts2),
      ↪ QML_t_ratios = FALSE, max_iter = 50, crit = 1e-9)

    beta_total <- bekk_model2$H_t[,2]/bekk_model2$H_t[,4]

    event_qxts2$beta1 <- beta_total

    beta_durante_evento <- window(event_qxts2$beta1, start = event_start
      ↪ , end = event_end)
    #####
      ↪

    beta_real[[i]] <- as.vector(beta_durante_evento$beta1)

    cat(paste("Evento", empresa[o], "dia:", as.character(index(qxts[
      ↪ indices_event[i]])), "\n", "\n-----\n
      ↪ "))

  }

  #mat <- colMeans(do.call(rbind, beta_real))

  lista_suprema[[o]] <- beta_real
}

vetor <- list()

for (k in 1:length(lista_suprema)) {

  vetor[[k]] <- colMeans(do.call(rbind, lista_suprema[[k]]))

}

vetor_final <- colMeans(do.call(rbind, vetor))

a <- c(-50:0)

```



```
b <- c(1:50)

z <- c(a,b)

data_beta <- data.frame(beta = vetor_final,
                        tempo = z)

ggplot() + geom_line(data = data_beta, aes(x = tempo, y = beta), size =
  ↪ 0.75)+
  labs(x="", y="Beta", title="")+
  geom_vline(xintercept = 0, linetype = "dotted", color = "red", size =
  ↪ 1.5)+
  theme_bw()+
  theme(axis.text.x = element_text(angle = 0, hjust = 0.5))

teste_t <- t.test(vetor_final[25:50], mu = mean(vetor_final[0:50]))

teste_wilcox <- wilcox.test(vetor_final[50:25], mu = median(vetor_final
  ↪ [0:50]))

teste_wilcox

teste_t

mean(vetor_final[0:50])

median(vetor_final[50:25])

'''
```

### Estudo de eventos BEKK GARCH

```
---
title: "Estudo de Eventos da Dissertao"
author: "Arthur de Brito Baldini"
date: "2023-02-22"
```

```
output:
  html_document: default
  pdf_document: default
---

““{r setup, include=FALSE}
library(readxl)
library(xts)
library(dplyr)
library(xlsx)
library(BEKKs)
library(ggplot2)
library(tidyr)
library(purrr)

#Janela de estimao
L1 <- 500

myFunction <- function(x, y) {

  if (identical(which(as.Date(x) == as.Date(y)), integer(0)) == FALSE){

    return(which(as.Date(x) == as.Date(y)))

  } else {

    return(myFunction(x,as.Date(y+1)))

  }
}

datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/
↪ V2/Base de Dados.xlsx", sheet = 4)

#datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital
↪ /V2/economica - Emissoes Debntures.xlsx", sheet = 3)

empresa <- unique(datas$Cdigo)
```

```
lista_indices <- list()

for (i in 1:length(empresa)) {

  Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↳ Capital/V2/COTAES SOMENTE DAS EMPRESAS DO ESTUDO.xlsx")

  Dados <- subset(Dados, select = c("Data", empresa[i], "IBOV")) #
    ↳ Selecionando somente a empresa e o índice de mercado

  qxts <- xts(Dados[,-1], order.by=Dados$Data) #Transformando em srie
    ↳ temporal

  qxts <- na.omit(qxts) #Omitindo NAs. Caso as NAs não sejam omitidas
    ↳ haver problemas por todas a programação

  datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↳ Capital/V2/Base de Dados.xlsx", sheet = 4)

  #datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↳ Capital/V2/economica - Emissões Debntures.xlsx", sheet = 3)

  datas <- datas[datas$Codigo == empresa[i], ] #Filtrando os eventos para
    ↳ a empresa de interesse

  datas <- datas[order(datas$'Data do Evento', decreasing = TRUE),] #
    ↳ Ordenando as datas

  achar_index <- data.frame(date=index(qxts), coredata(qxts))

  vetor_indices <- c()

  for (j in 1:length(datas$'Data do Evento')) {

    d1 <- achar_index$date

    d2 <- datas$'Data do Evento'[j]
```

```
vetor_indices[j] <- myFunction(d1,d2)

}

cat(empresa[i],": ",vetor_indices,"\n-----\n")

lista_indices[[i]] <- vetor_indices

}

names(lista_indices) <- empresa

lista_indices <- lapply(lista_indices, unique)

lista_indices <- lapply(lista_indices, function(x) x[x > L1])

lista_indices <- Filter(function(x) !is.null(x) && length(x) > 0,
  ↪ lista_indices)

empresa <- NULL

empresa <- names(lista_indices)

rm(achar_index, Dados, datas, qxts, i, j, vetor_indices, d1, d2)

#Desabilitando a notao cienttifica
options(scipen=999)

lista_suprema <- list()

for (o in 1:length(empresa)) {

  #Carregando a base de dados e removendo NA's
  Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↪ Capital/V2/COTAES SOMENTE DAS EMPRESAS DO ESTUDO.xlsx")

  Dados <- subset(Dados, select = c("Data", empresa[o], "IBOV"))
```

```
qxts <- xts(Dados[,-1], order.by=Dados$Data)

qxts <- na.omit(qxts)

#Vetor de ndices que correspondentes s datas de ocorrncia dos eventos
indices_event <- lista_indices[[empresa[o]]]
indices_estimation <- c(indices_event-1)

#Listas para salvar os resultados dos clculos
resultCAR <- list()

resultSCAR <- list()

#Sero conduzidos estudos de eventos para varias janelas de
  ↪ 3,5,9,11,15,21,31 e 41 dias.
days_1 <- c(1,2,3,4,5,7,10,15,20)

days_2 <- c(1,2,3,4,5,7,10,15,20)

for (k in 1:length(days_1)) {

  days_before <- days_1[k]

  days_forward <- days_2[k]

  var_ar_list <- list()

  CAR_list <- list()

  SCAR_list <- list()

  statistic_list <- list()

  for (i in 1:length(indices_event)) {

    #Definindo as datas das janelas de eventos e de estimao
    event_start = as.character(index(qxts[indices_event[i]-days_before])
      ↪ )
```

```
event_end = as.character(index(qxts[indices_event[i]+days_forward]))

estimation_start = as.character(as.Date(index(qxts[indices_event[i]-
↳ days_before-L1])))

estimation_end = as.character(as.Date(index(qxts[indices_event[i]-
↳ days_before-1])))

model_qxts <- as.matrix(window(qxts, start = estimation_start, end =
↳ estimation_end))

beta_qxts <- window(qxts, start = estimation_start, end =
↳ estimation_end)

#Estimao do modelo BEKK e o beta variante no tempo
obj_spec <- bekk_spec()
bekk_model <- bekk_fit(obj_spec, model_qxts, QML_t_ratios = FALSE,
↳ max_iter = 50, crit = 1e-9)

beta_forecast <- predict(bekk_model, n = ((days_before*2)+1), ci =
↳ 0.50)

beta_before <- bekk_model$H_t[,2]/bekk_model$H_t[,4]

beta_predict <- beta_forecast$H_t_forecast[,2]/
↳ beta_forecast$H_t_forecast[,4]

beta <- c(beta_before, beta_predict)

event_qxts <- window(qxts, start = estimation_start, end = event_end
↳ )

#Criando as colunas com o beta e a mdia mvel
event_qxts$beta <- beta

event_qxts$ut <- mean(beta_qxts[,1])

event_qxts$AR <- event_qxts[,1]-event_qxts$ut-event_qxts$beta*
↳ event_qxts$IBOV
```

```
CAR <- sum(window(event_qxts$AR, start = event_start, end =
  ↪ event_end))

var_ar <- sd(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))^2

var_CAR <- length(window(event_qxts$AR, start = event_start, end =
  ↪ event_end))*var_ar

SCAR <- CAR/(var_CAR)^(1/2)

alpha<-0.05

df <- length(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))-2

statistic <- qt(alpha/2,df)

test <- abs(SCAR) > abs(qt(1-(alpha/2),df))

#Salvando os dados para posterior utilizao
var_ar_list[[i]] <- list(var_ar, as.character(index(qxts[
  ↪ indices_event[i]])))

CAR_list[[i]] <- list(CAR, as.character(index(qxts[indices_event[i]
  ↪ ]]))))

SCAR_list[[i]] <- list(SCAR, as.character(index(qxts[indices_event[i]
  ↪ ]]))))

statistic_list[[i]] <- list(statistic, as.character(index(qxts[
  ↪ indices_event[i]])))

cat(paste("Evento",empresa[o], "dia:", as.character(index(qxts[
  ↪ indices_event[i]])), "\n", "Janela de eventos de ", (2*days_1[k
  ↪ ])+1, "dias\n", "CAR:", CAR, "\n", "SCAR:", SCAR, "\n
  ↪ -----\n"))
```

```
}

  resultCAR[[k]] <- list(CAR_list)

  resultSCAR[[k]] <- list(SCAR_list)
}

lista_final_CAR <- list()
lista_final_SCAR <- list()

for (l in 1:length(resultCAR)) {

  valores <- c(unlist(resultCAR[[l]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("CAR", " -", l))

  lista_final_CAR[[l]] <- final
}

for (m in 1:length(resultSCAR)) {

  valores <- c(unlist(resultSCAR[[m]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("SCAR", " -", m))

  lista_final_SCAR[[m]] <- final
}
```



```
}

merged_df_CAR <- Reduce(function(x, y) merge(x, y, by = "Data do Evento
  ↪ ", all.x = TRUE), lista_final_CAR)

names(merged_df_CAR)[2:length(merged_df_CAR)] <- c("3 dias", "5 dias",
  ↪ "7 dias",
                                     "9 dias", "11 dias", "15 dias",
                                     "21 dias", "31 dias", "41 dias")

final_merged_df_CAR <- gather(merged_df_CAR, key = "Dias", value = "
  ↪ Valor CAR", -1)

merged_df_SCAR <- Reduce(function(x, y) merge(x, y, by = "Data do
  ↪ Evento", all.x = TRUE), lista_final_SCAR)

names(merged_df_SCAR)[2:length(merged_df_SCAR)] <- c("3 dias", "5 dias",
  ↪ "7 dias",
                                     "9 dias", "11 dias", "15 dias",
                                     "21 dias", "31 dias", "41 dias")

final_merged_df_SCAR <- gather(merged_df_SCAR, key = "Dias", value = "
  ↪ Valor SCAR", -1)

df_para_excel <- merge(final_merged_df_CAR, final_merged_df_SCAR, by =
  ↪ c('Data do Evento', 'Dias'))

df_para_excel$Codigo <- empresa[o]

lista_suprema[[o]] <- df_para_excel
}

resultado_supremo <- do.call(rbind, lista_suprema) #Unindo os dataframes
  ↪ com base em suas colunas
```

```
resultado_supremo$'Valor CAR' <- as.numeric(resultado_supremo$'Valor CAR
  ↪ ')

estatisticas <- resultado_supremo %>% group_by(Dias) %>% summarize(CAAR =
  ↪ mean('Valor CAR'),
  SCAAR = sqrt(var('
    ↪ Valor CAR')),
  N = length('Valor
    ↪ CAR'),
  mediana = median('
    ↪ Valor CAR'),
  maximo = max('Valor
    ↪ CAR'),
  minimo = min('Valor
    ↪ CAR'),
  positivo = length('
    ↪ Valor CAR'['
    ↪ Valor CAR'>0])
  ↪ /length('Valor
    ↪ CAR'))

estatisticas$t_stat <- (estatisticas$CAAR/estatisticas$SCAAR)*sqrt(
  ↪ estatisticas$N)

#Cria um arquivo xlsx com o dataframe dos retornos anormais acumulados da
  ↪ empresa
write.xlsx(resultado_supremo, "LISTA DE CARs e SCARs ANNCIOS DE DEBNTURES
  ↪ - BEKK.xlsx")

#View(estatisticas)

'''
```

## Estudo de eventos com modelo de mercado

```
---
title: "Estudo de Eventos MODELO DE MERCADO"
author: "Arthur de Brito Baldini"
date: "2023-03-09"
output: html_document
---

““{r setup, include=FALSE}
library(readxl)
library(xts)
library(dplyr)
library(xlsx)
library(BEKKs)
library(ggplot2)
library(tidyr)
library(purrr)

L1 <- 500

myFunction <- function(x, y) {

  if (identical(which(as.Date(x) == as.Date(y)), integer(0)) == FALSE){

    return(which(as.Date(x) == as.Date(y)))

  } else {

    return(myFunction(x,as.Date(y+1)))

  }
}

datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/
↳ V2/Base de Dados.xlsx", sheet = 4)

#datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital
↳ /V2/economica - Emisses Debntures.xlsx", sheet = 3)
```

```
empresa <- unique(datas$Cdigo)

lista_indices <- list()

for (i in 1:length(empresa)) {

  Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
  ↳ Capital/V2/COTAES SOMENTE DAS EMPRESAS DO ESTUDO.xlsx")

  Dados <- subset(Dados, select = c("Data", empresa[i], "IBOV")) #
  ↳ Selecionando somente a empresa e o ndice ded mercado

  qxts <- xts(Dados[,-1], order.by=Dados$Data) #Transformando em srie
  ↳ temporal

  qxts <- na.omit(qxts) #Omitindo NAs. Caso as NAs no sejam omitidas
  ↳ haver problemas por todas a programao

  datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
  ↳ Capital/V2/Base de Dados.xlsx", sheet = 4)

  #datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
  ↳ Capital/V2/economica - Emisses Debntures.xlsx", sheet = 3)

  datas <- datas[datas$Cdigo == empresa[i], ] #Filtrando os eventos para
  ↳ a empresa de interesse

  datas <- datas[order(datas$'Data do Evento', decreasing = TRUE),] #
  ↳ Ordenando as datas

  achar_index <- data.frame(date=index(qxts), coredata(qxts))

  vetor_indices <- c()

  for (j in 1:length(datas$'Data do Evento')) {

    d1 <- achar_index$date

    d2 <- datas$'Data do Evento'[j]
```

```
vetor_indices[j] <- myFunction(d1,d2)

}

cat(empresa[i],": ",vetor_indices,"\n-----\n")

lista_indices[[i]] <- vetor_indices

}

names(lista_indices) <- empresa

lista_indices <- lapply(lista_indices, unique)

lista_indices <- lapply(lista_indices, function(x) x[x > L1])

lista_indices <- Filter(function(x) !is.null(x) && length(x) > 0,
  ↪ lista_indices)

empresa <- NULL

empresa <- names(lista_indices)

rm(achar_index, Dados, datas, qxts, i, j, vetor_indices, d1, d2)

#Desabilitando a notao cienttifica
options(scipen=999)

lista_suprema <- list()

for (o in 1:length(empresa)) {

  #Carregando a base de dados e removendo NA's
  Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↪ Capital/V2/COTAES SOMENTE DAS EMPRESAS DO ESTUDO.xlsx")

  Dados <- subset(Dados, select = c("Data", empresa[o], "IBOV"))
```

```
qxts <- xts(Dados[,-1], order.by=Dados$Data)

qxts <- na.omit(qxts)

#Vetor de ndices que correspondentes s datas de ocorrncia dos eventos
indices_event <- lista_indices[[empresa[o]]]
indices_estimation <- c(indices_event-1)

#Listas para salvar os resultados dos clculos
resultCAR <- list()

resultSCAR <- list()

#Sero conduzidos estudos de eventos para varias janelas de
  ↪ 3,5,9,11,15,21,31 e 41 dias.
days_1 <- c(1,2,3,4,5,7,10,15,20)

days_2 <- c(1,2,3,4,5,7,10,15,20)

for (k in 1:length(days_1)) {

  days_before <- days_1[k]

  days_forward <- days_2[k]

  var_ar_list <- list()

  CAR_list <- list()

  SCAR_list <- list()

  statistic_list <- list()

  for (i in 1:length(indices_event)) {

    #Definindo as datas das janelas de eventos e de estimao
    event_start = as.character(index(qxts[indices_event[i]-days_before])
      ↪ )
```

```
event_end = as.character(index(qxts[indices_event[i]+days_forward]))

estimation_start = as.character(as.Date(index(qxts[indices_event[i]-
↳ days_before-L1])))

estimation_end = as.character(as.Date(index(qxts[indices_event[i]-
↳ days_before-1])))

model_qxts <- window(qxts, start = estimation_start, end =
↳ estimation_end)

#Estimao do modelo de mercado

market_model <- lm(model_qxts[,1]~model_qxts[,2], data = model_qxts)

event_qxts <- window(qxts, start = estimation_start, end = event_end
↳ )

event_qxts$AR <- event_qxts[,1]-market_model$coefficients[1]-
↳ market_model$coefficients[2]*event_qxts$IBOV

CAR <- sum(window(event_qxts$AR, start = event_start, end =
↳ event_end))

var_ar <- sd(window(event_qxts$AR, start = estimation_start, end =
↳ estimation_end))^2

var_CAR <- length(window(event_qxts$AR, start = event_start, end =
↳ event_end))*var_ar

SCAR <- CAR/(var_CAR)^(1/2)

alpha<-0.05

df <- length(window(event_qxts$AR, start = estimation_start, end =
↳ estimation_end))-2

statistic <- qt(alpha/2,df)
```

```
test <- abs(SCAR) > abs(qt(1-(alpha/2),df))

#Salvando os dados para posterior utilizao
var_ar_list[[i]] <- list(var_ar, as.character(index(qxts[
  ↪ indices_event[i]])))

CAR_list[[i]] <- list(CAR, as.character(index(qxts[indices_event[i]
  ↪ ]])))

SCAR_list[[i]] <- list(SCAR, as.character(index(qxts[indices_event[i]
  ↪ ])))

statistic_list[[i]] <- list(statistic, as.character(index(qxts[
  ↪ indices_event[i]])))

cat(paste("Evento", empresa[o],"dia:", as.character(index(qxts[
  ↪ indices_event[i]])),"\n", "Janela de eventos de ",(2*days_1[k
  ↪ ])+1, "dias\n", "CAR:", CAR, "\n", "SCAR:", SCAR,"\n
  ↪ -----\n"))

}

resultCAR[[k]] <- list(CAR_list)

resultSCAR[[k]] <- list(SCAR_list)
}

lista_final_CAR <- list()
lista_final_SCAR <- list()

for (l in 1:length(resultCAR)) {

  valores <- c(unlist(resultCAR[[l]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)
```





```

"21 dias", "31 dias", "41 dias")

final_merged_df_SCAR <- gather(merged_df_SCAR, key = "Dias", value = "
  ↳ Valor SCAR", -1)

df_para_excel <- merge(final_merged_df_CAR, final_merged_df_SCAR, by =
  ↳ c('Data do Evento', 'Dias'))

df_para_excel$Cdigo <- empresa[o]

lista_suprema[[o]] <- df_para_excel
}

resultado_supremo <- do.call(rbind, lista_suprema) #Unindo os dataframes
  ↳ com base em suas colunas

resultado_supremo$'Valor CAR' <- as.numeric(resultado_supremo$'Valor CAR
  ↳ ')

estatisticas1 <- resultado_supremo %>% group_by(Dias) %>% summarize(CAAR
  ↳ = mean('Valor CAR'),
                                                                    SCAAR = sqrt(var('
  ↳ Valor CAR')),
  N = length('Valor
  ↳ CAR'),
  mediana = median('
  ↳ Valor CAR'),
  maximo = max('Valor
  ↳ CAR'),
  minimo = min('Valor
  ↳ CAR'),
  positivo = length('
  ↳ Valor CAR'['
  ↳ Valor CAR'>0])
  ↳ /length('Valor
  ↳ CAR'))

```

```
estatisticas1$t_stat <- (estatisticas1$CAAR/estatisticas1$SCAAR)*sqrt(
  ↪ estatisticas1$N)

#setwd("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/V2")

#Cria um arquivo xlsx com o dataframe dos retornos anormais acumulados da
  ↪ empresa
#write.xlsx(resultado_supremo, paste("LISTA DE CARs e SCARs ANNCIOS DE
  ↪ DEBNTURES - Modelo de Mercado (SIMTRICA).xlsx"))

View(estatisticas1)

'''
```

## Estudo de eventos com modelo de mercado GARCH

```
---
title: "Estudo de Eventos GARCH corrected Market Model"
author: "Arthur de Brito Baldini"
date: "2023-03-23"
output: html_document
---

''#{r setup, include=FALSE}
library(readxl)
library(xts)
library(dplyr)
library(xlsx)
library(BEKKs)
library(ggplot2)
library(tidyr)
library(purrr)
library(rugarch)
```

```
L1 <- 500

myFunction <- function(x, y) {

  if (identical(which(as.Date(x) == as.Date(y)), integer(0)) == FALSE){

    return(which(as.Date(x) == as.Date(y)))

  } else {

    return(myFunction(x,as.Date(y+1)))

  }
}

datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/
↳ V2/Base de Dados.xlsx", sheet = 4)

#datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital
↳ /V2/economica - Emisses Debntures.xlsx", sheet = 3)

empresa <- unique(datas$Cdigo)

lista_indices <- list()

for (i in 1:length(empresa)) {

  Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
↳ Capital/V2/COTAES SOMENTE DAS EMPRESAS DO ESTUDO.xlsx")

  Dados <- subset(Dados, select = c("Data", empresa[i], "IBOV")) #
↳ Selecionando somente a empresa e o ndice ded mercado

  qxts <- xts(Dados[,-1], order.by=Dados$Data) #Transformando em srie
↳ temporal

  qxts <- na.omit(qxts) #Omitindo NAs. Caso as NAs no sejam omitidas
↳ haver problemas por todas a programao
```

```
datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
  ↳ Capital/V2/Base de Dados.xlsx", sheet = 4)

#datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
  ↳ Capital/V2/economica - Emissões Debntures.xlsx", sheet = 3)

datas <- datas[datas$Cdigo == empresa[i], ] #Filtrando os eventos para
  ↳ a empresa de interesse

datas <- datas[order(datas$'Data do Evento', decreasing = TRUE),] #
  ↳ Ordenando as datas

achar_index <- data.frame(date=index(qxts), coredata(qxts))

vetor_indices <- c()

for (j in 1:length(datas$'Data do Evento')) {

  d1 <- achar_index$date

  d2 <- datas$'Data do Evento'[j]

  vetor_indices[j] <- myFunction(d1,d2)

}

cat(empresa[i],": ",vetor_indices,"\n-----\n")

lista_indices[[i]] <- vetor_indices

}

names(lista_indices) <- empresa

lista_indices <- lapply(lista_indices, unique)

lista_indices <- lapply(lista_indices, function(x) x[x > L1])
```

```
lista_indices <- Filter(function(x) !is.null(x) && length(x) > 0,
  ↪ lista_indices)

empresa <- NULL

empresa <- names(lista_indices)

rm(achar_index, Dados, datas, qxts, i, j, vetor_indices, d1, d2)

#Desabilitando a notao cienttifica
options(scipen=999)

lista_suprema <- list()

for (o in 1:length(empresa)) {

  #Carregando a base de dados e removendo NA's
  Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de
    ↪ Capital/V2/COTAES SOMENTE DAS EMPRESAS DO ESTUDO.xlsx")

  Dados <- subset(Dados, select = c("Data", empresa[o], "IBOV"))

  qxts <- xts(Dados[,-1], order.by=Dados$Data)

  qxts <- na.omit(qxts)

  #Vetor de ndices que correspondentes s datas de ocorrncia dos eventos
  indices_event <- lista_indices[[empresa[o]]]
  indices_estimation <- c(indices_event-1)

  #Listas para salvar os resultados dos clculos
  resultCAR <- list()

  resultSCAR <- list()

  #Sero conduzidos estudos de eventos para varias janelas de
    ↪ 3,5,9,11,15,21,31 e 41 dias.
  days_1 <- c(1,2,3,4,5,7,10,15,20)
```

```
days_2 <- c(1,2,3,4,5,7,10,15,20)

for (k in 1:length(days_1)) {

  days_before <- days_1[k]

  days_forward <- days_2[k]

  var_ar_list <- list()

  CAR_list <- list()

  SCAR_list <- list()

  statistic_list <- list()

  for (i in 1:length(indices_event)) {

    #Definindo as datas das janelas de eventos e de estimao
    event_start = as.character(index(qxts[indices_event[i]-days_before])
    ↪ )

    event_end = as.character(index(qxts[indices_event[i]+days_forward]))

    estimation_start = as.character(as.Date(index(qxts[indices_event[i]-
    ↪ days_before-L1])))

    estimation_end = as.character(as.Date(index(qxts[indices_event[i]-
    ↪ days_before-1])))

    model_qxts <- window(qxts, start = estimation_start, end =
    ↪ estimation_end)

    #Estimao do modelo de mercado

    spec <- ugarchspec(variance.model =
    list(model = "sGARCH", garchOrder = c(1, 1),
    submodel = NULL, external.regressors = NULL, variance.targeting =
    ↪ FALSE),
```

```

mean.model = list(armaOrder = c(0, 0), external.regressors =
  ↪ model_qxts[,2],
distribution.model = "norm", start.pars = list(), fixed.pars =
  ↪ list()))

market_garch <- ugarchfit(spec = spec, data = model_qxts[,2], solver
  ↪ = 'hybrid')

event_qxts <- window(qxts, start = estimation_start, end = event_end
  ↪ )

event_qxts$AR <- event_qxts[,1]-market_garch@fit$coef[1]-
  ↪ market_garch@fit$coef[2]*event_qxts$IBOV

CAR <- sum(window(event_qxts$AR, start = event_start, end =
  ↪ event_end))

var_ar <- sd(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))^2

var_CAR <- length(window(event_qxts$AR, start = event_start, end =
  ↪ event_end))*var_ar

SCAR <- CAR/(var_CAR)^(1/2)

alpha<-0.05

df <- length(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))-2

statistic <- qt(alpha/2,df)

test <- abs(SCAR) > abs(qt(1-(alpha/2),df))

#Salvando os dados para posterior utilizao
var_ar_list[[i]] <- list(var_ar, as.character(index(qxts[
  ↪ indices_event[i]])))

CAR_list[[i]] <- list(CAR, as.character(index(qxts[indices_event[i]

```



```
    ↪ ]]))))

    SCAR_list[[i]] <- list(SCAR, as.character(index(qxts[indices_event[i]
    ↪ ]]))))

    statistic_list[[i]] <- list(statistic, as.character(index(qxts[
    ↪ indices_event[i]])))

    cat(paste("Evento", empresa[o],"dia:", as.character(index(qxts[
    ↪ indices_event[i]])),"\n", "Janela de eventos de ",(2*days_1[k
    ↪ ])+1, "dias\n", "CAR:", CAR, "\n","SCAR:", SCAR,"\n
    ↪ -----\n"))

  }

  resultCAR[[k]] <- list(CAR_list)

  resultSCAR[[k]] <- list(SCAR_list)
}

lista_final_CAR <- list()
lista_final_SCAR <- list()

for (l in 1:length(resultCAR)) {

  valores <- c(unlist(resultCAR[[l]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("CAR",l))

  lista_final_CAR[[l]] <- final
}
```

```
for (m in 1:length(resultSCAR)) {

  valores <- c(unlist(resultSCAR[[m]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("SCAR",m))

  lista_final_SCAR[[m]] <- final
}

merged_df_CAR <- Reduce(function(x, y) merge(x, y, by = "Data do Evento
  ↪ ", all.x = TRUE), lista_final_CAR)

names(merged_df_CAR)[2:length(merged_df_CAR)] <- c("3 dias", "5 dias",
  ↪ "7 dias",
                                     "9 dias", "11 dias", "15 dias",
                                     "21 dias", "31 dias", "41 dias")

final_merged_df_CAR <- gather(merged_df_CAR, key = "Dias", value = "
  ↪ Valor CAR", -1)

merged_df_SCAR <- Reduce(function(x, y) merge(x, y, by = "Data do
  ↪ Evento", all.x = TRUE), lista_final_SCAR)

names(merged_df_SCAR)[2:length(merged_df_SCAR)] <- c("3 dias", "5 dias",
  ↪ "7 dias",
                                     "9 dias", "11 dias", "15 dias",
                                     "21 dias", "31 dias", "41 dias")

final_merged_df_SCAR <- gather(merged_df_SCAR, key = "Dias", value = "
  ↪ Valor SCAR", -1)
```

```
df_para_excel <- merge(final_merged_df_CAR, final_merged_df_SCAR, by =
  ↪ c('Data do Evento', 'Dias'))

df_para_excel$Cdigo <- empresa[o]

lista_suprema[[o]] <- df_para_excel
}

resultado_supremo <- do.call(rbind, lista_suprema) #Unindo os dataframes
  ↪ com base em suas colunas

resultado_supremo$'Valor CAR' <- as.numeric(resultado_supremo$'Valor CAR
  ↪ ')

estatisticas1 <- resultado_supremo %>% group_by(Dias) %>% summarize(CAAR
  ↪ = mean('Valor CAR'),
                                                                    SCAAR = sqrt(var('
  ↪ Valor CAR')),
  N = length('Valor
  ↪ CAR'),
  mediana = median('
  ↪ Valor CAR'),
  maximo = max('Valor
  ↪ CAR'),
  minimo = min('Valor
  ↪ CAR'),
  positivo = length('
  ↪ Valor CAR' ['
  ↪ Valor CAR'>0])
  ↪ /length('Valor
  ↪ CAR'))

estatisticas1$t_stat <- (estatisticas1$CAAR/estatisticas1$SCAAR)*sqrt(
  ↪ estatisticas1$N)

#setwd("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/V2")
```

```
#Cria um arquivo xlsx com o dataframe dos retornos anormais acumulados da
  ↳ empresa
#write.xlsx(resultado_supremo, paste("LISTA DE CARs e SCARs ANNCIOS DE
  ↳ DEBNTURES - Modelo de Mercado (SIMTRICA).xlsx"))

View(estatisticas1)

'''
```

### Regressões lineares

```
library(readxl)
library(dplyr)
library(lmtest)
library(sandwich)

options(scipen=999)

rm(a, b, Dados, datas, df, df1, lmfit)

Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/
  ↳ V2/TABELA PARA REGRESSAO - BEKK.xlsx", sheet = 2)

datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/
  ↳ V2/Base de Dados.xlsx", sheet = 4)

df1 <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/V2
  ↳ /TABELA PARA REGRESSAO - BEKK.xlsx", sheet = 4)

a <- unique(datas[,c("Codigo", "Setor")])

b <- df1[,c("Data do Evento", "Codigo", "Idade")]

df <- merge(Dados, a, by = "Codigo")
```

```
df <- merge(df, b, by = c("Data do Evento", "Codigo"))

df <- subset(df, Dias == '15 dias')

df$'Divida Total Bruta' <- (df$'Divida Total Bruta'/df$'Ativo Total')

df$'Fluxo de Caixa Livre' <- (df$'Fluxo de Caixa Livre'/df$'Ativo Total')

df$Montante <- df$Montante/(df$'Ativo Total'*1000)

df$ROA <- df$ROA/100

df$ROE <- df$ROE/100

df$Capex <- (df$Capex/df$'Ativo Total')

df$'Ativo Total' <- log(df$'Ativo Total')

rm(a, b, Dados, datas, df1)

IDA <- read_excel("C:/Users/Arthur/Desktop/Artigo Estrutura de Capital/V2
  ↪ /IDA.xlsx")

colnames(IDA)[colnames(IDA) == "Data de Referencia"] = "Data do Evento"

df <- merge(IDA, df)

df$'Variacao Diaria (%)' <- df$'Variacao Diaria (%)'/100

df$'Variacao no Mes (%)' <- df$'Variacao no Mes (%)'/100

df$'Variacao 12 Meses (%)' <- df$'Variacao 12 Meses (%)'/100

lmfit <- lm(df$'Valor CAR' ~ df$'Ativo Total' + df$Montante + df$ROE +
  ↪ df$'Divida Total Bruta' + df$'Fluxo de Caixa Livre' +
  df$'Liquidez Corrente' + df$'Variacao 12 Meses (%)' + factor(
  ↪ df$Setor), data = df)
```

```
summary(lmfit)
```

```
coeftest(lmfit, vcov = vcovHC(lmfit, type = 'HCO'))
```

# APÊNDICE C – Apêndice C - Códigos utilizados no artigo 2

## Estudos de eventos calculados

```
---  
title: "Estudo de Eventos FOMC"  
author: "Arthur de Brito Baldini"  
date: "2023-04-13"  
output: html_document  
---  
  
MODELO DE MERCADO  
  
““{r setup, include=FALSE}  
library(readxl)  
library(xts)  
library(dplyr)  
library(xlsx)  
library(ggplot2)  
library(tidyr)  
library(purrr)  
  
options(scipen=999)  
  
BR_INDEX <- "BVSP-BRL"  
  
#Janela de estimao  
L1 <- 500  
  
myFunction <- function(x, y) {  
  
  if (identical(which(as.Date(x) == as.Date(y)), integer(0)) == FALSE){  
  
    return(which(as.Date(x) == as.Date(y)))  
  
  } else {
```

```
    return(myFunction(x,as.Date(y)+1))
  }
}

BVSP_USD <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/BVSP-
  ↳ USD.xlsx", sheet = 2, guess_max = 1000000)

BVSP_USD <- subset(BVSP_USD, select = c("Data", "BVSP-USD"))

BVSP_USD <- subset(BVSP_USD, BVSP_USD$Data > "2008-12-31" & BVSP_USD$Data
  ↳ < "2023-01-01")

BVSP_USD <- na.omit(BVSP_USD)

Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Dados
  ↳ Arthur.xlsx", sheet = 1, guess_max = 1000000)

Dados <- na.omit(Dados)

Dados <- subset(Dados, Dados$Data > "2008-12-31" & Dados$Data <
  ↳ "2023-01-01")

Dados <- merge(Dados, BVSP_USD, by = "Data")

qxts <- xts(Dados[,-1], order.by=Dados$Data)

qxts <- diff(log(qxts))

qxts <- na.omit(qxts)

datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Datas
  ↳ dos Eventos.xlsx", sheet = 3)

datas <- as.Date(datas$Date)

achar_index <- data.frame(date=index(qxts), coredata(qxts))
```



```
vetor_indices <- c()

for (j in 1:length(datas)) {

  d1 <- achar_index$date

  d2 <- datas[j]

  vetor_indices[j] <- myFunction(d1,d2)

  print(d2)

}

rm(achar_index, Dados, datas, qxts, j, d1, d2)

BVSP_USD <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/BVSP-
  ↳ USD.xlsx", sheet = 2, guess_max = 1000000)

BVSP_USD <- subset(BVSP_USD, select = c("Data", "BVSP-USD"))

BVSP_USD <- subset(BVSP_USD, BVSP_USD$Data > "2008-12-31" & BVSP_USD$Data
  ↳ < "2023-01-01")

BVSP_USD <- na.omit(BVSP_USD)

Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Dados
  ↳ Arthur.xlsx", sheet = 1, guess_max = 1000000)

Dados <- na.omit(Dados)

Dados <- subset(Dados, Dados$Data > "2008-12-31" & Dados$Data <
  ↳ "2023-01-01")

Dados <- merge(Dados, BVSP_USD, by = "Data")

qxts <- xts(Dados[, -1], order.by=Dados$Data)
```

```
qxts <- diff(log(qxts))

qxts <- na.omit(qxts)

qxts <- subset(qxts, select = c(BR_INDEX, "S&P500"))

#Vetor de ndices que correspondentes s datas de ocorrncia dos eventos
indices_event <- vetor_indices
indices_estimation <- c(indices_event-1)

#Sero conduzidos estudos de eventos para varias janelas de
  ↪ 3,5,9,11,15,21,31 e 41 dias.

days_1 <- c(3,2,1)

days_2 <- c(0,0,0)

resultCAR <- list()

resultSCAR <- list()

for (k in 1:length(days_1)) {

  days_before <- days_1[k]

  days_forward <- days_2[k]

  var_ar_list <- list()

  CAR_list <- list()

  SCAR_list <- list()

  statistic_list <- list()

  for (i in 1:length(indices_event)) {

    #Definindo as datas das janelas de eventos e de estimao
    event_start = as.character(index(qxts[indices_event[i]-days_before]))
```

```
event_end = as.character(index(qxts[indices_event[i]+days_forward]))

estimation_start = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-L1])))

estimation_end = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-1])))

model_qxts <- window(qxts, start = estimation_start, end =
  ↪ estimation_end)

#Estimao do modelo de mercado

market_model <- lm(model_qxts[,1]~model_qxts[,2], data = model_qxts)

market_model

event_qxts <- window(qxts, start = estimation_start, end = event_end
  ↪ )

event_qxts$AR <- event_qxts[,1]-market_model$coefficients[1]-
  ↪ market_model$coefficients[2]*event_qxts[,2]

CAR <- sum(window(event_qxts$AR, start = event_start, end =
  ↪ event_end))

var_ar <- sd(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))^2

var_CAR <- length(window(event_qxts$AR, start = event_start, end =
  ↪ event_end))*var_ar

SCAR <- CAR/(var_CAR)^(1/2)

alpha<-0.05

df <- length(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))-2
```

```

    statistic <- qt(alpha/2,df)

    test <- abs(SCAR) > abs(qt(1-(alpha/2),df))

#Salvando os dados para posterior utilizao
var_ar_list[[i]] <- list(var_ar, as.character(index(qxts[indices_event
  ↪ [i]])))

CAR_list[[i]] <- list(CAR, as.character(index(qxts[indices_event[i]]))
  ↪ )

SCAR_list[[i]] <- list(SCAR, as.character(index(qxts[indices_event[i]
  ↪ ]]))))

statistic_list[[i]] <- list(statistic, as.character(index(qxts[
  ↪ indices_event[i]])))

if (days_before == days_forward) {

    cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[
  ↪ i]])), "\n", "Janela de eventos de ", (2*days_1[k])+1, "dias
  ↪ .", "Loop", i, "\n", "CAR:", CAR, "\n", "SCAR:", SCAR, "\n
  ↪ -----\n"))

} else if ((days_forward - days_before) < 0) {

    cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[i]
  ↪ ]])), "\n", "Janela de eventos de (-", (days_1[k]), ", 0)", "
  ↪ dias.", "Loop", i, "\n", "CAR:", CAR, "\n", "SCAR:", SCAR, "\n
  ↪ -----\n"))

} else {

    cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[
  ↪ i]])), "\n", "Janela de eventos de (0,", (days_2[k]), ")", "
  ↪ dias.", "Loop", i, "\n", CAR, "\n", "SCAR:", SCAR, "\n
  ↪ -----\n"))

}

```

```
}

resultCAR[[k]] <- list(CAR_list)

resultSCAR[[k]] <- list(SCAR_list)

}

lista_final_CAR <- list()
lista_final_SCAR <- list()

for (l in 1:length(resultCAR)) {

  valores <- c(unlist(resultCAR[[l]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("CAR",l))

  lista_final_CAR[[l]] <- final

}

for (m in 1:length(resultSCAR)) {

  valores <- c(unlist(resultSCAR[[m]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("SCAR",m))

}
```

```
lista_final_SCAR[[m]] <- final

}

merged_df_CAR <- Reduce(function(x, y) merge(x, y, by = "Data do Evento",
  ↪ all.x = TRUE), lista_final_CAR)

names(merged_df_CAR)[2:length(merged_df_CAR)] <- c("-1 dias", "3 dias",
  ↪ "+1 dias")

final_merged_df_CAR <- gather(merged_df_CAR, key = "Dias", value = "Valor
  ↪ CAR", -1)

merged_df_SCAR <- Reduce(function(x, y) merge(x, y, by = "Data do Evento",
  ↪ all.x = TRUE), lista_final_SCAR)

names(merged_df_SCAR)[2:length(merged_df_SCAR)] <- c("-1 dias", "3 dias",
  ↪ "+1 dias")

final_merged_df_SCAR <- gather(merged_df_SCAR, key = "Dias", value = "
  ↪ Valor SCAR", -1)

df_para_excel <- merge(final_merged_df_CAR, final_merged_df_SCAR, by = c('
  ↪ Data do Evento', 'Dias'))

df_para_excel$'Valor SCAR' <- as.numeric(df_para_excel$'Valor SCAR')

df_para_excel$'Valor CAR' <- as.numeric(df_para_excel$'Valor CAR')

estatisticas <- df_para_excel %>% group_by(Dias) %>% summarize(CAAR =
  ↪ mean(as.numeric('Valor CAR')),
  SCAAR = sqrt(var(as.
  ↪ numeric('Valor
  ↪ CAR'))),
  N = length('Valor
  ↪ CAR'),
  mediana = median(as.
  ↪ numeric('Valor
```

```

        ↪ CAR')),
maximo = max(as.
        ↪ numeric('Valor
        ↪ CAR')),
minimo = min(as.
        ↪ numeric('Valor
        ↪ CAR'))

estatisticas$CV <- (estatisticas$SCAAR)/estatisticas$CAAR

estatisticas$t_stat <- (estatisticas$CAAR/estatisticas$SCAAR)*sqrt(
  ↪ estatisticas$N)

eventos_significantes <- sum(iffelse(abs(df_para_excel$'Valor SCAR') >
  ↪ 1.96, 1, 0))

print(eventos_significantes)

View(estatisticas)

rm(list=ls()[! ls() %in% c("df_para_excel", "estatisticas")])

View(subset(df_para_excel, Dias == "-1 dias" & abs('Valor SCAR') > 1.96))

View(subset(df_para_excel, Dias == "3 dias" & abs('Valor SCAR') > 1.96))

View(subset(df_para_excel, Dias == "+1 dias" & abs('Valor SCAR') > 1.96))

'''

MODELO BEKK

'''{r setup, include=FALSE}
library(readxl)
library(xts)
library(dplyr)
library(xlsx)
library(BEKKs)
library(ggplot2)

```

```
library(tidyr)
library(purrr)

options(scipen=999)

BR_INDEX <- "BVSP-BRL"

#Janela de estimao
L1 <- 500

myFunction <- function(x, y) {

  if (identical(which(as.Date(x) == as.Date(y)), integer(0)) == FALSE){

    return(which(as.Date(x) == as.Date(y)))

  } else {

    return(myFunction(x,as.Date(y)+1))

  }
}

BVSP_USD <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/BVSP-
↳ USD.xlsx", sheet = 2, guess_max = 1000000)

BVSP_USD <- subset(BVSP_USD, select = c("Data", "BVSP-USD"))

BVSP_USD <- subset(BVSP_USD, BVSP_USD$Data > "2008-12-31" & BVSP_USD$Data
↳ < "2023-01-01")

BVSP_USD <- na.omit(BVSP_USD)

Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Dados
↳ Arthur.xlsx", sheet = 1, guess_max = 1000000)

Dados <- na.omit(Dados)

Dados <- subset(Dados, Dados$Data > "2008-12-31" & Dados$Data <
```



```
    ↪ "2023-01-01")

Dados <- merge(Dados, BVSP_USD, by = "Data")

qxts <- xts(Dados[,-1], order.by=Dados$Data)

qxts <- diff(log(qxts))

qxts <- na.omit(qxts)

datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Datas
    ↪ dos Eventos.xlsx", sheet = 3)

datas <- as.Date(datas$Date)

achar_index <- data.frame(date=index(qxts), coredata(qxts))

vetor_indices <- c()

for (j in 1:length(datas)) {

  d1 <- achar_index$date

  d2 <- datas[j]

  vetor_indices[j] <- myFunction(d1,d2)

  print(d2)

}

rm(achar_index, Dados, datas, qxts, j, d1, d2)

BVSP_USD <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/BVSP-
    ↪ USD.xlsx", sheet = 2, guess_max = 1000000)

BVSP_USD <- subset(BVSP_USD, select = c("Data", "BVSP-USD"))
```

```
BVSP_USD <- subset(BVSP_USD, BVSP_USD$Data > "2008-12-31" & BVSP_USD$Data
  ↪ < "2023-01-01")

BVSP_USD <- na.omit(BVSP_USD)

Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Dados
  ↪ Arthur.xlsx", sheet = 1, guess_max = 1000000)

Dados <- na.omit(Dados)

Dados <- subset(Dados, Dados$Data > "2008-12-31" & Dados$Data <
  ↪ "2023-01-01")

Dados <- merge(Dados, BVSP_USD, by = "Data")

qxts <- xts(Dados[,-1], order.by=Dados$Data)

qxts <- diff(log(qxts))

qxts <- na.omit(qxts)

qxts <- subset(qxts, select = c(BR_INDEX, "S&P500"))

#Vetor de ndices que correspondentes s datas de ocorrncia dos eventos
indices_event <- vetor_indices
indices_estimation <- c(indices_event-1)

#Sero conduzidos estudos de eventos para vrias janelas de
  ↪ 3,5,9,11,15,21,31 e 41 dias.

days_1 <- c(3,2,1)

days_2 <- c(0,0,0)

resultCAR <- list()

resultSCAR <- list()

for (k in 1:length(days_1)) {
```

```
days_before <- days_1[k]

days_forward <- days_2[k]

var_ar_list <- list()

CAR_list <- list()

SCAR_list <- list()

statistic_list <- list()

for (i in 1:length(indices_event)) {

  #Definindo as datas das janelas de eventos e de estimao
  event_start = as.character(index(qxts[indices_event[i]-days_before]))

  event_end = as.character(index(qxts[indices_event[i]+days_forward]))

  estimation_start = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-L1])))

  estimation_end = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-1])))

  model_qxts <- as.matrix(window(qxts, start = estimation_start, end =
  ↪ estimation_end))

  beta_qxts <- window(qxts, start = estimation_start, end =
  ↪ estimation_end)

  #Estimao do modelo BEKK e o beta variante no tempo
  obj_spec <- bekk_spec()
  bekk_model <- bekk_fit(obj_spec, model_qxts, QML_t_ratios = FALSE,
  ↪ max_iter = 50, crit = 1e-9)

  if (days_before == days_forward) {
```

```
beta_forecast <- predict(bekk_model, n = ((days_before*2)+1), ci =
  ↪ 0.50)

print("simtrica")

} else if ((days_forward - days_before) < 0) {

beta_forecast <- predict(bekk_model, n = ((days_before)+1), ci =
  ↪ 0.50)

print("assimtrica negativa")

} else {

beta_forecast <- predict(bekk_model, n = ((days_forward)+1), ci =
  ↪ 0.50)

print("assimtrica positiva")
}

beta_before <- bekk_model$H_t[,2]/bekk_model$H_t[,4]

beta_predict <- beta_forecast$H_t_forecast[,2]/
  ↪ beta_forecast$H_t_forecast[,4]

beta <- c(beta_before, beta_predict)

event_qxts <- window(qxts, start = estimation_start, end = event_end)

#Criando as colunas com o beta e a mdia mvel
event_qxts$beta <- beta

event_qxts$ut <- mean(beta_qxts[,1])

event_qxts$AR <- event_qxts[,1]-event_qxts$ut-event_qxts$beta*
  ↪ event_qxts[,2]

CAR <- sum(window(event_qxts$AR, start = event_start, end = event_end)
  ↪ )
```

```

var_ar <- sd(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))^2

var_CAR <- length(window(event_qxts$AR, start = event_start, end =
  ↪ event_end))*var_ar

SCAR <- CAR/(var_CAR)^(1/2)

alpha<-0.05

df <- length(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))-2

statistic <- qt(alpha/2,df)

test <- abs(SCAR) > abs(qt(1-(alpha/2),df))

#Salvando os dados para posterior utilizao
var_ar_list[[i]] <- list(var_ar, as.character(index(qxts[indices_event
  ↪ [i]])))

CAR_list[[i]] <- list(CAR, as.character(index(qxts[indices_event[i]]))
  ↪ )

SCAR_list[[i]] <- list(SCAR, as.character(index(qxts[indices_event[i]
  ↪ ])))

statistic_list[[i]] <- list(statistic, as.character(index(qxts[
  ↪ indices_event[i]])))

if (days_before == days_forward) {

  cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[
    ↪ i]])), "\n", "Janela de eventos de ", (2*days_1[k])+1, "dias\n
    ↪ ", "CAR:", CAR, "\n", "SCAR:", SCAR, "\n
    ↪ -----\n"))

} else if ((days_forward - days_before) < 0) {

```

```

    cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[i
    ↪ ]]))),"\n", "Janela de eventos de (-",(days_1[k]), ",0)", "
    ↪ dias\n", "CAR:", CAR, "\n","SCAR:", SCAR,"\n
    ↪ -----\n"))

} else {

    cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[
    ↪ i]]))),"\n", "Janela de eventos de (0,", (days_2[k]), ")", "
    ↪ dias\n", "CAR:", CAR, "\n","SCAR:", SCAR,"\n
    ↪ -----\n"))

}

}

resultCAR[[k]] <- list(CAR_list)

resultSCAR[[k]] <- list(SCAR_list)

}

lista_final_CAR <- list()
lista_final_SCAR <- list()

for (l in 1:length(resultCAR)) {

    valores <- c(unlist(resultCAR[[l]]))

    numbers <- valores[seq(1, length(valores), 2)]
    dates <- as.Date(valores[seq(2, length(valores), 2)])

    final <- data.frame(data = dates, x = numbers)

    names(final) <- c("Data do Evento", paste("CAR",l))

    lista_final_CAR[[l]] <- final

```

```
}

for (m in 1:length(resultSCAR)) {

  valores <- c(unlist(resultSCAR[[m]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("SCAR",m))

  lista_final_SCAR[[m]] <- final
}

merged_df_CAR <- Reduce(function(x, y) merge(x, y, by = "Data do Evento",
  ↪ all.x = TRUE), lista_final_CAR)

names(merged_df_CAR)[2:length(merged_df_CAR)] <- c("-1 dias", "3 dias",
  ↪ "+1 dias")

final_merged_df_CAR <- gather(merged_df_CAR, key = "Dias", value = "Valor
  ↪ CAR", -1)

merged_df_SCAR <- Reduce(function(x, y) merge(x, y, by = "Data do Evento",
  ↪ all.x = TRUE), lista_final_SCAR)

names(merged_df_SCAR)[2:length(merged_df_SCAR)] <- c("-1 dias", "3 dias",
  ↪ "+1 dias")

final_merged_df_SCAR <- gather(merged_df_SCAR, key = "Dias", value = "
  ↪ Valor SCAR", -1)

df_para_excel <- merge(final_merged_df_CAR, final_merged_df_SCAR, by = c('
  ↪ Data do Evento', 'Dias'))
```

```
df_para_excel$'Valor SCAR' <- as.numeric(df_para_excel$'Valor SCAR')

df_para_excel$'Valor CAR' <- as.numeric(df_para_excel$'Valor CAR')

estatisticas <- df_para_excel %>% group_by(Dias) %>% summarize(CAAR =
  ↪ mean(as.numeric('Valor CAR')),
  SCAAR = sqrt(var(as.
    ↪ numeric('Valor
    ↪ CAR'))),
  N = length('Valor
    ↪ CAR'),
  mediana = median(as.
    ↪ numeric('Valor
    ↪ CAR')),
  maximo = max(as.
    ↪ numeric('Valor
    ↪ CAR')),
  minimo = min(as.
    ↪ numeric('Valor
    ↪ CAR')),
  positivo = length('
    ↪ Valor CAR'[as.
    ↪ numeric('Valor
    ↪ CAR')>0])/
    ↪ length('Valor
    ↪ CAR'))

estatisticas$CV <- (estatisticas$SCAAR)/estatisticas$CAAR

estatisticas$t_stat <- (estatisticas$CAAR/estatisticas$SCAAR)*sqrt(
  ↪ estatisticas$N)

eventos_significantes <- sum(ifelse(abs(df_para_excel$'Valor SCAR') >
  ↪ 1.96, 1, 0))

print(eventos_significantes)

View(estatisticas)
```



```
rm(list=ls()[! ls() %in% c("df_para_excel", "estatisticas")])

View(subset(df_para_excel, Dias == "-1 dias" & abs('Valor SCAR') > 1.96))

View(subset(df_para_excel, Dias == "3 dias" & abs('Valor SCAR') > 1.96))

View(subset(df_para_excel, Dias == "+1 dias" & abs('Valor SCAR') > 1.96))

'''

MODELO DCC

'''{r setup, include=FALSE}
library(readxl)
library(xts)
library(dplyr)
library(xlsx)
library(ggplot2)
library(tidyr)
library(purrr)
library(rmgarch)

options(scipen=999)

BR_INDEX <- "BVSP-BRL"

#Janela de estimao
L1 <- 500

myFunction <- function(x, y) {

  if (identical(which(as.Date(x) == as.Date(y)), integer(0)) == FALSE){

    return(which(as.Date(x) == as.Date(y)))

  } else {

    return(myFunction(x,as.Date(y)+1))

  }

}
```

```
}  
}  
  
BVSP_USD <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/BVSP-  
  ↳ USD.xlsx", sheet = 2, guess_max = 1000000)  
  
BVSP_USD <- subset(BVSP_USD, select = c("Data", "BVSP-USD"))  
  
BVSP_USD <- subset(BVSP_USD, BVSP_USD$Data > "2008-12-31" & BVSP_USD$Data  
  ↳ < "2023-01-01")  
  
BVSP_USD <- na.omit(BVSP_USD)  
  
Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Dados  
  ↳ Arthur.xlsx", sheet = 1, guess_max = 1000000)  
  
Dados <- na.omit(Dados)  
  
Dados <- subset(Dados, Dados$Data > "2008-12-31" & Dados$Data <  
  ↳ "2023-01-01")  
  
Dados <- merge(Dados, BVSP_USD, by = "Data")  
  
qxts <- xts(Dados[,-1], order.by=Dados$Data)  
  
qxts <- diff(log(qxts))  
  
qxts <- na.omit(qxts)  
  
datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Datas  
  ↳ dos Eventos.xlsx", sheet = 3)  
  
datas <- as.Date(datas$Date)  
  
achar_index <- data.frame(date=index(qxts), coredata(qxts))  
  
vetor_indices <- c()
```

```
for (j in 1:length(datas)) {  
  
  d1 <- achar_index$date  
  
  d2 <- datas[j]  
  
  vetor_indices[j] <- myFunction(d1,d2)  
  
  print(d2)  
  
}  
  
rm(achar_index, Dados, datas, qxts, j, d1, d2)  
  
BVSP_USD <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/BVSP-  
  ↪ USD.xlsx", sheet = 2, guess_max = 1000000)  
  
BVSP_USD <- subset(BVSP_USD, select = c("Data", "BVSP-USD"))  
  
BVSP_USD <- subset(BVSP_USD, BVSP_USD$Data > "2008-12-31" & BVSP_USD$Data  
  ↪ < "2023-01-01")  
  
BVSP_USD <- na.omit(BVSP_USD)  
  
Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Dados  
  ↪ Arthur.xlsx", sheet = 1, guess_max = 1000000)  
  
Dados <- na.omit(Dados)  
  
Dados <- subset(Dados, Dados$Data > "2008-12-31" & Dados$Data <  
  ↪ "2023-01-01")  
  
Dados <- merge(Dados, BVSP_USD, by = "Data")  
  
qxts <- xts(Dados[,-1], order.by=Dados$Data)  
  
qxts <- diff(log(qxts))
```

```
qxts <- na.omit(qxts)

qxts <- subset(qxts, select = c(BR_INDEX, "S&P500"))

#Vetor de ndices que correspondentes s datas de ocorrncia dos eventos
indices_event <- vetor_indices
indices_estimation <- c(indices_event-1)

#Sero conduzidos estudos de eventos para varias janelas de
  ↳ 3,5,9,11,15,21,31 e 41 dias.

days_1 <- c(3,2,1)

days_2 <- c(0,0,0)

resultCAR <- list()

resultSCAR <- list()

for (k in 1:length(days_1)) {

  days_before <- days_1[k]

  days_forward <- days_2[k]

  var_ar_list <- list()

  CAR_list <- list()

  SCAR_list <- list()

  statistic_list <- list()

  for (i in 1:length(indices_event)) {

    #Definindo as datas das janelas de eventos e de estimao
    event_start = as.character(index(qxts[indices_event[i]-days_before]))

    event_end = as.character(index(qxts[indices_event[i]+days_forward]))
```

```

estimation_start = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-L1])))

estimation_end = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-1])))

model_qxts <- as.matrix(window(qxts, start = estimation_start, end =
  ↪ estimation_end))

beta_qxts <- window(qxts, start = estimation_start, end =
  ↪ estimation_end)

#Estimao do modelo DCC e o beta variante no tempo
uspec <- ugarchspec(mean.model = list(armaOrder = c(0,0)), variance.
  ↪ model = list(garchOrder = c(1,1), model = "sGARCH"),
  ↪ distribution.model = "norm")

spec1 <- dccspec(uspec = multispec(replicate(2,uspec)),dccOrder = c
  ↪ (1,1), distribution = "mvnorm")

fit1 <- dccfit(spec1, data = model_qxts)

fit1

if (days_before == days_forward) {

  beta_forecast <- dccforecast(fit1, n.ahead = ((days_before*2)+1))

  beta_predict <- c(beta_forecast@mforecast$H[[1]][[3]]/
    ↪ beta_forecast@mforecast$H[[1]][[4]],
    beta_forecast@mforecast$H[[1]][[7]]/
    ↪ beta_forecast@mforecast$H[[1]][[8]],
    beta_forecast@mforecast$H[[1]][[11]]/
    ↪ beta_forecast@mforecast$H[[1]][[12]])

  print("Janela simtrica")

} else if ((days_forward - days_before) < 0) {

```

```
beta_forecast <- dccforecast(fit1, n.ahead = ((days_before)+1))

loop <- c(((days_before)+1):1)

if (length(loop) == 4) {

  beta_predict <- c(beta_forecast@mforecast$H[[1]][[3]]/
    ↪ beta_forecast@mforecast$H[[1]][[4]],
    beta_forecast@mforecast$H[[1]][[7]]/
    ↪ beta_forecast@mforecast$H[[1]][[8]],
    beta_forecast@mforecast$H[[1]][[11]]/
    ↪ beta_forecast@mforecast$H[[1]][[12]],
    beta_forecast@mforecast$H[[1]][[15]]/
    ↪ beta_forecast@mforecast$H[[1]][[16]])

} else if (length(loop) == 3) {

  beta_predict <- c(beta_forecast@mforecast$H[[1]][[3]]/
    ↪ beta_forecast@mforecast$H[[1]][[4]],
    beta_forecast@mforecast$H[[1]][[7]]/
    ↪ beta_forecast@mforecast$H[[1]][[8]],
    beta_forecast@mforecast$H[[1]][[11]]/
    ↪ beta_forecast@mforecast$H[[1]][[12]])

} else if (length(loop) == 2) {

  beta_predict <- c(beta_forecast@mforecast$H[[1]][[3]]/
    ↪ beta_forecast@mforecast$H[[1]][[4]],
    beta_forecast@mforecast$H[[1]][[7]]/
    ↪ beta_forecast@mforecast$H[[1]][[8]])

} else {

  print("ERRO!!!")

}

print("Janela assimtrica negativa")
```

```

} else {

  beta_forecast <- dccforecast(fit1, n.ahead = ((days_forward)+1))

  beta_predict <- c(beta_forecast@mforecast$H[[1]][[3]]/
    ↪ beta_forecast@mforecast$H[[1]][[4]],
    beta_forecast@mforecast$H[[1]][[7]]/
    ↪ beta_forecast@mforecast$H[[1]][[8]])

  print("Janela assimtrica positiva")
}

covariancia <- as.data.frame(rcov(fit1)['BVSP-BRL', 'S&P500',])

covariancia$Data <- rownames(covariancia)

colnames(covariancia)[1] <- "Covariancia"

variancia_m <- as.data.frame(rcov(fit1)['S&P500', 'S&P500',])

variancia_m$Data <- rownames(variancia_m)

colnames(variancia_m)[1] <- "Variancia"

beta_before <- covariancia$Covariancia/variancia_m$Variancia

beta <- c(beta_before, beta_predict)

event_qxts <- window(qxts, start = estimation_start, end = event_end)

#Criando as colunas com o beta e a mdia mvel
event_qxts$beta <- beta

event_qxts$ut <- mean(beta_qxts[,1])

event_qxts$AR <- event_qxts[,1]-event_qxts$ut-event_qxts$beta*
  ↪ event_qxts[,2]

CAR <- sum(window(event_qxts$AR, start = event_start, end = event_end)

```

```

    ↪ )

var_ar <- sd(window(event_qxts$AR, start = estimation_start, end =
    ↪ estimation_end))^2

var_CAR <- length(window(event_qxts$AR, start = event_start, end =
    ↪ event_end))*var_ar

SCAR <- CAR/(var_CAR)^(1/2)

alpha<-0.05

df <- length(window(event_qxts$AR, start = estimation_start, end =
    ↪ estimation_end))-2

statistic <- qt(alpha/2,df)

test <- abs(SCAR) > abs(qt(1-(alpha/2),df))

#Salvando os dados para posterior utilizao
var_ar_list[[i]] <- list(var_ar, as.character(index(qxts[indices_event
    ↪ [i]])))

CAR_list[[i]] <- list(CAR, as.character(index(qxts[indices_event[i]]))
    ↪ )

SCAR_list[[i]] <- list(SCAR, as.character(index(qxts[indices_event[i]
    ↪ ])))

statistic_list[[i]] <- list(statistic, as.character(index(qxts[
    ↪ indices_event[i]])))

if (days_before == days_forward) {

  cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[
    ↪ i]])), "\n", "Janela de eventos de ", (2*days_1[k])+1, "dias\n
    ↪ ", "CAR:", CAR, "\n", "SCAR:", SCAR, "\n
    ↪ -----\n"))

```



```

} else if ((days_forward - days_before) < 0) {

  cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[i
  ↪ ]]))),"\n", "Janela de eventos de (-",(days_1[k]), ",0)", "
  ↪ dias\n", "CAR:", CAR, "\n","SCAR:", SCAR,"\n
  ↪ -----\n"))

} else {

  cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[
  ↪ i]])), "\n", "Janela de eventos de (0,", (days_2[k]), ")", "
  ↪ dias\n", "CAR:", CAR, "\n","SCAR:", SCAR,"\n
  ↪ -----\n"))

}

}

resultCAR[[k]] <- list(CAR_list)

resultSCAR[[k]] <- list(SCAR_list)

}

lista_final_CAR <- list()
lista_final_SCAR <- list()

for (l in 1:length(resultCAR)) {

  valores <- c(unlist(resultCAR[[l]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("CAR",l))

  lista_final_CAR[[l]] <- final

```

```
}

for (m in 1:length(resultSCAR)) {

  valores <- c(unlist(resultSCAR[[m]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("SCAR",m))

  lista_final_SCAR[[m]] <- final

}

merged_df_CAR <- Reduce(function(x, y) merge(x, y, by = "Data do Evento",
  ↪ all.x = TRUE), lista_final_CAR)

names(merged_df_CAR)[2:length(merged_df_CAR)] <- c("-1 dias", "3 dias",
  ↪ "+1 dias")

final_merged_df_CAR <- gather(merged_df_CAR, key = "Dias", value = "Valor
  ↪ CAR", -1)

merged_df_SCAR <- Reduce(function(x, y) merge(x, y, by = "Data do Evento",
  ↪ all.x = TRUE), lista_final_SCAR)

names(merged_df_SCAR)[2:length(merged_df_SCAR)] <- c("-1 dias", "3 dias",
  ↪ "+1 dias")

final_merged_df_SCAR <- gather(merged_df_SCAR, key = "Dias", value = "
  ↪ Valor SCAR", -1)

df_para_excel <- merge(final_merged_df_CAR, final_merged_df_SCAR, by = c('
  ↪ Data do Evento', 'Dias'))
```

```
df_para_excel$'Valor SCAR' <- as.numeric(df_para_excel$'Valor SCAR')

df_para_excel$'Valor CAR' <- as.numeric(df_para_excel$'Valor CAR')

estatisticas <- df_para_excel %>% group_by(Dias) %>% summarize(CAAR =
  ↪ mean(as.numeric('Valor CAR')),
  SCAAR = sqrt(var(as.numeric('Valor CAR'))),
  N = length('Valor CAR'),
  mediana = median(as.numeric('Valor CAR')),
  maximo = max(as.numeric('Valor CAR')),
  minimo = min(as.numeric('Valor CAR')),
  positivo = length('Valor CAR'[as.numeric('Valor CAR')>0])/
  ↪ length('Valor CAR'))

estatisticas$CV <- (estatisticas$SCAAR)/estatisticas$CAAR

estatisticas$t_stat <- (estatisticas$CAAR/estatisticas$SCAAR)*sqrt(
  ↪ estatisticas$N)

eventos_significantes <- sum(ifelse(abs(df_para_excel$'Valor SCAR') >
  ↪ 1.96, 1, 0))

print(eventos_significantes)

View(estatisticas)
```

```
rm(list=ls()[! ls() %in% c("df_para_excel", "estatisticas")])

View(subset(df_para_excel, Dias == "-1 dias" & abs('Valor SCAR') > 1.96))

View(subset(df_para_excel, Dias == "3 dias" & abs('Valor SCAR') > 1.96))

View(subset(df_para_excel, Dias == "+1 dias" & abs('Valor SCAR') > 1.96))

'''

MODELO DE MERCADO COM ERROS CORRIGIDOS GARCH

'''{r setup, include=FALSE}
library(readxl)
library(xts)
library(dplyr)
library(xlsx)
library(rugarch)
library(ggplot2)
library(tidyr)
library(purrr)

options(scipen=999)

BR_INDEX <- "BVSP-BRL"

#Janela de estimao
L1 <- 500

myFunction <- function(x, y) {

  if (identical(which(as.Date(x) == as.Date(y)), integer(0)) == FALSE){

    return(which(as.Date(x) == as.Date(y)))

  } else {

    return(myFunction(x,as.Date(y)+1))

  }

}
```

```
}  
}  
  
BVSP_USD <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/BVSP-  
  ↳ USD.xlsx", sheet = 2, guess_max = 1000000)  
  
BVSP_USD <- subset(BVSP_USD, select = c("Data", "BVSP-USD"))  
  
BVSP_USD <- subset(BVSP_USD, BVSP_USD$Data > "2008-12-31" & BVSP_USD$Data  
  ↳ < "2023-01-01")  
  
BVSP_USD <- na.omit(BVSP_USD)  
  
Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Dados  
  ↳ Arthur.xlsx", sheet = 1, guess_max = 1000000)  
  
Dados <- na.omit(Dados)  
  
Dados <- subset(Dados, Dados$Data > "2008-12-31" & Dados$Data <  
  ↳ "2023-01-01")  
  
Dados <- merge(Dados, BVSP_USD, by = "Data")  
  
qxts <- xts(Dados[,-1], order.by=Dados$Data)  
  
qxts <- diff(log(qxts))  
  
qxts <- na.omit(qxts)  
  
datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Datas  
  ↳ dos Eventos.xlsx", sheet = 3)  
  
datas <- as.Date(datas$Date)  
  
achar_index <- data.frame(date=index(qxts), coredata(qxts))  
  
vetor_indices <- c()
```

```
for (j in 1:length(datas)) {  
  
  d1 <- achar_index$date  
  
  d2 <- datas[j]  
  
  vetor_indices[j] <- myFunction(d1,d2)  
  
  print(d2)  
  
}  
  
rm(achar_index, Dados, datas, qxts, j, d1, d2)  
  
BVSP_USD <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/BVSP-  
  ↪ USD.xlsx", sheet = 2, guess_max = 1000000)  
  
BVSP_USD <- subset(BVSP_USD, select = c("Data", "BVSP-USD"))  
  
BVSP_USD <- subset(BVSP_USD, BVSP_USD$Data > "2008-12-31" & BVSP_USD$Data  
  ↪ < "2023-01-01")  
  
BVSP_USD <- na.omit(BVSP_USD)  
  
Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Dados  
  ↪ Arthur.xlsx", sheet = 1, guess_max = 1000000)  
  
Dados <- na.omit(Dados)  
  
Dados <- subset(Dados, Dados$Data > "2008-12-31" & Dados$Data <  
  ↪ "2023-01-01")  
  
Dados <- merge(Dados, BVSP_USD, by = "Data")  
  
qxts <- xts(Dados[, -1], order.by=Dados$Data)  
  
qxts <- diff(log(qxts))
```

```
qxts <- na.omit(qxts)

qxts <- subset(qxts, select = c(BR_INDEX, "S&P500"))

#Vetor de ndices que correspondentes s datas de ocorrncia dos eventos
indices_event <- vetor_indices
indices_estimation <- c(indices_event-1)

#Sero conduzidos estudos de eventos para varias janelas de
  ↳ 3,5,9,11,15,21,31 e 41 dias.

days_1 <- c(3,2,1)

days_2 <- c(0,0,0)

resultCAR <- list()

resultSCAR <- list()

for (k in 1:length(days_1)) {

  days_before <- days_1[k]

  days_forward <- days_2[k]

  var_ar_list <- list()

  CAR_list <- list()

  SCAR_list <- list()

  statistic_list <- list()

  for (i in 1:length(indices_event)) {

    #Definindo as datas das janelas de eventos e de estimao
    event_start = as.character(index(qxts[indices_event[i]-days_before]))

    event_end = as.character(index(qxts[indices_event[i]+days_forward]))
```

```
estimation_start = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-L1])))

estimation_end = as.character(as.Date(index(qxts[indices_event[i]-
  ↪ days_before-1])))

model_qxts <- window(qxts, start = estimation_start, end =
  ↪ estimation_end)

#Estimao do modelo de mercado

spec <- ugarchspec(variance.model =
list(model = "sGARCH", garchOrder = c(1, 1),
submodel = NULL, external.regressors = NULL, variance.targeting =
  ↪ FALSE),
mean.model = list(armaOrder = c(0, 0), external.regressors =
  ↪ model_qxts[,2],
distribution.model = "norm", start.pars = list(), fixed.pars =
  ↪ list()))

market_garch <- ugarchfit(spec = spec, data = model_qxts[,1], solver
  ↪ = 'hybrid')

event_qxts <- window(qxts, start = estimation_start, end = event_end
  ↪ )

event_qxts$AR <- event_qxts[,1]-market_garch@fit$coef[1]-
  ↪ market_garch@fit$coef[2]*event_qxts$'S&P500'

CAR <- sum(window(event_qxts$AR, start = event_start, end =
  ↪ event_end))

var_ar <- sd(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))^2

var_CAR <- length(window(event_qxts$AR, start = event_start, end =
  ↪ event_end))*var_ar
```



```

SCAR <- CAR/(var_CAR)^(1/2)

alpha<-0.05

df <- length(window(event_qxts$AR, start = estimation_start, end =
  ↪ estimation_end))-2

statistic <- qt(alpha/2,df)

test <- abs(SCAR) > abs(qt(1-(alpha/2),df))

#Salvando os dados para posterior utilizao
var_ar_list[[i]] <- list(var_ar, as.character(index(qxts[indices_event
  ↪ [i]])))

CAR_list[[i]] <- list(CAR, as.character(index(qxts[indices_event[i]]))
  ↪ )

SCAR_list[[i]] <- list(SCAR, as.character(index(qxts[indices_event[i]
  ↪ ]]))))

statistic_list[[i]] <- list(statistic, as.character(index(qxts[
  ↪ indices_event[i]])))

if (days_before == days_forward) {

  cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[
    ↪ i]])), "\n", "Janela de eventos de ", (2*days_1[k])+1, "dias\n
    ↪ ", "CAR:", CAR, "\n", "SCAR:", SCAR, "\n
    ↪ ----- \n"))

} else if ((days_forward - days_before) < 0) {

  cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[i]
    ↪ ]])), "\n", "Janela de eventos de (-", (days_1[k]), ", 0)", "
    ↪ dias\n", "CAR:", CAR, "\n", "SCAR:", SCAR, "\n
    ↪ ----- \n"))

} else {

```

```
    cat(paste("Evento", "dia:", as.character(index(qxts[indices_event[
      ↪ i]])), "\n", "Janela de eventos de (0,", (days_2[k]), ")", "
      ↪ dias\n", "CAR:", CAR, "\n", "SCAR:", SCAR, "\n
      ↪ -----\n"))
  }

}

resultCAR[[k]] <- list(CAR_list)

resultSCAR[[k]] <- list(SCAR_list)

}

lista_final_CAR <- list()
lista_final_SCAR <- list()

for (l in 1:length(resultCAR)) {

  valores <- c(unlist(resultCAR[[l]]))

  numbers <- valores[seq(1, length(valores), 2)]
  dates <- as.Date(valores[seq(2, length(valores), 2)])

  final <- data.frame(data = dates, x = numbers)

  names(final) <- c("Data do Evento", paste("CAR", l))

  lista_final_CAR[[l]] <- final

}

for (m in 1:length(resultSCAR)) {

  valores <- c(unlist(resultSCAR[[m]]))

  numbers <- valores[seq(1, length(valores), 2)]
```



```

        ↪ numeric('Valor
        ↪ CAR')),
N = length('Valor
        ↪ CAR'),
mediana = median(as.
        ↪ numeric('Valor
        ↪ CAR')),
maximo = max(as.
        ↪ numeric('Valor
        ↪ CAR')),
minimo = min(as.
        ↪ numeric('Valor
        ↪ CAR')),
positivo = length('
        ↪ Valor CAR'[as.
        ↪ numeric('Valor
        ↪ CAR')>0])/
        ↪ length('Valor
        ↪ CAR'))

estatisticas$CV <- (estatisticas$SCAAR)/estatisticas$CAAR

estatisticas$t_stat <- (estatisticas$CAAR/estatisticas$SCAAR)*sqrt(
        ↪ estatisticas$N)

eventos_significantes <- sum(iffelse(abs(df_para_excel$'Valor SCAR') >
        ↪ 1.96, 1, 0))

print(eventos_significantes)

View(estatisticas)

rm(list=ls()[! ls() %in% c("df_para_excel", "estatisticas")])

View(subset(df_para_excel, Dias == "-1 dias" & abs('Valor SCAR') > 1.96))

View(subset(df_para_excel, Dias == "3 dias" & abs('Valor SCAR') > 1.96))

View(subset(df_para_excel, Dias == "+1 dias" & abs('Valor SCAR') > 1.96))

```

```
‘ ‘ ‘
```

### Modelos estimados

```
library(rmgarch)
library(ggplot2)
library(readxl)
library(xts)
library(ggpubr)

#Desabilitando a notao cienttifica
options(scipen=999)

Dados <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Dados
  ↪ Arthur.xlsx", sheet = 1, guess_max = 1000000)

Dados <- na.omit(Dados)

Dados <- subset(Dados, Dados$Data > "2008-12-31" & Dados$Data <
  ↪ "2023-01-01")

qxts <- xts(Dados[,-1], order.by=Dados$Data)

qxts <- diff(log(qxts))

qxts <- na.omit(qxts)

qxts <- window(qxts, start = "2012-01-01", end = "2022-12-31")

#DCC
uspec <- ugarchspec(mean.model = list(armaOrder = c(0,0)), variance.model
  ↪ = list(garchOrder = c(1,1), model = "sGARCH"), distribution.model
  ↪ = "norm")

spec1 <- dccspec(uspec = multispec(replicate(2,uspec)),dccOrder = c(1,1),
  ↪ distribution = "mvnorm")

fit1 <- dccfit(spec1, data = qxts)
```

```
fit1

covariancia <- as.data.frame(rcov(fit1)['BVSP-BRL', 'S&P500',])

covariancia$Data <- rownames(covariancia)

colnames(covariancia)[1] <- "Covariancia"

variancia_m <- as.data.frame(rcov(fit1)['S&P500', 'S&P500',])

variancia_m$Data <- rownames(variancia_m)

colnames(variancia_m)[1] <- "Variancia"

beta_before <- covariancia$Covariancia/variancia_m$Variancia

beta_dcc <- data.frame(Data = as.Date(covariancia$Data),
                      beta = beta_before)

dcc_cor <- as.data.frame(rcor(fit1)['BVSP-BRL', 'S&P500',])

dcc_cor$Data <- rownames(dcc_cor)

dcc_plot1 <- ggplot() + geom_line(data = beta_dcc, aes(x = Data, y = beta
  ↪ ), size = 0.5)+
  labs(x="", y="", title="Beta DCC")+
  theme_bw()+
  theme(axis.text.x = element_text(angle = -45, hjust = 0.5))

dcc_plot2 <- ggplot() + geom_line(data = covariancia, aes(x = as.Date(
  ↪ Data), y = Covariancia), size = 0.5) +
  labs(x="", y="", title="Cov. Condicional DCC")+
  theme_bw()+
  theme(axis.text.x = element_text(angle = -45, hjust = 0.5))

dcc_plot3 <- ggplot() + geom_line(data = dcc_cor, aes(x = as.Date(Data),
  ↪ y = 'rcor(fit1)["BVSP-BRL", "S&P500", ]'), size = 0.5) +
  labs(x="", y="", title="Corr. Condicional DCC")+
  theme_bw()+
```

```

  theme(axis.text.x = element_text(angle = -45, hjust = 0.5))

#BEKK
library(BEKKs)

obj_spec <- bekk_spec()
bekk_model <- bekk_fit(obj_spec, qxts, QML_t_ratios = FALSE, max_iter =
  ↪ 50, crit = 1e-9)

beta_bekk <- bekk_model$H_t[,2]/bekk_model$H_t[,4]

beta_bekk <- data.frame(date=index(beta_bekk), coredata(beta_bekk))

bekk_cov <- data.frame(date=index(bekk_model$H_t[,2]), coredata(
  ↪ bekk_model$H_t[,2]))

bekk_cor <- data.frame(date=index(bekk_model$H_t[,2]/sqrt(bekk_model$H_t
  ↪ [,1]*bekk_model$H_t[,4])),
  coredata(bekk_model$H_t[,2]/sqrt(bekk_model$H_t[,1]*
  ↪ bekk_model$H_t[,4])))

bekk_plot1 <- ggplot() + geom_line(data = beta_bekk, aes(x = date, y =
  ↪ coredata.beta_bekk.), size = 0.5) +
  labs(x="", y="", title="Beta BEKK")+
  theme_bw()+
  theme(axis.text.x = element_text(angle = -45, hjust = 0.5))

bekk_plot2 <- ggplot() + geom_line(data = bekk_cov, aes(x = date, y =
  ↪ coredata.bekk_model.H_t...2..), size = 0.5) +
  labs(x="", y="", title="Cov. Condicional BEKK")+
  theme_bw()+
  theme(axis.text.x = element_text(angle = -45, hjust = 0.5))

bekk_plot3 <- ggplot() + geom_line(data = bekk_cor, aes(x = as.Date(date),
  ↪ y = coredata.bekk_model.H_t...2..sqrt.bekk_model.H_t...1....
  ↪ bekk_model.H_t...), size = 0.5) +
  labs(x="", y="", title="Corr. Condicional BEKK")+
  theme_bw()+
  theme(axis.text.x = element_text(angle = -45, hjust = 0.5))

```

```
final_graph <- ggarrange(dcc_plot1, dcc_plot2, dcc_plot3, bekk_plot1,  
  ↪ bekk_plot2, bekk_plot3)  
  
final_graph  
  
fit1  
  
summary(bekk_model)
```

### Regressões Probit

```
````{r setup, include=FALSE}  
library(readxl)  
library(lubridate)  
  
dias <- "-1 dias"  
  
DI <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Taxas de  
  ↪ juros.xlsx", sheet = 1, guess_max = 1000000)  
  
LTN <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Taxas de  
  ↪ juros.xlsx", sheet = 2, guess_max = 1000000)  
  
taxas <- merge(DI, LTN, by = "Data do Evento")  
  
taxas$'Data do Evento' <- as.Date(dmy(taxas$'Data do Evento'))  
  
taxas <- xts(taxas[, -1], order.by=taxas$'Data do Evento')  
  
taxas <- na.omit(taxas)  
  
taxas <- diff(log(taxas))  
  
taxas <- na.omit(taxas)  
  
taxas <- data.frame(date=index(taxas), coredata(taxas))  
  
colnames(taxas)[colnames(taxas) == "date"] = "Data do Evento"
```



```
datas <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/Datas
  ↳ dos Eventos.xlsx", sheet = 7)

datas <- datas[-55,]

painel <- merge(df_para_excel, taxas, by = "Data do Evento")

painel$Dependente <- if_else(abs(painel$'Valor SCAR') > 1.96, 1, 0)

regressao <- subset(painel, Dias == dias)

regressao <- regressao[order(regressao$'Data do Evento', decreasing =
  ↳ TRUE), ]

regressao$Forward <- datas$Forward

regressao$QE <- datas$QE

regressao <- xts(regressao[,-1], order.by=regressao$'Data do Evento')

IMA <- read_excel("C:/Users/Arthur/Desktop/Artigo Anncios FOMC/BVSP-USD.
  ↳ xls", sheet = 2, guess_max = 1000000)

IMA <- subset(IMA, select = c("Data", "IMA-G"))

IMA <- na.omit(IMA)

IMA <- xts(IMA[,-1], order.by=IMA$Data)

IMA <- diff(log(IMA))

IMA <- na.omit(IMA)

regressao <- merge.xts(regressao, IMA)

regressao$Dias <- NULL

regressao <- na.omit(regressao)
```

```
regressao <- data.frame(date=index(regressao), coredata(regressao))

probitMod1 <- glm(regressao$Dependente ~ regressao$Forward, data =
  ↪ regressao, family = binomial(link = "probit"))

probitMod2 <- glm(regressao$Dependente ~ regressao$Forward + regressao$QE
  ↪ + regressao$IMA.G, data = regressao, family = binomial(link = "
  ↪ probit"))

probitMod3 <- glm(regressao$Dependente ~ regressao$Forward + regressao$QE
  ↪ + regressao$DI, data = regressao, family = binomial(link = "probit
  ↪ "))

probitMod4 <- glm(regressao$Dependente ~ regressao$Forward + regressao$QE
  ↪ + regressao$DI + regressao$IMA.G, data = regressao, family =
  ↪ binomial(link = "probit"))

summary(probitMod1)

summary(probitMod2)

summary(probitMod3)

summary(probitMod4)

'''
```