



Paulo Vitor Jordão da Gama Silva

**Ensaio sobre Moedas Digitais: Um Estudo sobre
Volatilidade e Fenômenos Comportamentais**

Tese de Doutorado

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

Orientador: Prof. Marcelo Cabús Klotzle.

Co-orientador: Prof. Leonardo Lima Gomes.

Rio de Janeiro
Julho de 2019



Paulo Vitor Jordão da Gama Silva

**Ensaio sobre Moedas Digitais: Um Estudo sobre
Volatilidade e Fenômenos Comportamentais**

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

Prof. Marcelo Cabús Klotzle

Orientador

Departamento de Administração – PUC-Rio

Prof. Leonardo Lima Gomes

Co-orientador

Departamento de Administração – PUC-Rio

Prof. Antonio Carlos Figueiredo Pinto

Departamento de Administração – PUC-Rio

Prof. Carlos de Lamare Bastian Pinto

Pesquisador Autônomo

Prof. Carlos Heitor d'Avila Pereira Campani

UFRJ - Instituto COPPEAD de Administração

Prof. Fernando Nascimento de Oliveira

Instituto Brasileiro de Mercado de Capitais IBMEC-RJ

Rio de Janeiro, 29 de julho de 2019

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

Paulo Vitor Jordão da Gama Silva

Graduado em Administração (PUC-Rio) e Contabilidade (UNESA), possui MBA em Gestão Tributária e Fiscal (UNESA) e mestrado em finanças pela PUC-Rio. Possui experiência profissional em empresas públicas, privadas e multinacionais, atuando em áreas como: planejamento e controle financeiro, controladoria, contabilidade e projetos financeiros. Atualmente é proprietário da empresa Blockchain Finance, professor no MBA na IBMEC em modalidade EAD, membro do Núcleo de pesquisa CNPq de Finanças Comportamentais da PUC-Rio, membro do Núcleo de Pesquisa em Finanças (FINE) da PUC-Rio e professor na da Associação de Peritos Judiciais do Estado do Rio de Janeiro (APJERJ).

Ficha Catalográfica

Silva, Paulo Vitor Jordão da Gama

Ensaio sobre moedas digitais: um estudo sobre volatilidade e fenômenos comportamentais / Paulo Vitor Jordão da Gama Silva; orientador: Marcelo Cabús Klötzle; co-orientador: Leonardo Lima Gomes. – 2019.

200 f.: il. color.; 30 cm

Tese (doutorado)–Pontifícia Universidade Católica do Rio de Janeiro, Departamento de Administração, 2019.

Inclui bibliografia

1. Administração – Teses. 2. Criptoativos. 3. Efeito contágio. 4. Efeito manada. 5. Estados de volatilidade. 6. Feedback trading. I. Klötzle, Marcelo Cabús. II. Gomes, Leonardo Lima. III. Pontifícia Universidade Católica do Rio de Janeiro. Departamento de Administração. IV. Título.

CDD:658

Agradecimentos

Gostaria de agradecer ao meu orientador, professor Marcelo Cabús Klotzle, pelo estímulo e parceria para com a realização deste trabalho.

Ao professor Leonardo Gomes Lima pelo direcionamento da temática e parceria no projeto pelo qual esta tese teve sua inspiração / direcionamento.

Ao professor Antônio Carlos Figueiredo pelo auxílio bibliográfico e demais contribuições.

A PUC-Rio, CCPG e a Queiroz Galvão Energias Renováveis por meio do programa de P&D da ANEEL, pelos auxílios concedidos, sem os quais este trabalho não poderia ter sido realizado.

Aos meus pais e a minha avó Maria Alice (pela atenção e carinho de todas as horas), bem como aos familiares e amigos que de uma forma ou de outra me estimularam ou me ajudaram nesta jornada (em especial Renata Mattos).

Aos meus colegas de doutorado PUC-Rio e em especial ao amigo pesquisador Augusto Ferreira da Costa Neto que gerou grandes contribuições.

Aos professores Carlos Bastian, Carlos Campani e Fernando Nascimento que participaram da Comissão Examinadora.

A todos os professores e funcionários do IAG PUC-Rio pelos ensinamentos e pela ajuda.

O presente trabalho foi realizado com o apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior – Brasil (CAPES) – Código de Financiamento 001.

Resumo

Silva, Paulo Vitor Jordão da Gama; Klotzle, Marcelo Cabús; Gomes, Leonardo Lima. **Ensaio sobre Moedas Digitais: Um Estudo sobre Volatilidade e Fenômenos Comportamentais**. Rio de Janeiro, 2019. 200p. Tese de Doutorado - Departamento de Administração, Pontifícia Universidade Católica do Rio de Janeiro.

Com o surgimento dos criptoativos em 2009, iniciado com o Bitcoin, uma nova dinâmica de investimento e de tecnologia emergiu no século XXI com um novo mercado que já chegou a mais de 800 bilhões de dólares em 2018 e conta com mais de 2.000 moedas. Apesar da elevada volatilidade, de vários escândalos de pirâmides, da ausência de regulamentação e da maior utilização como investimento do que em compras de bens e serviços, os criptoativos vêm ganhando seu espaço, em meio às controvérsias, devido a tecnologia disruptiva. Este trabalho tem por objetivo analisar os 50 maiores criptoativos do mercado durante o período de 2015 – 2018 por meio de três ensaios que abordam: (i) a análise e previsão de volatilidade utilizando o MSGARCH (KLAASSEN, 2002), com testes de acurácia (envolvendo funções perda EQM e QLIKE, bem como o MAE, MAPE e o indicador U de Theil); (ii) análise dos fenômenos comportamentais de efeito manada seguindo modificações nas metodologias CSSD (CHRISTIE E HUANG, 1995), CSAD (CHANG, CHENG E KHORANA, 2000) e HS (HWANG E SALMON, 2004), bem como o efeito contágio seguindo modificações nas metodologias do teste FR (FORBES E RIGOBON, 2002) e de testes de comomentos de ordem superior (FRY, MARTIN E TANG, 2010; FRY-MCKIBBIN E HSIAO, 2018); (iii) bem como a análise do fenômeno de *feedback trading* por meio do modelo seminal de Sentana e Wadhvani (1992). Como principais achados, foi identificado que: (i) há uma forte influência de dois estados de volatilidade; nos criptoativos com maior probabilidade de ocorrência do segundo regime existe uma maior tendência do aparecimento do segundo estado de volatilidade com a subida de preços, onde existe uma maior volatilidade - a exceção que foi notada cabe apenas ao BTC e ETH, onde o primeiro estado de volatilidade é mais presente na subida de preços, com maior volatilidade; existe uma maior assertividade da previsão com dois estados de volatilidade para janelas de previsão mais longas do que nas mais curtas; (ii) em

relação ao efeito manada, o modelo CSAD detectou um efeito pouco significativo, e o modelo CSSD detectou um efeito manada forte estatisticamente significativo no movimento de queda de mercado; o modelo HS capturou com sucesso o comportamento de manada e revelou períodos extremos de manada reversa; em relação ao efeito contágio, o teste FR conseguiu captar contágio do Bitcoin em outras moedas em praticamente todos os casos com exceção do Tether Dollar, BITCNY e ECC - que tipicamente possuem controle inflacionário e particularidades das *stablecoins*; nos modelos de comomentos, os testes indicaram contágio do Bitcoin em relação as moedas analisadas; (iii) em relação ao fenômeno de *feedback trading*, foi possível captar *feedback trade* negativo no TETHER e positivo nas moedas BTC, ETH, CSC e ECC, cuja adequação do modelo utilizado foi confirmada posteriormente pelo teste de viés de sinais (ENGLE E NG, 1993), com exceção do TETHER - que contrariou Sentana e Wadhwani (1992) e Shi, Chiang e Liang (2012) ao apontarem que modelos menos parcimoniosos teriam pouca influência na verificação de *feedback trading*.

Palavras-chave

Criptoativos; Efeito Contágio; Efeito Manada; Estados de Volatilidade; Feedback Trading.

Abstract

Silva, Paulo Vitor Jordão da Gama; Klotzle, Marcelo Cabús (Advisor); Gomes, Leonardo Lima (Co-Advisor). **Essays on Digital Currencies: A Study about Volatility and Behavioral Phenomena**. Rio de Janeiro, 2019. 200p. Tese de Doutorado - Departamento de Administração, Pontifícia Universidade Católica do Rio de Janeiro.

With the arise of cryptocurrencies in 2009, started with the Bitcoin, a new dynamic of investment and technology emerged in the 21st century with a new market that has already exceed US\$ 800 billion in 2018 and has more than 2,000 coins. Despite the high volatility, various Ponzi schemes, lack of regulation and the main use as investment than in purchases goods and services, cryptocurrencies have been gaining ground, amid controversy, due to the disruptive technology. The objective of this work is to analyze the 50 largest cryptocurrencies in the market during the period of 2015-2018 by means of three essays that seek to investigate: (i) the volatility analysis and prediction using MSGARCH (KLAASSEN, 2002), with accuracy tests (involving MSE and QLIKE loss functions, as well as MAE, MAPE, and Theil's U indicator); (ii) the analysis of the behavioral phenomena of herd effect following modifications in CSSD (CHRISTIE & HUANG, 1995), CSAD (CHANG, CHENG & KHORANA, 2000) and HS (HWANG & SALMON, 2004) methodologies, as well as the contagion effect following modifications in the methodologies of FR test (FORBES & RIGOBON, 2002) and higher order comoments tests (FRY, MARTIN & TANG, 2010; FRY-MCKIBBIN & HSIAO, 2018); (iii) the analysis of the feedback trading phenomenon through the seminal model of Sentana and Wadhvani (1992). As main findings, it was identified that: (i) there is a strong influence of two volatility states; in the cryptoassets with more probability of occurrence under the second regime, there is a greater tendency of occurrence of the second state of volatility when prices go up, where there is more the volatility - the exception that has been noted only in BTC and ETH, where the first state of volatility is strong when prices go up, with more volatility; there is more accuracy in the forecasting with two volatility states for long term prediction than in short term prediction; (ii) with respect to the herd effect, the CSAD model detected a small herd effect, with little statistical significance, and the CSSD model

detected a strong herd effect statistically significant in the down movement of market; the HS model successfully captured herd behavior and revealed extreme periods of reversal in the herd effect; in relation to the contagion effect, the FR test was able to capture Bitcoin's contagion in other currencies in practically all cases except Tether Dollar, BITCNY and ECC - which typically have inflationary control and particularities of stablecoins; in the comoments models, the tests indicated contagion of Bitcoin in relation to the currencies analyzed; (iii) in relation to the feedback trading phenomenon, it was possible to capture negative feedback trading in TETHER and positive in BTC, ETH, CSC and ECC, whose adequacy of the model used was confirmed later by the signal bias test (ENGLE & NG, 1993), with the exception of TETHER - which contradicts Santana and Wadhvani (1992) and Shi, Chiang and Liang (2012) that less parsimonious models would have little influence on feedback trading.

Keywords

Cryptocurrencies; Contagion Effect; Herd Effect; Volatility States; Feedback Trading.

Sumário

1. Introdução Geral	18
2. Primeiro Ensaio: Avaliação de Estados de Volatilidade em Criptoativos	24
2.1. Principais Moedas do Mercado Digital	25
2.2. Estudos Relevantes sobre Volatilidade de Criptoativos	30
2.3. Modelos Markovianos de Mudança de Estado	37
2.4. Metodologia e Base de Dados	39
2.5. Resultados	46
2.6. Conclusões	58
3. Segundo Ensaio: Efeitos Manada e Contágio no Mercado de Criptoativos	60
3.1. Efeito Manada	61
3.2. Efeito Contágio	66
3.3. Principais Estudos Anteriores	69
3.4. Metodologia e Base de Dados	70
3.4.1. Composição e Cálculo do Índice CRIX	71
3.4.2. Efeito Manada	72
3.4.3. Efeito Contágio	74
3.5. Resultados	77
3.5.1. Efeito Manada	77
3.5.2. Efeito Contágio	84
3.6. Conclusões	87
4. Terceiro Ensaio: O Efeito do <i>Feedback Trading</i> no Mercado de Criptoativos	89
4.1. O Mercado de Criptoativos	90
4.2. Comportamento do Investidor e Modelos de <i>Feedback Trading</i>	96
4.3. Metodologia e Base de Dados	99
4.4. Resultados	103
4.5. Conclusões	106
5. Considerações Finais	108
6. Referências bibliográficas	112
7. Anexos	125
7.1. Anexo 1: Primeiro Ensaio	125
7.1.1. Gráficos de volatilidade condicional para apenas um estado	125
7.1.2. Gráficos de volatilidade condicional para dois estados	131
7.1.3. Gráficos probabilidades filtradas para um e dois regimes	137

7.2. Anexo 2: Segundo Ensaio	149
7.2.1. Testes de cocurtose e covolatilidade	149
7.3. Anexo 3: Terceiro Ensaio	151
7.3.1. Resultados completos do teste de <i>feedback trading</i>	151
7.3.2. Resultados completos do teste de robustez de viés de sinais	176

Lista de Tabelas

Primeiro Ensaio: Avaliação de Estados de Volatilidade em Criptoativos

Tabela 1 - Seleção dos 50 Criptoativos	39
Tabela 2 - Melhores modelos por Estado de Volatilidade	42
Tabela 3 - Resumo da volatilidade por estado	46
Tabela 4 - Parâmetros nos Estados de Volatilidade	47
Tabela 5 - Duração Média em Dias da Permanência em cada Estado de Volatilidade	49
Tabela 6 - Parâmetros nos Estados de Volatilidade	50
Tabela 7 - Teste de Acurácia com Função Perda EQM	53
Tabela 8 - Teste de Acurácia com Função Perda QLIKE	54
Tabela 9 - Teste de Acurácia com MAE	55
Tabela 10 - Teste de Acurácia com MAPE	56
Tabela 11 - Teste de Acurácia com indicador U de Theil	57

Segundo Ensaio: Efeitos Manada e Contágio no Mercado de Criptoativos

Tabela 1 - Seleção dos 50 Criptoativos	70
Tabela 2 - Sumário Estatístico do Retorno, CSSD e CSAD	77
Tabela 3 - Sumário Estatístico do Mercado Global 2000-2009	78
Tabela 4 - Resultado do teste CSSD	79
Tabela 5 - Resultado do teste CSAD	79
Tabela 6 - Resultado do Modelo HS	80
Tabela 7 - Teste HS antes e depois da quebra estrutural de data	83
Tabela 8 - Teste de Contágio FR para 2015 - 2018	84
Tabela 9 - Teste de Contágio FR por ano	85
Tabela 10 - Teste de Contágio de Coasimetria de 2015 - 2018	86
Tabela 11 - Teste de Contágio de Coasimetria por ano	86

Terceiro Ensaio: O Efeito do *Feedback Trading* no Mercado de Criptoativos

Tabela 1 - Seleção dos 50 Criptoativos	99
Tabela 2 - Resultado do teste SW de <i>feedback trading</i>	103
Tabela 3 - Visão geral dos resultados de <i>feedback trading</i>	104
Tabela 4 - Resultado do teste de viés de sinais	105

Lista de Gráficos

Segundo Ensaio: Efeitos Manada e Contágio no Mercado de Criptoativos

Gráfico 1 - Evolução da estatística h_{mt} do efeito manada 80

Gráfico 2 - Teste Zivot-Andrews com o efeito manada 83

Terceiro Ensaio: O Efeito do *Feedback Trading* no Mercado de Criptoativos

Gráfico 1 - Capitalização Mensal de Mercado em USD 90

Gráfico 2 - Retorno Acumulados Diários de 2017 91

Gráfico 3 - Levantamento dos principais ICOs de 2014 – 2017 93

Lista de Equações

Primeiro Ensaio: Avaliação de Estados de Volatilidade em Criptoativos

Eq. (1) - Séries temporais com mudanças de estado Markoviano	37
Eq. (2) - Variância condicional com mudança de estado	38
Eq. (3) - Forma generalizada do processo de retorno do MSGARCH	40
Eq. (4) - Distribuição condicional do retorno	41
Eq. (5) - Variância agregada para data t-1 condicional	41
Eq. (6) - Termo de choque	41
Eq. (7) - Volatilidade para dois estados generalizada	41
Eq. (8) - Probabilidade de transição da cadeia de Markov	41
Eq. (9) - Duração esperada do estado de volatilidade	42
Eq. (10) - Teste de Erro Quadrático Médio	44
Eq. (11) - Teste Quasi-Likelihood	44
Eq. (12) - Teste de Erro Absoluto Médio	45
Eq. (13) - Teste de Erro Absoluto Médio Percentual	45
Eq. (14) - Teste do índice U de Theil	45

Segundo Ensaio: Efeitos Manada e Contágio no Mercado de Criptoativos

Eq. (1) - Método de Lakonishok, Shleifer e Vishny (1992)	62
Eq. (2) - Fração institucional de compra	63
Eq. (3) - Fração de investidores institucionais	63
Eq. (4) - Regressão do modelo de Sias (2004)	63
Eq. (5) - Desvio padrão transversal dos retornos ou CSSD	64
Eq. (6) - Regressão do modelo CSSD	64
Eq. (7) - Desvio absoluto transversal dos retornos ou CSAD	65
Eq. (8) - Regressão do modelo CSAD	65
Eq. (9) - Índice CRIX baseado em Laspeyres	72
Eq. (10) - Divisor K do índice CRIX	72
Eq. (11) - Modificação do CSSD	73
Eq. (12) - Modificação do CSAD	73
Eq. (13) – Modificação da Regressão do modelo CSAD	73
Eq. (14) - Modelo HS de estado espaço com filtro de Kalman	74
Eq. (15) - Estimador H_{mt} do Modelo de estado espaço HS	74
Eq. (16) - Coeficiente de Pearson do teste de contágio FR	75
Eq. (17) - Teste de Contágio FR	75
Eq. (18) - Teste de Coassimetria	76
Eq. (19) - Teste de Cocurtose	76
Eq. (20) - Teste e Covolatilidade	76

Terceiro Ensaio: O Efeito do *Feedback Trading* no Mercado de Criptoativos

Eq. (01) - Função de demanda para a utilidade esperada	100
Eq. (02) - Demanda por cotas do <i>feedback trader</i>	100
Eq. (03) - Equação geral do mercado em equilíbrio SW	100
Eq. (04) - Modelo de retorno do processo SW	101
Eq. (05) - Retornos esperados com erro estocástico em SW	101
Eq. (06) - Modelo proposto por Sentana e Wadwhani (1992)	101
Eq. (07) - Processo assimétrico GARCH no Modelo SW	102
Eq. (08) - Teste de viés de sinais de Engle e Ng (1993)	102

Lista de Abreviaturas

ACGARCH - Assymmetric Component GARCH (GARCH de componente assimétrico);
AIC - Akaike;
APARCH - Assymmetric Power ARCH (ARCH de poder assimétrico);
AR - Processo autorregressivo;
ARCH - Autoregressive conditional heteroskedasticity (heteroscedasticidade condicional autorregressiva);
ARFIMA - Autoregressive fractionally integrated moving average model (modelo de média móvel integrado fracionado autorregressivo);
AVGARCH - Absolute Value GARCH (GARCH de valor absoluto);
BACEN – Banco Central do Brasil;
BAY - BitBay;
BBR - Boolberry;
BCH - Bitcoin Cash;
BCN - Bytecoin;
BIC - Critério Bayesiano de Schwarz;
BLK - BlackCoin;
BLOCK - Blocknet;
BTC - Bitcoin;
BTS - BitShares;
CAPM - Capital Asset Pricing Model (Modelo de precificação de ativos financeiros);
CCC MGARCH - Constant Conditional Correlation multivariate GARCH (GARCH multivariado de correlação condicional constante);
CCK - Método desenvolvido por Chang, Cheng e Khorana (2000);
CFTC - Commodities Futures Trading Commission (Comissão de Negociação de Contratos Futuros de Commodities);
CGARCH - Component GARCH (GARCH de componente);
CH - Medida proposta por Christie e Huang (1995);
CK - Cokurtosis (cocurtose);
CLOAK - CloakCoin;
CoVar - Vetores autorregressivos condicionais;
CRIX - CRyptocurrency IndeX;
CRW - Crown;
CS - Coskewness (coassimetria);
CSAD - Cross-Sectional Absolute Deviation (Desvio absoluto transversal dos retornos);
CSC - CassinoCoin;
CSGARCH - Component SGARCH (SGARCH de componente);
CSSD - Cross-Sectional Standard Deviation (Desvio padrão transversal dos retornos);
CV - Cross-validation (validação cruzada);
CVM – Comissão de Valores Mobiliários;
CVol - Covolatility (covolatilidade);
DA - Desvio absoluto;
DAG - Directed acyclic graph (Grafos acíclicos dirigidos);

DASH - Dashcoin;
DCC MGARCH - Dynamic Conditional Correlation multivariate GARCH (GARCH multivariado de correlação condicional dinâmica);
DGB - DigiByte;
DMD - Diamond;
DOGE - Dogecoin;
EGARCH - Exponential GARCH (GARCH exponencial);
EMC2 - Einsteinium;
ES - Expected Shortfall;
ETF - Exchange Traded Funds (fundos de índices);
ETH - Ethereum;
FCV - Full cross-validation (validação cruzada total);
FIC - Fração institucional de compra;
FIGARCH - Fractionally Integrated GARCH (GARCH integrado fracionado);
FLO - FlorinCoin;
FR - Teste desenvolvido por Forbes e Rigobon (2002);
FTC - Feathercoin;
GAME - GameCredits;
GARCH - Generalized autoregressive conditional heteroskedasticity (ARCH generalizado);
GCV - Generalized cross-validation (validação cruzada generalizada);
GFCV - Generalized Full cross-validation (validação cruzada generalizada total);
GJRGARCH - Glosten-Jagannathan-Runkle GARCH;
GRS - Groestlcoin;
HAR - Heterogeneous Autoregressive (modelo Autorregressivo Heterogêneo);
HQ - Critério Hannan e Quinn;
HS – Teste de efeito manada de Hwang e Salmon (2004)
ICO - Initial Coin Offer (oferta inicial de moeda);
IGARCH - Integrated GARCH (GARCH integrado);
IoT - Internet of Things (internet das coisas);
ITO - Inicial Token Offer (oferta inicial de token);
LSV - método de medida de Lakonishok, Shleifer e Vishny (1992);
LTC - Litecoin;
MAID - MaidSafeCoin;
MIOTA - IOTA;
MIT - Massachusetts Institute of Technology (Instituto de Tecnologia de Massachusetts);
MONA – Monacoin;
MSARCH - Markov Switching ARCH (Modelos Markovianos de mudança de Estado ARCH);
MSGARCH - Markov Switching GARCH (Modelos Markovianos de mudança de Estado GARCH);
MSIH - Markov Switching Intercept Heteroskedasticity (Modelos Markovianos de mudança de estado no intercepto e na variância);
MSM - Markov Switching Multifractal (Modelos Markovianos com Mudança de Estado Multifractal);

NAGARCH - Nonlinear Asymmetric GARCH (GARCH não-linear assimétrico);
NAV - Navcoin;
NGARCH - Nonlinear GARCH (GARCH não-linear);
NLG - Gulden;
NMC - Namecoin;
NVC - Novacoin;
NXS - Nexus;
OECD - Organização para a Cooperação e Desenvolvimento Económico;
p2p - peer-to-peer (par-a-par);
PFT - Positive Feedback Trading (Feedback Trading positivo);
POT - PotCoin;
PoW - Proof of Work (Protocolo de Prova de Trabalho);
PPC - Peercoin;
RDD - ReddCoin;
SEC - Securities and Exchange Commission (Comissão de Títulos e Câmbio dos Estados Unidos);
SGARCH - Standard GARCH (GARCH padrão);
SP500 - Standard and Poor's 500;
SW - Teste desenvolvido por Sentana e Wadhwani (1992);
SYS - Syscoin;
TCC - Teste de cobertura condicional;
TCI - Teste de cobertura incondicional;
TGARCH - Threshold GARCH (GARCH limiar);
TI - Teste de independência;
UBQ - Ubiq;
UNO - Unobtanium;
USDT - Thether Dollar;
VaR - Value at Risk (Valor em Risco);
VAR - Vetores autorregressivos;
VE - Volatilidade Estocástica;
VIA - Viacoin;
VTC - VertCoin;
XCP - Counterparty;
XDN - DigitalNote;
XLM - Stellar Lumens;
XMR - Monero;
XPM - PrimeCoin;
XRP - Ripple;
XVG - Verge;
XWC - WhiteCoin.

1 Introdução Geral

Os criptoativos surgem como uma das principais inovações na área financeira e tecnológica do século XXI. Como observa Extance (2015), são moedas completamente descentralizadas, sem bancos ou regulações de governos que possam intervir em seu controle e vem chamando atenção de investidores, governos, empresas e acadêmicos. Apesar da era das moedas digitais ter se iniciado em 2009 com o Bitcoin, segundo o *website* Blockchain.info, somente em 2010 o Bitcoin começou a apresentar um valor de mercado acima do esperado (com uma capitalização de US\$ 277.567). Um ano mais tarde, o valor de mercado já havia saltado para US\$ 81.725.531, apontando um aumento de 29.444%.

Tendo em vista a crescente valorização das moedas (CIAIAN, RAJCANIOVA E KANCS, 2016; ALBUQUERQUE E CALLADO, 2015; HAUBRICH, 2014; ROGOJANU E BADEA, 2014; YERMACK, 2015), que denotam sua importância comercial e financeira, um dos pontos mais importantes a ser explorado é a volatilidade das mesmas - a fim de estimar a faixa de preços em que o ativo poderá oscilar no futuro. É importante acrescentar que, no meio financeiro, a volatilidade atua como sendo uma medida fundamental para realizar estimações para análises de mercado.

Adicionalmente à volatilidade, entender o processo de tomada de decisão dos diversos participantes do mercado digital é um grande desafio tanto para acadêmicos, profissionais de mercado, empresas, órgãos reguladores e agentes governamentais. Com a contínua interação advinda da globalização e da massificação tecnológica oriunda das moedas digitais, uma das consequências é uma interligação cada vez maior, dado a elevação dos fluxos de capitais internacionais. Nesse contexto, fenômenos atípicos de caráter comportamental começam a tomar forma neste mercado e serem identificados como possíveis influenciadores da volatilidade de ativos, sendo os principais exemplos: o efeito manada, efeito contágio e o efeito de *feedback trading*.

O efeito manada ou comportamento de manada entre os investidores vem sendo uma explicação comportamental popular para o excesso de volatilidade e tendências de curto prazo observadas nos mercados financeiros, sendo alvo de diversos estudos empíricos (LAKONISHOK, SHLEIFER E VISHNY, 1992; CHRISTIE E HUANG, 1995; CHANG, CHENG E KHORANA, 2000; HWANG E SALMON, 2004; DEMIRER, KUTAN E CHEN, 2010; YAO, MA E HE, 2014; GALARIOTIS, RONG E SPYROU, 2015; ECONOMOU, KATSIKAS E VICKERS, 2016; BENSÁIDA, 2017; KABIR E SHAKUR, 2018; entre outros). Desta maneira, em função do comportamento de manada gerar desvios de preços e criar implicações para estratégias de negociação e para modelos de precificação de ativos, tem recebido grande atenção nos últimos anos, mas ainda não explorado com profundidade no mercado de criptoativos.

Já o efeito contágio, definido pelo Banco Mundial como o processo de choque transmitido entre países, considerando comovimentos de mercados que aumentam a correlação entre economias distintas, é alvo de estudos desde a década de 1990 com grandes crises globais e seu conseqüente impacto sistêmico em diversas economias - como os estudos de Engle, Ito e Lin, (1990), Bekaert e Hodrick (1992), Dungey e Zhumabekova (2001), Basu (2002), Pericoli e Sbracia (2003), Beirne et al. (2009), Longstaff (2010), Bekaert et al. (2014), Sahalia, Cacho-Diaz e Laeven (2015), Silva et al. (2016), Nguyen, Bhatti e Henry (2017), Casarin, Sartore e Tronzano (2018), entre outros. Assim como o efeito manada, o efeito contágio ainda foi pouco explorado no mercado de criptoativos e passa a ser influenciado por proibições ou aceitações por países, notícias de grandes empresas que utilizam ou aceitam estas moedas, entre outros. Sendo importante complementar que o efeito manada tende a acentuar o efeito contágio, seja em qualquer mercado (CIPRIANI E GUARINO, 2008).

O efeito de *feedback trading*, na área de finanças comportamentais, tem como objetivo indicar até que ponto as informações passadas influenciam na tomada de decisões futuras, identificando também a racionalidade das decisões dos investidores (WOOD, MCLNISH E ORD, 1985; KARPOFF, 1987; CHEN E ZHOU, 2001; LEE E RUI, 2002; ARNOLD, 2009; entre vários outros). Kramer (2001), por exemplo, aponta que o otimismo ou pessimismo desempenham um papel importante no padrão de retorno e também podem desempenhar papéis importantes na geração de retornos futuros, na volatilidade e no volume de ativos

do mercado. Outro fator importante é a disponibilidade de negociações *on-line* automatizadas para investidores desinformados, que traz duas tendências: aumento da participação no mercado e aumento da troca de *feedback trading* (BARBER E ODEAN, 2001).

Este trabalho está dividido em três ensaios:

- **Primeiro Ensaio:** Avaliação de Estados de Volatilidade em Criptoativos.

No que se refere ao primeiro ensaio, este trabalho contribui para analisar mudanças de estados na volatilidade de 50 das moedas digitais mais líquidas do mercado digital por meio de análises econométricas, auxiliando na análise de viabilidade de utilização da moeda para aplicação de suas tecnologias, para investimentos e, inclusive, para processos operacionais de desenvolvimentos em empresas (tendo efeito de redução de custos operacionais, agilidade de pagamentos e recebimentos, além da redução da burocracia bancária) - para facilitar o entendimento do leitor, o termo criptoativos será generalizado para a amostra deste trabalho (também lembrando a existência de *tokens* e criptomonedas neste respectivo mercado).

A metodologia explorada neste primeiro ensaio aborda o MSGARCH (KLAASSEN, 2002). Sendo um modelo flexível, ele é utilizado para modelar séries no qual a transição entre estados é realizada por meio de uma variável aleatória. Vários estudos apontam uma melhor *performance* de análise de volatilidade do MSGARCH em comparação ao regime único do GARCH (como MARCUCCI, 2005; ARDIA, 2008; BAUWENS, PREMINGER E ROMBOUTS, 2010; BAUWENS, BACKER E DUFAYS, 2014). Em virtude da ampla aceitação do modelo de regime de Markov, esta modelagem considera a incorporação da mudança de estado de volatilidade em modelos de variância condicional. O período utilizado na análise foi de 2015 – 2018. Em relação a projeção de volatilidade, para se testar a acurácia das previsões foram avaliadas as funções perda EQM e QLIKE, bem como o MAE, MAPE e o indicador U de Theil.

Os resultados do primeiro ensaio são importantes para: as empresas, na medida que se coloca em pauta a questão de redução de custos, otimização, agilidade e segurança em operações de pagamento ou recebimento; os *traders*, que podem operar avaliando questões ligadas ao apreçamento de produto, tendências e

previsões (utilizando modelos de volatilidade mais adequados); pessoas físicas ao realizarem compras ou contratarem serviços; Bancos, que devem avaliar medidas de custos de operações em função de uma tendência de utilização de moedas digitais; e Instituições Governamentais, na medida em que com o aumento do uso, em um mercado com um volume de bilhões de dólares, comece a impactar na questão fiscal e monetária.

- **Segundo Ensaio:** Efeitos Manada e Contágio no Mercado de Criptoativos.

No que se refere ao segundo ensaio, este trabalho tem como objetivo identificar e analisar os comportamentos de manada e contágio no mercado de moedas digitais, levando em consideração o índice CRIX (CRyptocurrency IndeX) no mesmo conjunto de 50 criptoativos de maior valor de mercado e liquidez, que possuem o mesmo histórico de dados deste índice com um período de 2015 – 2018. Apesar de existirem mais de 2.000 moedas digitais, a maioria é recente, surgiram no início de 2017 e por conta disso possuem uma pequena série histórica para se analisar os dados de maneira conjunta e comparativa.

As metodologias aplicadas para avaliação do efeito manada compreendem modificações das abordagens clássicas de se medir o efeito manada desenvolvido por Christie e Huang (1995) do desvio padrão transversal dos retornos ou CSSD (*Cross-Sectional Standard Deviation*) e a abordagem de Chang, Cheng e Khorana (2000) da distribuição de retornos do mercado com o CSAD (*Cross-Sectional Absolute Deviation*); bem como a generalização dos modelos clássicos baseado no filtro de Kalman seguindo estudo de Hwang e Salmon (2004). Já para avaliar o efeito contágio, foram realizadas modificações nos testes de contágio paramétrico de Forbes e Rigobon (2002) e em suas extensões considerando momentos de ordem superior elaboradas por Fry, Martin e Tang (2010) e Fry-McKibbin e Hsiao (2018).

A importância em realizar este segundo estudo, no que se refere ao efeito manada, se justifica em: entender distorções nos preços dos criptoativos (que por exemplo, podem gerar “bolhas” – como visto em CHEUNG, ROCA E SU, 2015); compreender a dinâmica e relação entre as moedas digitais; avaliar aceitação de políticas regulatórias de governos e transparência de informações de empresas no mercado de moedas digitais, entre outras. Já para o efeito contágio, são destacadas na literatura a importância do estudo para a gestão de carteiras e nos processos de

diversificação de riscos, bem como os subsídios aos formuladores de políticas monetárias (já que a realidade dos criptoativos avança nas mais diversas frentes econômicas), entre outras.

- **Terceiro Ensaio:** O Efeito do *Feedback Trading* no Mercado de Criptoativos.

No que se refere ao terceiro ensaio, este trabalho tem por objetivo avaliar um fenômeno comportamental conhecido como efeito *feedback trading* no mercado de moedas digitais envolvendo os 50 maiores criptoativos utilizados nos ensaios anteriores no período de 2015 – 2018. O intuito foi entender se os investidores neste mercado utilizam dados passados para tomar decisões futuras e avaliar a presença de investidores racionais e *noise tradres*. No caso do comportamento errático (comprar na alta e vender na baixa), a presença do chamado *noise trader* pode existir e impactar de maneira negativa – podendo, inclusive, afetar a eficiência do mercado.

A metodologia empregada neste trabalho engloba o modelo seminal de *feedback trading* de Sentana e Wadhvani (1992), que incorpora as inovações trazidas por Bollerslev (1986) com o modelo GARCH. Para avaliar a robustez do GJR GARCH (1,1), foi realizado o teste de viés de sinais de Engle e Ng (1993), que examina se existe assimetria na volatilidade após choques positivos e negativos, não explicados pelo modelo GARCH utilizado.

Entender o comportamento de *feedback trading* no mercado digital se torna importante pois o acompanhamento de tendências amplifica as flutuações de preços de ativos neste mercado em qualquer direção, e isto pode enviesar modelos com *traders* racionalmente limitados e em horizontes curtos - como pode ser visto em Abreu e Brunnermeier (2003) e Brunnermeier e Pedersen (2005) para o mercado de ações. Além do que, a negociação baseada em *feedback trading* sempre induz pressões líquidas de venda.

No estudo de De Long, et al. (1990), os autores apontam que os investidores que geram o efeito de *feedback trading* tentam descobrir tendências nos preços das ações passadas e tomar suas decisões de investimento na esperança de que essas tendências persistam. Uma consequência desse grande número de operadores de *feedback trading* no mercado é a previsibilidade potencial dos retornos das ações, da volatilidade e do volume. Aliás, é importante acrescentar que tal fenômeno

auxilia a explicar eventos incomuns no mercado como excesso de volatilidade, *momentum* e reversões nos preços de ativos.

Assim, este estudo busca avaliar, por meio destes três ensaios, como estes criptoativos podem ter vieses comportamentais e nuâncias de volatilidade que, diferente de ativos comuns, possam apresentar uma ameaça para investidores inexperientes, empresas que operam com estas moedas, Bancos, instituições financeiras e até mesmo para os Governos (já que estas moedas possuem particularidades que podem impactar diretamente em políticas monetárias, evasão de divisas, entre outras). Inclusive, no Brasil, o Banco Central do Brasil (BACEN) apontou nos comunicados N° 25.306/14 e N° 31.379/17 a preocupação com tais moedas e a Comissão de Valores Mobiliários (CVM) por meio da instrução N° 555/14 não qualifica estes ativos para negociação direta em bolsa ou fundos no Brasil – apenas com negociação de forma indireta por meio de outros mercados em que são permissíveis.

2

Primeiro Ensaio: Avaliação de Estados de Volatilidade em Criptoativos

Desde Nakamoto (2008), uma enorme onda de inovações atingiu o mercado financeiro, acadêmico e tecnológico. Muitos debates e estudos vem sendo levantados a respeito da tipologia destes ativos, das questões de regulamentação, das propriedades estatísticas deste novo mercado de moedas digitais e até mesmo dos modelos apropriados para modelar e prever a volatilidade destas moedas.

Neste primeiro ensaio o principal foco está na previsão de volatilidade dos 50 maiores criptoativos. Também serão avaliadas questões inerentes ao modelo MSGARCH (melhor descrito ao longo do ensaio), cuja dinâmica engloba estados de volatilidade distintos e os próprios parâmetros gerados pelo modelo que serão avaliados ao longo do período de 2015 – 2018.

Como visto em Hamilton e Susmel (1994), um grande número de estudos empíricos apontam uma *performance* pobre e uma persistência fraca de previsão em modelos baseados apenas em um estado de volatilidade. Li e Lin (2003, 2004) observam que os modelos ARCH e GARCH possuem uma configuração de volatilidade linear e podem ser menos eficazes para estudos sensíveis às mudanças de volatilidade do que os modelos MSGARCH.

Os autores ainda apontam que o MSGARCH se propõe controlar a persistência do estado de volatilidade através da configuração da cadeia de Markov, logo, os modelos do tipo MS incorporam as variáveis de estado para controlar as mudanças estruturais no período de teste e mitigar os problemas de persistência para estimar a volatilidade nos modelos ARCH e GARCH.

Neste ensaio, o trabalho foi direcionado da seguinte forma: pretende-se explorar os 10 maiores criptoativos da série de 50 que foi coletada no final de 2018 (as chamadas “Top 10” tendem a se manter próximo a liderança do *ranking* ao longo do tempo), os principais estudos de volatilidade de criptoativos publicados até o momento e os modelos markovianos de mudança de estado de volatilidade; posteriormente será descrita a metodologia; análise de resultados; e a conclusão.

2.1 Principais Moedas do Mercado Digital

Com a criação do Bitcoin, inúmeras moedas digitais começaram a surgir, algumas com tecnologias disruptivas e inovadoras e outras como meras cópias ou esquemas de pirâmide (conhecidas como *fake coins*). Atualmente existem mais de 2.000 moedas digitais registradas no mercado digital segundo o *website* *cryptocompare*, mas para a relevância apontada anteriormente neste estudo, foram tomadas as moedas com maior grau de liquidez, capitalização de mercado e relevância (que se tornaram grande destaque dentre o vasto número de moedas digitais).

De forma resumida, são apontadas 10 das principais moedas da lista das 50 que foram ranqueadas neste trabalho - abordando sucintamente sua história, diferencial e funcionalidade - optou-se por falar a respeito das 10 maiores porque as mesmas tendem a se manter no topo de ranqueamento ao longo do tempo e as demais podem ser modificadas.

O **Bitcoin**, como observado em Negurita (2014), é a primeira implementação de um conceito chamado de criptoativo que foi descrito por Nakamoto (2008) sugerindo a ideia de uma nova forma de dinheiro que usa criptografia para controlar sua criação e as transações, dispensando uma autoridade central. Implementado oficialmente em 2009 por um grupo ou programador com o pseudônimo Satoshi Nakamoto, este criptoativo iniciou uma nova era que se baseia em agilidade de pagamentos, desburocratização e redução de custos. Até dias atuais, os usuários de moedas digitais têm crescido exponencialmente com muitos desenvolvedores (já que a moeda possui ampla utilização em inúmeras áreas com uma tipologia geral de desenvolvimento) e atualmente, o Bitcoin é a moeda digital com maior liquidez e valor de mercado.

Esta moeda revolucionária trouxe a ideia de compartilhamento de processamento e segurança por meio da *blockchain* (um banco de dados distribuído que guarda um registro de transações permanente e à prova de violação) - sendo comprovadamente mais seguro do que o sistema de muitos bancos da atualidade. Extance (2015), Maftai (2014), Negurita (2014), Little (2014), Bryans (2014), Hurlburt e Bojanova (2014), Brito e Castillo (2013), Iavorschi (2013) observam que o Bitcoin funciona seguindo o processo par-a-par (também conhecido como *peer-*

to-peer), que é um formato de rede de computadores no qual a principal característica é descentralização das funções convencionais de rede, onde o computador de cada usuário conectado acaba por realizar funções de servidor e de usuário ao mesmo tempo, sem a necessidade de uma terceira parte.

O **Ethereum**, como visto no Ethereum.org, também conhecido por Ether foi desenvolvido em 2013 e chegou ao mercado em 2014. Seus criadores a chamam de criptocombustível, e seu objetivo inicial é o de executar contratos inteligentes, ou seja, contratos baseados em criptografia. A diferença básica entre o Ethereum e o Bitcoin é que o primeiro permite que os desenvolvedores criem aplicações sem a necessidade de desenvolver sua própria *blockchain* (em meio a *softwares* de *blockchain* públicos e privados). Na formação de blocos, enquanto o Bitcoin leva 10 minutos, o Ethereum leva cerca de 14 – 15 segundos.

Vitalik Buterin, o criador do Ethereum, apontou desde a criação desta moeda que esta ideia foi implementada pelo desejo de se criar um protocolo em que as soluções na *blockchain* fossem mais ágeis e menos complexas, na medida em que o protocolo do Bitcoin (de maneira comparativa) gastava esforços desnecessários na construção de uma infraestrutura equivalente. Assim, com o Ethereum, pôde-se criar a primeira aplicação universal dos princípios subjacentes ao Bitcoin.

Ao invés de se utilizar a *blockchain* como forma de estabelecer/fornecer valor, o Ethereum oferece a capacidade de usar essa tecnologia em um ambiente com a capacidade de se criar aplicativos universais. Um outro ponto comparativo ao Bitcoin é o seu limite universal de 21 milhões de unidades enquanto o fornecimento de ETH é limitado anualmente em 18 milhões de ETH, mas não há limite estabelecido além disso. Atualmente esta é a segunda moeda digital mais líquida e em conjunto com o Bitcoin lideram mais da metade de todo o investimento em moedas digitais do mercado global.

O **Ripple**, segundo o RippleNet, é um sistema distribuído de pagamento de código aberto com o objetivo de libertar as pessoas dos “muros” criados pelas redes financeiras, ou seja, bancos, operadoras de cartão de crédito, paypal e outros que restringem o acesso às redes de pagamentos por conta de taxas, encargos com operações cambiais e demora para o processamento das operações.

Como visto no OpenCoin, seus fundadores Chris Larsen e Jed McCaleb desenvolveram a moeda com este nome como uma metáfora, alusão de se manter o dinheiro fluindo livremente. Com início de sua comercialização em 2013, esta

moeda aparece não como uma rival ao Bitcoin, mas como um complemento, projetada para transferir de maneira transparente qualquer forma de moeda, inclusive, as já utilizadas por diversos bancos (como por exemplo o Bank of America, CBW Bank, Santander), com o intuito de oferecer transações instantâneas com menores tarifas.

Atualmente existem 100 milhões de ripples, sendo que cerca de metade desta quantidade foi liberada para circulação e a outra metade é de propriedade da empresa controlada pelos sócios fundadores, ou seja, ao contrário do Ethereum e Bitcoin, esta moeda não é descentralizada.

A **Stellar** se propõe ser uma moeda baseada em uma plataforma multi-transacional de moedas correntes (como dólar, euro, libra, etc.), permitindo que as pessoas enviem e recebam moedas legalizadas rapidamente, com taxas baixas, dentro de uma *exchange*. Diferente do Bitcoin, o método de confirmação das transações é baseado no algoritmo de Prova de Consenso, em vez do PoW (*Proof of Work*) do Bitcoin.

Como visto no stellar.org, o criador da Stellar (Jed McCaleb) é um dos fundadores da Ripple e da *exchange* Mt. Gox. Jed saiu do projeto Ripple em 2013 e lançou o projeto Stellar em 2014. Em alguns aspectos a tecnologia utilizada nas transações da Stellar se assemelha à da Ripple, porém em uma versão descentralizada (pois a Ripple é uma moeda centralizada, voltada para bancos). A tecnologia e a proposta do projeto Stellar acabou rendendo em 2017 uma parceria com a empresa IBM.

Existem cerca de 100 bilhões de moedas criadas e todos os anos, há uma taxa de inflação de 1% (novos lúmens não podem ser gerados arbitrariamente por ninguém). A ideia é tornar a moeda uma facilitadora entre os demais pares de moedas da plataforma Stellar. Ao contrário de outros criptoativos onde o usuário baixa a carteira para seu *desktop*, a Stellar não oferece a versão *off-line* da carteira, ou seja, a carteira é via *web* ou *on-line* (ficam na internet).

O **Litecoin**, assim como observado no Litecoin.org, foi desenvolvido em 2011 e comercializado na bolsa Mt. Gox em 2013, sendo inspirado no Bitcoin. O Bitcoin é considerado por muitos como o irmão mais velho do Litecoin e estas moedas possuem mais semelhanças do que diferenças. As principais diferenças em relação ao Bitcoin, são: que os blocos do Litecoin são formados a cada 2,5 minutos; a produção do Litecoin é limitada em 84 milhões de unidades.

Seu fundador, Charles Lee, decidiu reescrever o Bitcoin buscando corrigir algumas das falhas que via no desenvolvimento desta moeda criptográfica. Lee tentou lançar a moeda Fairbrix, que fracassou por conta de instabilidades técnicas. Em 2011, ele conseguiu desenvolver um produto mais aperfeiçoado, que viria a ser conhecido como Litecoin e seria futuramente simbolizado pela prata, em oposição ao ouro no qual o Bitcoin se inspira. A ideia é justamente essa, ser a prata para o ouro do Bitcoin – ou seja, uma opção mais leve e abundante. O Litecoin também tem a vantagem quando se trata de escalabilidade. O Litecoin é mais adaptável às mudanças e melhorias em comparação com Bitcoin.

O **Monero**, de acordo com o GetMonero.org, é um criptoativo descentralizado lançado em 2014, e tem como objetivo não ser rastreável, conferindo uma maior privacidade que o Bitcoin. O Monero não foi criado usando o código do Bitcoin. Ao invés disso, esta moeda é baseada em um protocolo chamado *cryptonote*, que foi descrito pela primeira vez em um relatório de 2012 por Nicolas von Saberhagen, um provável pseudônimo, tal como Satoshi Nakamoto.

Embora o Monero tenha algumas similaridades com o Bitcoin, entre elas a mineração e a estrutura da *blockchain* como chave de seu funcionamento, ele tem algumas grandes diferenças que ajudam seus usuários a manter o anonimato *online*. O Monero cria um endereço único para cada transação, com uma senha privada que apenas permite que as informações completas da transação sejam vistas pela pessoa que recebeu o depósito e por outras pessoas com quem o usuário decidir compartilhar a senha (uma assinatura digital conhecida como *ring signature*).

Em comparação com outras moedas que possuem anonimato o Monero é de longe a melhor. Ao ser comparado com o Dashcoin, por exemplo: os detalhes financeiros dos endereços desta moeda são visíveis para qualquer um que examine a cadeia de blocos e como as transações são encaminhadas através de uma série de *masternodes*, caso um governo, um grupo de *hackers*, outra entidade ou mesmo um indivíduo comprassem muitos *masternodes* (não haveria nenhuma maneira de saber se isso ocorreu), e se a transação passasse por uma rota onde todos os *masternodes* eram de propriedade destes grupos, então a transação poderia ser rastreada (dado o custo relativamente baixo de *masternodes* e o enorme orçamento de governos e algumas organizações, a possibilidade de as moedas serem rastreadas é real).

O **Tether Dollar**, segundo o Tether.to, utiliza o protocolo Omni e está construído sobre a *blockchain* do Bitcoin. Ele tem como lastro a moeda fiduciária do dólar norte-americano, de modo que 1 USDT representa um dólar americano, mantido em reserva pela empresa por trás do projeto Tether. A referida empresa foi fundada por Brock Pierce e Stanley Hainsworth em 2008 e a moeda foi lançada em 2013. O Tether encontrou alguns problemas bancários há algum tempo já que a empresa usa um banco taiwanês para receber e enviar retiradas do USD - esse banco apresentou alguns problemas, resultando na incapacidade da empresa de converter USD para USDT e vice-versa (obrigou os usuários a confiarem em trocas de terceiros para completar este processo de conversão).

A disparidade no valor do Tether dollar em relação ao dólar americano começou depois que o banco americano Wells Fargo parou de pagar as transações de saída de seus bancos correspondentes em Taiwan. O mesmo problema foi experimentado pela Bitfinex, que em algum ponto até levou a uma ação judicial contra Wells Fargo. Atualmente a moeda encontra-se na lista das *stable coins* do mercado de moedas digitais.

O **Dashcoin**, segundo o Dash.org, originalmente foi lançado em 2014 como XCoin e em 2015 teve uma mudança de nome para Darkcoin. De maneira análoga ao Litecoin, também apresenta grande similaridade com a tecnologia do Bitcoin. Uma das diferenças do Dash é que o mesmo possui uma tecnologia chamada de *masternodes*, que se beneficia de uma rede paralela que garante uma maior privacidade dos usuários do que o Bitcoin, ao mesmo tempo que possibilita a implementação de inúmeros serviços, funções e aprimoramentos, dando ainda uma maior segurança a todo o sistema.

Evan Duffield, o criador e arquiteto chefe do Dash desenvolveu esta moeda como uma evolução a partir do Bitcoin, corrigindo falhas e aperfeiçoando-se para se tornar o *digital cash*, uma tecnologia que devolve ao cidadão sua soberania financeira, liberdade e privacidade em suas transações. O usuário passa a ser responsável pela segurança de seu dinheiro, e é esse o maior detalhe: não existe mais a dependência de terceiros com a tecnologia do *masternode* (são *nodes* ou pontos da rede Dash, criados pelos próprios usuários dessa rede, que tem a função específica de prestar o serviço de *coin mixing*), assim, as transações se tornam anônimas, livres e independentes.

O **Dogecoin**, de acordo com o Dogechain.com, foi criado pelo programador Billy Markus, em 2013 com o objetivo inicial de criar um criptoativo divertido que pudesse atingir um público mais amplo do que o Bitcoin - com um “meme” do cachorro Shiba Inu (entrou no mercado como uma piada do Bitcoin). Markus baseou o Dogecoin em um criptoativo existente, Luckycoin, que apresenta uma recompensa aleatória que é recebida para a mineração de um bloco, embora esse comportamento tenha sido posteriormente alterado para uma recompensa de bloco estático em março de 2014.

Ainda que poucas aplicações comerciais tradicionais partam do Doge, a moeda ganhou força como um sistema de gorjetas na internet, no qual os usuários de mídia social concedem dicas à Dogecoin para outros usuários por fornecer conteúdo interessante ou digno de nota. O Dogecoin se baseia no protocolo Bitcoin, mas com modificações. Ele utiliza um algoritmo *scrypt* e tem 100 bilhões de unidades, sem teto para o número de unidades emitidas em um dado momento. O tempo de bloco é de 60 segundos e a dificuldade se reajusta a cada quatro horas, porém, o ecossistema do DOGE é suportado apenas por seus usuários voluntários, sem uma equipe dedicada para apoiá-lo.

O **BitShares** foi criado em 2014 por Dan Larimer (co-fundador do Steem, EOS e do CTO), e Charles Hoskinson (co-fundador do Ethereum e Cardano). O BitShares é um criptoativo descentralizado que faz parte da *blockchain* do Microsoft Azure e, como visto no bitshares.org, a moeda funciona também como uma *exchange* descentralizada, que permite trocar moedas mais voláteis por mais estáveis, como o BitAssets - atrelado às principais moedas do mundo real (como dólar, euro etc). BitShares já representa a próxima revolução da economia colaborativa com a *blockchain*. Ao contrário do Bitcoin, o objetivo principal do BitShares não é ser uma moeda *peer-to-peer* (p2p), mas uma *exchange* descentralizada - construído sobre a rede *blockchain* Graphene, que permite que transações sejam efetuadas em apenas 3 segundos.

2.2 Estudos Relevantes sobre Volatilidade de Criptoativos

Existem poucos estudos que avaliam a volatilidade de moedas digitais ou demais relações de preços envolvendo as mesmas, por se tratar de um tema recente

no mundo acadêmico. Como visto anteriormente, as moedas digitais surgiram em 2009 e apenas por volta de 2015 – 2016, começaram a ganhar visibilidade e público. Chu et al. (2017) observam que a maior parte dos estudos existentes é baseado apenas no Bitcoin e particularmente na modelagem GARCH (como apontado pelos autores, a modelagem mais popular para moedas tradicionais e taxas de câmbio).

Dwyer (2015), analisou o desvio dos retornos logarítmicos diários do Bitcoin em três bolsas distintas e aponta que a média dos desvios é de 7,2% por dia para a bolsa MtGox (que foi desativada), 5,1% por dia para a bolsa BTCE e 5,5% por dia para a Bitstamp de janeiro de 2011 até fevereiro de 2014. Os valores máximos do desvio foram de 17% em junho de 2011 na MtGox, 16,52% em abril de 2013 na BTCE e 16,2% em outubro de 2010 na Bitstamp. Os valores mínimos foram de 1,1% na MtGox, 0,9% na BTCE e 1,0% na Bitstamp. O autor concluiu que a volatilidade média mensal de retornos sobre Bitcoin é maior do que o ouro ou de um conjunto de moedas estrangeiras em dólares, mas as menores volatilidades mensais para o Bitcoin são menores que as mais altas volatilidades do ouro e das moedas.

Bouoiyour e Selmi (2015) analisaram durante o período de 2010 – 2015 o comportamento dos preços do Bitcoin por meio da otimização do modelo GARCH considerando a utilização de um modelo “ótimo” por meio dos critérios AIC (AKAIKE, 1974), BIC (critério de SCHWARZ, 1974) e HQ (critério de HANNAN E QUINN, 1989). Os autores identificaram o TGARCH (Threshold-GARCH) como o melhor modelo, que considera quebras estruturais na volatilidade, enquanto a volatilidade segue um processo GARCH dentro de cada regime. Os resultados apontaram para uma grande volatilidade do preço do Bitcoin e indicaram que a variância condicional tende a seguir um processo de memória longa durante o período e que existe uma maior influência dos choques negativos do que os positivos.

Letra (2016) avaliou o impacto da influência de ferramentas de pesquisas e mídias sociais (como Google Trends, Wikipedia e tweets do Twitter) no preço do Bitcoin durante o período de 2011 – 2015. Para tanto, o autor utilizou a modelagem GARCH (1,1) e descobriu que tanto os dados de conteúdo da *web* quanto os preços anteriores do Bitcoin têm um impacto significativo na volatilidade do Bitcoin. Ou seja, o autor concluiu que os preços do Bitcoin são influenciados por sua popularidade e também notou a presença de *noise traders*, percebendo que o

aumento do volume de negociações e tomada de decisões pouco eficientes (no ponto de vista racional) podem fomentar alta volatilidade no preço do Bitcoin.

Barbosa (2016), realizou um estudo de volatilidade comparada entre o Bitcoin e algumas moedas como real, euro, dólar canadense, iene, yuan e peso mexicano durante o período de fevereiro de 2012 até janeiro de 2016. Para avaliar a interação entre as moedas, o autor utilizou o modelo IGARCH. O autor verificou que o Bitcoin possuía uma volatilidade 5,3 vezes maior que a do Euro, 4,5 vezes maior que a do dólar canadense, 3,9 vezes maior do que a do peso mexicano, 3,0 vezes maior que a do Iene, 2,2 vezes maior do que a do real e 4,3 vezes maior do que uma carteira de moedas elaborada pelo autor – o yuan foi retirado da amostra por problemas de ajuste em relação as demais.

Dyhrberg (2016) analisou relações entre o Bitcoin com o dólar e o ouro considerando os modelos GARCH. Os dados utilizados contemplaram o período de 2010 – 2015 com dados do Bitcoin retirados da base Coindesk e os demais dados da base Datastream. O autor encontrou várias semelhanças entre o Bitcoin com o ouro e o dólar indicando possibilidades de *hedge*. O GARCH assimétrico mostrou que o Bitcoin pode ser útil no gerenciamento de risco e ideal para investidores avessos ao risco em antecipação a choques negativos no mercado. O autor, por fim, concluiu que o Bitcoin tem um lugar nos mercados financeiros e na gestão de portfólio, pois pode ser classificado como um ativo intermediário entre o ouro e o dólar.

Katsiampa (2017) estudou a volatilidade do Bitcoin comparando modelos da família GARCH. Foram usados dados de 2010 – 2016 contendo 2.267 observações da base Coindesk. Foram utilizados modelos como GARCH, EGARCH, TGARCH, ARCH com poder assimétrico (APARCH), GARCH componente (CGARCH) e GARCH com componente assimétrico (ACGARCH). Verificou-se que o melhor modelo é o modelo AR (1) – CGARCH (1,1), destacando o significado de incluir um componente de curto e longo prazo da variância condicional.

Bouri, Azzi e Dyhrberg (2017) examinam a relação entre os retornos dos preços e as mudanças na volatilidade do Bitcoin durante a queda de 2013 relacionado com várias moedas correntes (dólar, euro libra, yen, entre outras). Os resultados apontaram uma relação inversa e significativa entre choques passados e volatilidade no período antes da queda de mercado e nenhuma relação significativa depois da queda de mercado. Esta constatação mostrou que, antes do *crash* dos

preços de dezembro de 2013, os choques positivos aumentaram a volatilidade condicional mais do que os choques negativos (o inverso visto no mercado de ações).

Urquhart (2017) realizou uma análise no Bitcoin estudando previsões de modelos GARCH e de alta frequência (HAR) com dados de 2012 – 2016, provenientes do Bitcoincharts. Não foram encontradas evidências do efeito alavancagem na volatilidade do Bitcoin e de que os modelos HAR são superiores aos modelos GARCH tradicionais na modelagem deste ativo. Foi notado que a inclusão dos saltos e os componentes contínuos dos modelos HAR adicionam mais informações aos modelos.

Stavroyiannis e Babalos (2017) analisaram as propriedades dinâmicas do Bitcoin e do índice SP500 (da Standard and Poor's), utilizando uma variedade de abordagens econométricas, incluindo modelos GARCH univariados e multivariados e especificações vetoriais autorregressivas. Os resultados da pesquisa indicaram que o Bitcoin na verdade não possui nenhuma das propriedades de *hedge*, diversificação ou de ser algum “porto seguro”, ao invés disso, este ativo exibe atributos intrínsecos não relacionados ao desenvolvimento do mercado norte-americano, representado pela SP500.

Cermak (2017) buscou avaliar até que ponto o Bitcoin pode ser uma alternativa para moedas correntes. De fato, o autor aponta que o Bitcoin atualmente não cumpre os critérios de ser uma moeda porque não funciona como um meio de troca, uma unidade de conta e uma reserva de valor. Para o autor o maior empecílio para o Bitcoin é ter uma elevada volatilidade. Na metodologia, no período de 2010 – 2017, foi utilizado o modelo GARCH (1,1) para analisar a volatilidade do Bitcoin em relação às variáveis macroeconômicas de países onde o Bitcoin foi mais negociado. Como principais achados, notou-se que o Bitcoin já se comporta de forma semelhante a moedas na China, nos EUA e na União Europeia, mas não no Japão.

Bariviera et al. (2017) analisaram a dinâmica do Bitcoin e moedas correntes (Euro e Libra Esterlina) com foco na análise de retornos em diferentes escalas de tempo. O período estudado foi de 2011 até 2017 (com dados diários) e de 2013 até 2016 (com dados intradiários). Alguns pontos interessantes foram observados pelos autores como: apesar do Bitcoin apresentar grande volatilidade, está reduzindo ao longo do tempo; a memória de longo prazo não está relacionada à liquidez do

mercado; o comportamento em diferentes escalas de tempo (5-12h) é essencialmente similar, em termos de memória de longo prazo.

Chu et al. (2017) avaliaram 7 moedas digitais populares (Bitcoin, Dash, Dogecoin, Litecoin, Maidsafecoin, Monero e Ripple), no período de 2014 – 2017, em 12 modelos GARCH distintos baseados no método de máxima verossimilhança - SGARCH, EGARCH, GJRGARCH, APARCH, IGARCH, CSGARCH, GARCH, TGARCH, AVGARCH, NGARCH, NAGARCH e ALLGARCH. Os autores concluíram que os modelos IGARCH e GJRGARCH ofereceram os melhores ajustes, em termos de modelagem da volatilidade.

Baur, Dimpfl e Kuck (2018) fizeram uma replicação do estudo de Dyrhberg (2016) com a mesma amostra e modelos econométricos para replicar os achados e demonstra que a replicação exata não é possível e que os métodos estatísticos alternativos fornecem resultados mais confiáveis, porém muito diferentes. Os autores concluíram que o Bitcoin exibe características de retorno, volatilidade e correlação distintamente diferentes em comparação com outros ativos, incluindo ouro e dólar norte-americano.

Corbet et al. (2018) realizaram uma revisão da literatura com base nos principais tópicos que têm sido associados ao mercado de moedas digitais desde seu desenvolvimento como um ativo financeiro de 2009 - 2018. Os autores observaram que para as metodologias de volatilidade como ARCH e GARCH, os agrupamentos mais comuns incorporam uma análise de rede ou análise de expoente de Hurst (HURST, 1951). Um ponto interessante é que a volatilidade dos preços é frequentemente observada nos períodos em torno de duas características distintas indesejáveis que foram predominantemente associadas às moedas digitais: desorientação reguladora e cibercriminalidade.

Phillip, Chan e Peiris (2018) utilizaram uma análise de corte transversal com uma amostra de 224 moedas digitais diferentes com o objetivo de identificar várias propriedades únicas, incluindo efeitos de alavancagem, distribuições de erros, etc. O número de observações registradas para cada moeda varia, mas todas terminam em 31/07/2017. A análise empírica dos dados mostrou que estas moedas exibem memória longa, alavancagem, volatilidade estocástica e possuem caudas pesadas na distribuição (ou seja, têm uma cauda que vai para zero mais devagar do que uma função exponencial).

Gkillas e Katsiampa (2018) estudaram o comportamento da cauda dos retornos de cinco principais criptoativos (Bitcoin, Ethereum, Ripple, Bitcoin Cash e Litecoin) desde a data mais antiga disponível até 23/10/2017. Empregando análise de valor extremo, estimando VaR (do inglês *Value at Risk*) e o método ES (do inglês, *Expected Shortfall*), como medidas de risco de cauda, os autores descobriram que o Bitcoin Cash é o mais arriscado, enquanto o Bitcoin e o Litecoin são os criptoativos menos arriscados.

Hu et al. (2018) analisaram o comportamento do preço intradiário para negociações com Bitcoin, Litecoin e Ripple. O número de observações registradas para cada criptoativo varia, mas todos terminam em 28/02/2018. Os autores descobriram que os preços das negociações se agrupam em números redondos ao longo do dia e o agrupamento aumenta com o nível de preços e a incerteza de preços. Os autores também apontaram que os preços são formados principalmente devido às negociações e estratégias de negociação, em vez de se basearem em números psicologicamente atraentes.

Mighri e Alsagaf (2019) analisaram o efeito de transbordamento de volatilidade (também conhecido como efeito *spillover*) entre as séries temporais de 3 criptoativos (Bitshares, MonaCoin e Ripple) no período de 01/08/2014 até 27/02/2018. Os autores avaliam a própria volatilidade das moedas, choques, interchoque e transmissão de volatilidade utilizando uma modelagem GARCH multivariada. As descobertas empíricas mostram que o modelo DCC MGARCH (ENGLE, 2002) é preferido em relação aos outros modelos, embora o CCC-MGARCH (com a correlação condicional constante de BOLLERSLEV, 1990) seja uma segunda escolha. Os autores também descobriram que em média, uma posição longa de \$1 em BitShares (BTS) pode ser coberta (*hedged*) por 15% com uma posição vendida em MonaCoin (MONA), enquanto uma posição longa de \$1 em MONA pode ser coberta por 14% com uma posição curta em Ripple (XRP).

Tiwari, Kumar e Pathak (2019) analisaram de maneira comparativa o Bitcoin e o Litecoin no que se refere a modelagem GARCH em relação a modelagem de volatilidade estocástica (VE). Os vários modelos examinados incluíram o GARCH (1,1) e VE com um processo de log-volatilidade AR (1), bem como modelos mais flexíveis com saltos, volatilidade em média, efeitos de alavancagem, inovações de distribuição t e médias móveis. Os resultados apontaram que o melhor modelo para Bitcoin é o VE-t enquanto para o Litecoin é o TGARCH. No geral, a classe t de

modelos tem melhor desempenho que as outras classes para os dois criptoativos. Para o Bitcoin, os modelos VE superam consistentemente os modelos GARCH e o mesmo vale para o Litecoin na maioria dos casos. Finalmente, a comparação dos modelos GARCH com os modelos GJRGARCH revelaram que o efeito de alavancagem não é significativo para estes criptoativos, sugerindo que eles não se comportam como os preços das ações.

Segnon e Bekiros (2019) analisaram a previsão de volatilidade com o Bitcoin no período de 2013 – 2018. Os autores assumiram que o processo de média segue uma média móvel integrada autorregressiva (ARFIMA) e para o processo de variância foram utilizados: o GARCH, o Markov Switching GARCH (MSGARCH) e Markov Switching Multifractal (MSM). Os resultados confirmaram a ocorrência de mudança de estado, memória longa e multifractalidade. Os autores também descobriram que os modelos MSM e FIGARCH superam modelos do tipo GARCH na previsão da volatilidade dos retornos do Bitcoin. Além disso, as previsões combinadas melhoram as previsões de modelos individuais.

Ardia, Bluteau e Rüede (2019) analisaram a presença de mudanças de regime na dinâmica da volatilidade GARCH dos retornos logarítmicos do Bitcoin utilizando o MSGARCH no período de 2011 - 2018. Os autores também compararam o MSGARCH em estados distintos de volatilidade (considerando apenas um estado, dois e três) na previsão de um dia para o VaR. A abordagem Bayesiana foi utilizada para estimar os parâmetros do modelo e calcular as previsões do VaR. Os autores apontaram como principais achados que: existem mudanças de estado de volatilidade para a moeda; ao se avaliar três estados de volatilidade, notaram que para dois estados há um melhor *trade-off* entre qualidade dos testes e a complexidade do modelo; modelos MSGARCH tem um melhor desempenho na previsão do VaR do que os que operam apenas com um regime.

Tendo em vista o caráter rescente da temática das moedas digitais, como dito anteriormente, pretende-se neste trabalho utilizar o modelo MSGARCH com o EGARCH, TGARCH, GJRGARCH e SGARCH para se poder avaliar a volatilidade dos 50 maiores criptoativos com maior liquidez e capitalização de mercado, com o intuito de entender como a volatilidade destas moedas se comportam na mudança de estados de volatilidade, como os parâmetros de volatilidade podem ajudar na compreensão e na previsão destas moedas com

diferentes estados de volatilidade e como funciona a previsão de volatilidade considerando a presença de dois estados de volatilidade para estes criptoativos.

2.3 Modelos Markovianos de Mudança de Estado

Como visto em Oliveira e Pereira (2012), os modelos Markovianos com mudança de estado (*Markov Switching Models*) são uma abordagem utilizada para modelar séries no qual a transição entre estados é realizada por meio de uma variável aleatória não observada, seguindo um processo de Markov (1906). Estes modelos são flexíveis, e podem ser utilizados para se calcular volatilidade de ativos. Como observa Hamilton (1994), as quebras estruturais são endógenas ao modelo.

Os modelos de séries temporais com mudanças de estado Markoviano, introduzido por Goldfeld e Quandt (1973), são modelos dinâmicos, com parâmetros que variam no tempo, de acordo com o estado em que o processo se encontra. Um modelo autorregressivo de ordem p, AR (p), de N estados para os regimes possíveis, $s_t \in \{1,2,3,\dots,N\}$, é denotado por MS (N) – AR (p) e representado pela equação 1.

$$y_t = v_{st} + \alpha_{1,st}y_{t-1} + \alpha_{2,st}y_{t-2} + \alpha_{3,st}y_{t-3} + \alpha_{n,st}y_{t-n} + \varepsilon_t, \varepsilon_t \sim N(0, \sigma_{st}^2)$$

Eq. (1)

Onde: $N\{S_{t+1} = j | S_t = i\} = n_{i,j}$; $\sum_{j=1}^N n_{i,j} = 1, i = 1,2,3 \dots$ e $n_{i,j} \geq 0, \forall i, j$; o termo de intercepto é dado pelo v_{st} ; os coeficientes autorregressivos são $\alpha_{n,st}$; e a variância é definida por σ_{st}^2 .

Para estes modelos, a estimação da mudança de estado Markoviano é realizada por meio da maximização da função de verossimilhança usando o algoritmo EM (HAMILTON, 1994; KIM E NELSON, 1999), onde o passo “E” representa as integrais sem solução analítica e o passo “M” representa as equações sem solução analítica.

Os modelos de mudança de estado no intercepto e na variância (MSIH) possuem uma maior flexibilidade ao descrever séries financeiras em que geralmente ocorrem quebras na estrutura da média condicional e na variância incondicional no processo gerador dos dados (mas não apresenta uma regra de formação para a

variância condicional). O MSIH segue as mesmas propriedades do modelo com mudança de estado Markoviano geral apresentado na equação 1.

É importante observar que a volatilidade condicional no modelo MSIH é dada pela previsão da variância condicional em conjunto com a informação do período anterior. A volatilidade condicional possui sempre um passo à frente, sendo: $E(\sigma_{t+1}^2 | y_t, s_t; \theta) = \sum_{st=1}^N \sigma_{st}^2 \times n(s_{t+1} = s_t | y_t; \theta)$. Assim, o processo gerador dos dados deste modelo apresenta uma variância que muda de estado, caracterizando a volatilidade.

Nos modelos ARCH com mudança de estado (MSARCH), de Hamilton e Susmel (1994), ocorre um processo ARCH com mudança de estado que altera a escala da volatilidade, com transição entre N estados possíveis, $s_t = \{1, 2, \dots, N\}$ dirigidas por uma cadeia de Markov de primeira ordem. O modelo MSARCH (N,r), para dois estados N=2, com um processo ARCH (r) de ordem r, é formulado considerando-se $\mu_t = \sqrt{g_{st}} \times \tilde{\mu}_t$ e $\tilde{\mu}_t = h_t \times v_t$ para gerar a variância condicional representada na equação 2.

$$h_t^2 = \alpha_0 + \sum_{i=1}^r \alpha_i \tilde{\mu}_{t-i}^2$$

Eq. (2)

Onde: $N\{S_{t+1} = j | S_t = i\} = n_{i,j}$; $\sum_{j=1}^N n_{i,j} = 1, i = 1, 2, 3 \dots$ e $n_{i,j} \geq 0, \forall i, j$; para o fator que multiplica o processo ARCH $\sqrt{g_{st}}$ no primeiro estado, $s_t = 1$, logo obtém-se $\sqrt{g_1}$ e para o segundo estado, $s_t = 2$, logo obtém-se $\sqrt{g_2}$.

O MSARCH corresponde a uma especificação para a variância não condicional com mudança de estado ao longo do tempo. A mudança de estado provoca um aumento repentino da variância quando se entra no estado de instabilidade. A mudança de estado para a volatilidade está associada a um processo gerador dos dados para a série temporal com mudança de estado, sendo a variância não condicional um parâmetro com quebra estrutural.

Os modelos do tipo MS surgiram por meio da ampla aceitação do modelo de Markov, considerando a incorporação da mudança de estado em modelos de variância condicional. Primeiramente estudado por Cai (1994), Hamilton e Susmel

(1994) e Gray (1996), estes modelos foram refinados ao longo de outros estudos, como os de Dueker (1997) e Klaassen (2002).

Como visto em Marcucci (2005) e Ardia (2008), os modelos baseados em MSGARCH são muito mais flexíveis em relação ao modelo GARCH de um estado e podem se adaptar rapidamente às variações da volatilidade incondicional, o que melhora as previsões de risco. Além do mais, análises empíricas mostram que as estimativas dos modelos GARCH podem ser tendenciosas por quebras estruturais na dinâmica da volatilidade (BAUWENS, PREMINGER E ROMBOUTS, 2010; BAUWENS, BACKER E DUFAYS, 2014).

É interessante observar que em um estudo recente realizado por Ardia et al. (2017) para avaliar *performance* de previsão de volatilidade em modelos MSGARCH e GARCH, os autores concluíram que o melhor modelo depende do tipo de ativo. Sendo que ativos como ações, o MSGARCH aponta uma excelente *performance* de previsão para gerenciamento de risco (o que não se aplicava para índices e moedas). Porém, como as moedas digitais são uma nova tipologia de ativo, torna-se um criptoativo atípico nesta comparação.

2.4 Metodologia e Base de Dados

Os preços dolarizados das 50 moedas, utilizadas neste estudo, são provenientes da base do *website* coinmarketcap. O levantamento inicial contemplou dados de 2013 – 2018, porém, para igualar o tamanho das amostras máximas entre as maiores moedas o recorte foi reduzido para 1.344 dados diários, abordando desta maneira um período total do recorte de dados de 03/2015 – 11/2018 (considerando dados diários e disponibilidade de dados), com o ranqueamento de moedas efetuado em 11/2018 (tabela 1).

Tabela 1: Seleção dos 50 criptoativos.

1	2	3	4	5	6
BTC Bitcoin	ETH Ethereum	XRP Ripple	XLM Stellar Lumens	LTC Litecoin	XMR Monero
7	8	9	10	11	12
Tether Tether Dollar	DASH Dash	DOGE Dogecoin	BTS BitShares	BCN Bytecoin	DGB DigiByte
13	14	15	16	17	18
XVG Verge	MAID MaidSafeCoin	MONA Monacoin	RDD ReddCoin	Nxt Nxt	SYS Syscoin

19	20	21	22	23	24
PPC Peercoin	NXS Nexus	GRS Groestlcoin	VTC VertCoin	EMC2 Einsteinium	UBQ Ubiq
25	26	27	28	29	30
BLOCK Blocknet	NAV NavCoin	BITCNY bitCNY	NVC Novacoin	XDN DigitalNote	VIA ViaCoin
31	32	33	34	35	36
BAY BitBay	BURST Burst	XWC WhiteCoin	CLOAK CloakCoin	BBR Boolberry	UNO Unobtanium
37	38	39	40	41	42
NLG Gulden	BITUSD BitUSD	GAME GameCredits	CSC CassinoCoin	XCP Counterparty	NMC Namecoin
43	44	45	46	47	48
FTC Feathercoin	XPM PrimeCoin	CRW Crown	FLO FlorinCoin	BLK BlackCoin	ECC ECC
49	50				
DMD Diamond	POT PotCoin				

Fonte: Própria.

Para se avaliar a volatilidade das moedas digitais segundo o modelo de mudança de estado Markoviano com modelos GARCH, ou seja, o MSGARCH, utilizou-se a modelagem de Klaassen (2002) aplicada no *software* R com o pacote MSGARCH elaborado por Ardia et al. (2018) - para o SGARCH (BOLLERSLEV, 1986), EGARCH (NELSON, 1991), GJRGARCH (GLOSTEN, JAGANNATHAN E RUNKLE, 1993) e TGARCH (ZAKOIAN, 1994) – os quatro modelos GARCH disponíveis para interação com o MSGARCH.

A escolha da utilização de dois estados de volatilidade foi baseada no estudo de Segnon e Bekiros (2019) e Ardia, Bluteau e Rüede (2019), sendo visto no estudo dos últimos autores que para dois estados de volatilidade há um melhor *trade-off* entre qualidade dos testes e a complexidade do modelo – nesta tese não houve a intenção de se avaliar uma ótima quantidade de estados para cada moeda.

Uma forma generalizada do MSGARCH pode ser definida ao se considerar inicialmente o processo de retorno r_t , como uma expansão do primeiro estado de Henschel (1995) para os dois estados de Markov, definido na equação 3.

$$r_{t+1} = \lambda_i + y_i \sqrt{h_{i,t}} + \sqrt{h_{i,t}} \epsilon_{t+1}$$

Eq. (3)

Onde: λ_i e y_i são as constantes dos estados; ϵ_t denota o processo independente e identicamente distribuído dos dados; $h_{i,t}$ representa a variância condicional no estado i .

A distribuição condicional do retorno é uma mistura de dois níveis normais distribuições que podem ser escritas segundo a equação 4.

$$r_{t+1}|\phi_t \sim \begin{cases} N(\lambda_1 + y_1\sqrt{h_{1,t}}, h_{1,t}), \text{ com probabilidade de } p_{1,t} \\ N(\lambda_2 + y_2\sqrt{h_{2,t}}, h_{2,t}), \text{ com probabilidade de } (1 - p_{1,t}) \end{cases}$$

Eq. (4)

Onde: ϕ_t define o conjunto de informações a partir da data t; $p_{1,t}$ denota a probabilidade ex-ante de estar no estado 1 na data t.

A variância agregada para data t-1 condicional ao fato de estar em estado i na data t por $h_{t-1}^{(i)}$ (equação 5) e, conseqüentemente, o termo de choque $\delta_t^{(i)}$ (equação 6).

$$h_{t-1}^{(i)} = p_{1,t-1}^{(i)} h_{1,t-1} + (1 - p_{1,t-1}^{(i)}) h_{2,t-1} + p_{1,t-1}^{(i)} (1 - p_{1,t-1}^{(i)}) (\lambda_1 + y_1\sqrt{h_{1,t-1}} - \lambda_2 + y_2\sqrt{h_{2,t-1}})^2$$

Eq. (5)

$$\delta_t^{(i)} = p_{1,t-1}^{(i)} \frac{r_t(\lambda_1 + y_1\sqrt{h_{1,t-1}})}{\sqrt{h_{1,t-1}}} + (1 - p_{1,t-1}^{(i)}) \frac{r_t(\lambda_2 + y_2\sqrt{h_{2,t-1}})}{\sqrt{h_{2,t-1}}}$$

Eq. (6)

A volatilidade para dois estados pode ser generalizada na equação 7.

$$\sqrt{h_{1,t}} = \omega_i + \alpha_i \sqrt{h_{i,t-1}^{(i)}} f_i(\delta_t^{(i)}) + \beta_i \sqrt{h_{i,t-1}^{(i)}}$$

Eq. (7)

Onde: $f_i(\delta_t^{(i)}) = |\delta_t^{(i)} - b_i| - c_i(\delta_t^{(i)} - b_i)$; b_i e c_i representam os parâmetros específicos de cada estado.

No modelo de mudança de estado markoviano a variável de estado evolui de acordo com uma cadeia de Markov estacionária de primeira ordem, com probabilidade de transição definida por meio da equação 8.

$$Pr(s_t = j | s_{t-1} = i) = p_{ij}$$

Eq. (8)

Onde: i é a probabilidade de mudança de estado no tempo $t-1$ para o estado j no tempo t . Usualmente, as probabilidades são descritas por meio da matriz de transição. Para dois estados, como utilizado neste trabalho, as probabilidades são descritas na matriz de transição como: $P = \begin{bmatrix} p_{11} & p_{21} \\ p_{12} & p_{22} \end{bmatrix}$.

Como descrito por Hamilton (1989), uma informação importante para ser observada é a duração média de cada regime, dado que se está em um regime específico. Definido como W a duração de determinado regime pode-se observar que:

$$\begin{cases} w = 1; \text{ se } s_t = i, s_{t+1} = 1, s_{t+2} = 2; p(w = 1 | s_t = i; s_{t+1} = i) = 1 - p_{ii} \\ w = 2; \text{ se } s_t = s_{t+1} = i, s_{t+2} = i; p(w = 2 | s_t = s_{t+1} = i; s_{t+2} = i) = p_{ii}(1 - p_{ii}) \end{cases}$$

Onde é possível observar que a variável aleatória W tem distribuição geométrica e, portanto, a duração esperada do estado $s_t = i$ com $i = 1$ e 2 é representada segundo a equação 9.

$$E|w| = \frac{1}{1 - p_{ii}}$$

Eq. (9)

Com o intuito de encontrar os melhores modelos que busquem otimizar a integração com cada moeda digital em particular, os resultados foram ranqueados em função do menor AIC e maior Log-Kernel (tabela 2). Como exemplo, no caso do BTC, foi notado que EGARCH foi a melhor escolha considerando os critérios AIC e Log-Kernel para um estado de volatilidade, ao contrário dos modelos SGARCH, GJRGARCH e TGARCH. Já para dois estados, o GJRGARCH foi mais aderente. Não houve convergência do modelo para o segundo estado dos criptoativos Tether, ECC e BITCNY.

Tabela 2: Melhores modelos por Estado de Volatilidade.

	1 ESTADO	2 ESTADOS	
BTC	EGARCH	GJRGARCH	GJRGARCH
ETH	SGARCH	GJRGARCH ²	GJRGARCH ²
XRP	TGARCH	TGARCH ³	TGARCH ³
XLM	TGARCH	TGARCH ²	TGARCH ²
LTC	EGARCH	TGARCH ²	TGARCH ²
XMR	EGARCH	GJRGARCH ²	GJRGARCH ²

Tether	EGARCH	-	-
DASH	EGARCH	EGARCH	EGARCH
DOGE	EGARCH	EGARCH	EGARCH
BTS	EGARCH	EGARCH	EGARCH
BCN	EGARCH	TGARCH ²	TGARCH ²
DGB	EGARCH	TGARCH ³	TGARCH ³
XVG	SGARCH	TGARCH	TGARCH
MAID	TGARCH	EGARCH	EGARCH
MONA	SGARCH	TGARCH ²	TGARCH ²
RDD	SGARCH	GJRGARCH	GJRGARCH
Nxt	EGARCH	EGARCH	EGARCH
SYS	EGARCH	TGARCH ²	TGARCH ²
PPC	EGARCH	TGARCH ²	TGARCH ²
NXS	EGARCH	EGARCH	EGARCH
GRS	EGARCH	TGARCH ²	TGARCH ²
VTC	EGARCH	GJRGARCH ²	GJRGARCH ²
EMC2	EGARCH	TGARCH	TGARCH
UBQ	GJRGARCH ³	TGARCH ²	TGARCH ²
BLOCK	EGARCH	EGARCH	EGARCH
NAV	SGARCH	GJRGARCH	GJRGARCH
BITCNY	GJRGARCH	-	-
NVC	EGARCH	TGARCH ³	TGARCH ³
XDN	EGARCH	TGARCH	TGARCH
VIA	EGARCH	TGARCH ²	TGARCH ²
BAY	EGARCH	TGARCH ²	TGARCH ²
Burst	TGARCH	EGARCH	EGARCH
XWC	EGARCH	SGARCH ³	SGARCH ³
CLOAK	GJRGARCH	TGARCH	TGARCH
BBR	EGARCH	TGARCH ²	TGARCH ²
UNO	EGARCH	SGARCH ³	SGARCH ³
NLG	EGARCH	TGARCH ²	TGARCH ²
BITUSD	EGARCH	SGARCH ³	SGARCH ³
GAME	EGARCH	EGARCH	EGARCH
CSC	TGARCH ²	GJRGARCH ³	GJRGARCH ³
XCP	EGARCH	EGARCH	EGARCH
NMC	TGARCH ⁴	TGARCH ²	TGARCH ²
FTC	TGARCH	TGARCH ²	TGARCH ²
XPM	EGARCH	EGARCH	EGARCH
CRW	GJRGARCH	GJRGARCH	GJRGARCH
FLO	EGARCH	EGARCH	EGARCH
BLK	EGARCH	EGARCH ²	EGARCH ²
ECC	GJRGARCH	-	-
DMD	EGARCH	EGARCH	EGARCH
POT	EGARCH	TGARCH	TGARCH

2 = significa que o segundo melhor caso de convergência foi adotado por aderência do modelo; 3 = significa que o terceiro melhor caso de convergência foi adotado por aderência do modelo; 4 = significa que o quarto melhor caso de convergência foi adotado por aderência do modelo.

Fonte: Própria.

Para a análise de previsão de volatilidade com o MSGARCH, foi utilizado o modelo proposto por Ardía et al. (2018), por meio de seu pacote no *software* R, se utilizando de janelas de 15, 30, 60 e 90 dias para comparação entre previsto e realizado (de 15/11/2018 – 12/02/2019). Para se avaliar a acurácia da previsão e consequente eficiência dos modelos, é comum se utilizar os testes de cobertura de

Kupiec (1995), Christoffesen (1998) ou McAleer e Da Veiga (2008). Porém, dada a pequena amostra de previsão (com 90 dias para frente) estes testes possuem uma deficiência em serem estatisticamente fracos para amostras pequenas com menos de 1 ano previsto (CAMPBELL, 2005; VIEIRA E SILVA FILHO, 2012; HERNANDEZ, 2016).

Desta forma, para avaliar a *performance* das previsões de volatilidade dos modelos com um e dois estados de volatilidade, optou-se por utilizar duas funções perdas conhecidas: Erro Quadrático Médio (EQM) e Quasi-Likelihood (QLIKE) – que funcionam como funções simétrica e assimétrica respectivamente de acordo com Audrino e Hu (2016). De maneira adicional também foram adicionadas as análises por meio do Erro Absoluto Médio Percentual (MAPE), do Erro Absoluto Médio (MAE) e do índice U de Theil (1966).

Como visto em Patton (2011), as funções EQM e QLIKE são parte da família paramétrica de funções perda amplamente utilizadas na literatura. Nagata e Oya (2012) observam que diversas funções perda foram propostas em estudos anteriores para avaliar o desempenho da previsão e que o problema é que essas funções, às vezes, fornecem resultados diferentes para classificar as previsões de volatilidade nas pesquisas empíricas.

Como visto em Hansen e Lunde (2006) e Patton (2011), pode-se utilizar as funções EQM e QLIKE para comparar a acurácia de previsões e a consistência de ranqueamento é aprovada quando todas as suposições são satisfeitas – as equações das funções EQM e QLIKE são apresentadas nas equações 10 e 11.

$$EQM = \frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2$$

Eq. (10)

$$QLIKE = \frac{1}{n} \sum_{t=1}^n \left(\frac{\ln(F_t) + Y_t}{F_t} \right)$$

Eq. (11)

Onde: n é o número de componentes da amostra; Y_t é o valor realizado observado no período t ; F_t é o valor previsto para o período t .

Como visto em Hanke (2001):

- O **MAE** (ou erro absoluto médio) mede a magnitude média dos erros de um conjunto de previsões, sem considerar sua direção, onde todas as diferenças individuais possuem mesmo peso. De regra, quanto menor este indicador, melhor é a acurácia - é definido por meio da equação 12;

- O **MAPE** é o erro absoluto médio percentual e é calculado encontrando o erro absoluto em cada período, calculando então a média desses erros absolutos percentuais. Este indicador avalia o quão grandes os erros de previsão estão na comparação com os valores atuais da série. Quanto menor o valor percentual encontrado, melhor será o desempenho da previsão – seu cálculo é definido na equação 13;

- O **indicador U de Theil** (1966) avalia o desempenho das previsões pelos métodos formais contra os valores da previsão ingênua. A previsão ingênua é a estimativa do futuro sendo igual a estimativa do valor atual. A primeira proposta do U de Theil é delimitada entre 0 e 1. Já na segunda proposta o limite superior é infinito. De regra, quanto mais próximo a zero, melhor o valor da estimativa - é definido por meio da equação 14.

$$MAE = \frac{1}{n} \sum_{t=1}^n |Y_t - F_t|$$

Eq. (12)

$$MAPE = \frac{1}{n} \sum_{t=1}^n \frac{|Y_t - F_t|}{Y_t} \times 100$$

Eq. (13)

$$U \text{ de Theil} = \frac{\sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t - F_t)^2}}{\sqrt{\frac{1}{n} \sum_{t=1}^n (Y_t)^2} + \sqrt{\frac{1}{n} \sum_{t=1}^n (F_t)^2}}$$

Eq. (14)

Onde: n é o número de componentes da amostra; Y_t é o valor realizado observado no período t ; F_t é o valor previsto para o período t .

2.5 Resultados

Como pode ser notado na tabela 3, do total de 50 criptoativos 47 foram convergentes com os modelos e 10 apresentaram uma maior probabilidade em ocorrer dois estados de volatilidade – apontados em negrito. Destas 10 moedas o BTC e ETH fazem parte e apenas estas duas moedas representam mais da metade de todo o mercado de moedas digitais. Na maior parte das moedas que apresentaram maior probabilidade de ocorrência de dois estados de volatilidade, a volatilidade do segundo regime foi maior do que a do primeiro regime (as exceções foram o BTC e ETH).

Tabela 3: Resumo da volatilidade por estado.

Moedas	Volatilidade Anualizada para 1 Estado	Volatilidade Anualizada para 2 Estados			
		1 Regime	2 Regimes	Probabilidades	
BTC	103,15%	130,97%	24,67%	49,94%	50,06%
ETH	261,47%	416,21%	43,03%	42,99%	57,01%
XRP	155,62%	96,11%	184,08%	72,94%	27,06%
XLM	158,15%	16,95%	164,64%	42,45%	57,55%
LTC	121,12%	25,93%	141,18%	50,23%	49,77%
XMR	141,89%	43,80%	251,79%	71,40%	28,60%
Tether	-	-	-	-	-
DASH	130,11%	56,07%	152,92%	52,60%	47,40%
DOGE	175,93%	14,19%	560,27%	57,31%	42,69%
BTS	178,56%	40,04%	333,56%	33,71%	66,29%
BCN	348,01%	168,92%	539,98%	86,39%	13,61%
DGB	209,07%	115,52%	371,57%	83,32%	16,68%
XVG	316,14%	0,37%	435,71%	23,81%	76,19%
MAID	149,10%	2,69%	181,14%	55,45%	44,55%
MONA	261,90%	105,74%	250,94%	77,76%	22,24%
RDD	299,73%	101,87%	613,90%	94,66%	5,34%
Nxt	176,99%	114,96%	238,22%	75,29%	24,71%
SYS	203,04%	176,71%	212,39%	69,41%	30,59%
PPC	157,99%	37,76%	223,89%	67,33%	32,67%
NXS	288,98%	194,47%	356,62%	57,89%	42,11%
GRS	325,42%	34,41%	364,27%	61,89%	38,11%
VTC	230,76%	106,63%	263,20%	80,82%	19,18%
EMC2	284,30%	97,88%	420,30%	72,39%	27,61%
UBQ	213,00%	98,19%	215,23%	6,16%	93,84%
BLOCK	268,06%	150,51%	683,79%	95,81%	4,19%
NAV	247,75%	281,45%	246,93%	60,71%	39,29%
BITCNY	-	-	-	-	-
NVC	205,75%	56,16%	424,19%	85,07%	14,93%

XDN	241,30%	56,87%	342,60%	62,87%	37,13%
VIA	230,20%	161,40%	282,38%	65,80%	34,20%
BAY	224,52%	154,83%	359,81%	78,98%	21,02%
Burst	214,80%	86,17%	238,58%	49,89%	50,11%
XWC	549,75%	143,65%	888,73%	92,15%	7,95%
CLOAK	307,14%	221,00%	797,79%	93,94%	6,06%
BBR	379,07%	135,86%	436,74%	77,62%	22,38%
UNO	181,78%	87,39%	616,34%	90,32%	9,68%
NLG	162,82%	46,07%	302,40%	39,26%	60,74%
BITUSD	244,58%	64,16%	322,52%	95,76%	4,24%
GAME	533,71%	75,86%	835,65%	73,35%	26,65%
CSC	648,02%	319,05%	1106,83%	83,87%	16,13%
XCP	184,09%	100,93%	238,92%	44,39%	55,61%
NMC	159,36%	123,21%	196,38%	68,74%	31,26%
FTC	236,68%	99,14%	550,91%	87,75%	12,25%
XPM	233,70%	127,41%	264,14%	88,54%	11,46%
CRW	661,63%	2,23%	716,57%	34,43%	65,57%
FLO	226,75%	91,69%	387,83%	56,40%	43,60%
BLK	241,60%	50,43%	252,88%	53,01%	46,99%
ECC	-	-	-	-	-
DMD	175,85%	201,82%	242,30%	76,89%	23,11%
POT	175,41%	176,14%	176,78%	77,45%	22,55%

Fonte: Própria.

No anexo, podem ser notados os gráficos de volatilidade condicional para apenas um regime no item 8.1.1. e os gráficos de volatilidade na presença de dois regimes no item 8.1.2. Para uma avaliação complementar, optou-se também por incluir as probabilidades filtradas de ocorrências para um e dois regimes representados nos gráficos do item 8.1.3.

Em linhas gerais, ter uma maior probabilidade de ocorrência do segundo estado de volatilidade significa dizer que ao sortear uma observação ao acaso nestas respectivas séries, a probabilidade é maior de se encontrar uma observação no segundo regime. Porém, para associar de melhor forma interpretativa os resultados, optou-se por analisar os dados da matriz de transição das séries e também entender qual a duração média de se estar com um ou dois estados de volatilidade nas séries – as tabelas 4 e 5 compilam os respectivos resultados.

Tabela 4: Componentes da Matriz de Transição de Mudança de Estado.

Moedas	Matriz de Transição			
	p ₁₁	p ₁₂	p ₂₁	p ₂₂
BTC	0,9787	0,0212	0,0213	0,9788
ETH	0,6720	0,2473	0,3280	0,7527
XRP	0,9633	0,0989	0,0367	0,9011
XLM	0,9639	0,0266	0,0361	0,9734
LTC	0,8405	0,1610	0,1595	0,8390
XMR	0,6582	0,8462	0,3418	0,1538
Tether	-	-	-	-
DASH	0,9788	0,0236	0,0212	0,9764

DOGE	0,7539	0,3305	0,2461	0,6695
BTS	0,8085	0,0974	0,1915	0,9026
BCN	0,9970	0,0190	0,0030	0,9810
DGB	0,9633	0,1835	0,0367	0,8165
XVG	0,3900	0,1906	0,6100	0,8094
MAID	0,7854	0,2670	0,2146	0,7330
MONA	0,9984	0,0057	0,0016	0,9943
RDD	0,9967	0,0585	0,0033	0,9415
Nxt	0,9953	0,0142	0,0047	0,9858
SYS	0,9982	0,0042	0,0018	0,9958
PPC	0,7846	0,4439	0,2154	0,5561
NXS	0,9916	0,0116	0,0084	0,9884
GRS	0,8862	0,1848	0,1138	0,8152
VTC	0,9660	0,1433	0,0340	0,8567
EMC2	0,8169	0,4801	0,1831	0,5199
UBQ	0,9068	0,0165	0,0932	0,9835
BLOCK	0,9835	0,3783	0,0165	0,6217
NAV	0,9801	0,0308	0,0199	0,9692
BITCNY	-	-	-	-
NVC	0,9603	0,2265	0,0397	0,7735
XDN	0,7708	0,3882	0,2292	0,6118
VIA	0,9911	0,0172	0,0089	0,9828
BAY	0,9920	0,0299	0,0080	0,9701
Burst	0,9714	0,0284	0,0286	0,9716
XWC	0,9344	0,7691	0,0656	0,2309
CLOAK	0,9914	0,1330	0,0086	0,8670
BBR	0,9355	0,2239	0,0645	0,7761
UNO	0,8964	0,9674	0,1036	0,0326
NLG	0,8944	0,0683	0,1056	0,9317
BITUSD	0,9557	1,0000	0,0443	0,0000
GAME	0,8703	0,3571	0,1297	0,6429
CSC	0,9328	0,3496	0,0672	0,6504
XCP	0,4606	0,4305	0,5394	0,5695
NMC	0,9988	0,0027	0,0012	0,9973
FTC	0,9302	0,4999	0,0698	0,5001
XPM	0,9514	0,3757	0,0486	0,6243
CRW	0,6720	0,2473	0,3280	0,7527
FLO	0,7361	0,3413	0,2639	0,6587
BLK	0,9592	0,0461	0,0408	0,9539
ECC	-	-	-	-
DMD	0,9990	0,0035	0,0010	0,9965
POT	0,9927	0,0252	0,0073	0,9748

Fonte: Própria.

Desta forma, ao se analisar a título de exemplo o BTC na tabela 4, pode-se notar que para o $BTC = \begin{bmatrix} 0,9787 & 0,0213 \\ 0,0212 & 0,9788 \end{bmatrix}$ as probabilidades de estar com um estado de volatilidade varia entre 0 e 0,9 e as probabilidades de estar em um ou dois estados de volatilidade são respectivamente p_{11} e p_{22} , ou seja, para o BTC é praticamente quase a mesma probabilidade (que é confirmado com a tabela 5 na duração média em dias para o BTC em cada estado).

Ainda na tabela 4, pegando o ETH como exemplo, o $ETH = \begin{bmatrix} 0,6720 & 0,3280 \\ 0,2473 & 0,7527 \end{bmatrix}$

indica que as probabilidades de estar com um estado de volatilidade varia entre 0,2 e 0,6 e as probabilidades de estar em um ou dois estados de volatilidade são respectivamente p_{11} e p_{22} que denotam uma maior probabilidade de permanência no segundo estado.

A tabela 5, como apontado anteriormente demonstra a duração média em dias da permanência em cada estado de volatilidade. Assim como esperado, os mesmos 10 criptoativos com maior probabilidade de ocorrência do segundo estado de volatilidade apresentaram uma maior duração média de se estar no segundo estado.

Tabela 5: Duração Média em Dias da Permanência em cada Estado de Volatilidade.

Moedas	Duração Média Esperada dos Estados (dias)	
	1 Estado	2 Estados
BTC	46,9484	47,1698
ETH	3,0488	4,0437
XRP	27,2480	10,1112
XLM	27,7008	37,5940
LTC	6,2696	6,2112
XMR	2,9257	1,1818
Tether	-	-
DASH	47,1698	42,3729
DOGE	4,0634	3,0257
BTS	5,2219	10,2669
BCN	333,3333	52,6316
DGB	27,2480	5,4496
XVG	1,6393	5,2466
MAID	4,6598	3,7453
MONA	625,0000	175,4386
RDD	303,0303	17,0940
Nxt	212,7660	70,4225
SYS	555,5556	238,0952
PPC	4,6425	2,2528
NXS	119,0476	86,2069
GRS	8,7873	5,4113
VTC	29,4118	6,9784
EMC2	5,4615	2,0829
UBQ	10,7296	60,6061
BLOCK	60,6061	2,6434
NAV	50,2513	32,4675
BITCNY	-	-
NVC	25,1889	4,4150
XDN	4,3630	2,5760
VIA	112,3596	58,1395
BAY	125,0000	33,4448
Burst	34,9650	35,2113
XWC	15,2439	1,3002
CLOAK	116,2791	7,5188
BBR	15,5039	4,4663
UNO	9,6525	1,0337
NLG	9,4697	14,6413
BITUSD	22,5734	1,0000

GAME	7,7101	2,8003
CSC	14,8810	2,8604
XCP	1,8539	2,3229
NMC	833,3333	370,3704
FTC	14,3266	2,0004
XPM	20,5761	2,6617
CRW	3,0488	4,0437
FLO	3,7893	2,9300
BLK	24,5098	21,6920
ECC	-	-
DMD	1000,0000	285,7143
POT	136,9863	39,6825

Desta forma, ao se considerar a matriz de transição para dois estados de volatilidade: a duração média de se estar no primeiro regime é definida como sendo $p11 = 1 / (1 - p11)$ e para o segundo regime é $p22 = 1 / (1 - p22)$.

Fonte: Própria.

Com base nas probabilidades filtradas e nos dias médios de se estar em cada estado nas amostras destes mesmos 10 criptoativos, foi possível notar que existe uma maior tendência de aparecimento do segundo estado de volatilidade com a subida de preços para a maior parte das moedas (onde existe uma maior volatilidade) – a exceção cabe apenas ao BTC e ETH, onde o primeiro estado de volatilidade é mais presente na subida de preços (com maior volatilidade).

Os parâmetros para um e dois estados dos dados realizados no MSGARCH com os melhores casos apontados anteriormente na tabela 2, estão dispostos na tabela 6 para análise.

Tabela 6: Parâmetros nos Estados de Volatilidade.

Moedas	Parâmetros para 1 estado de volatilidade							
	alpha0_1	alpha1_1	alpha2_1	beta_1	alpha0_2	alpha1_2	alpha2_2	beta_2
BTC	-0,2273	0,2682	0,0002	0,9622	-	-	-	-
ETH	0,0003	0,3058	0,0000	0,6843	-	-	-	-
XRP	0,0127	0,5016	0,2193	0,5388	-	-	-	-
XLM	0,0079	0,2267	0,1068	0,7675	-	-	-	-
LTC	-0,1703	0,0798	0,1185	0,9699	-	-	-	-
XMR	-0,2336	0,1596	0,1049	0,9561	-	-	-	-
Tether	-	-	-	-	-	-	-	-
DASH	-0,3885	0,3026	0,0701	0,9296	-	-	-	-
DOGE	-0,1936	0,3302	0,1022	0,9622	-	-	-	-
BTS	-0,1622	0,1831	0,0623	0,9667	-	-	-	-
BCN	-0,1313	0,2311	0,1325	0,9643	-	-	-	-
DGB	-0,0616	0,0667	0,1151	0,9870	-	-	-	-
XVG	0,0027	0,2342	0,0000	0,6673	-	-	-	-
MAID	0,0032	0,0861	0,1203	0,8754	-	-	-	-
MONA	0,0007	0,4967	0,0000	0,4859	-	-	-	-
RDD	0,0005	0,1394	0,0000	0,8405	-	-	-	-
Nxt	-0,1543	0,2416	0,0452	0,9688	-	-	-	-
SYS	-0,4189	0,2526	0,1037	0,9088	-	-	-	-
PPC	-0,1663	0,1903	0,1072	0,9679	-	-	-	-

NXS	-0,2996	0,3493	0,0294	0,9239	-	-	-	-
GRS	-0,3648	0,3231	-0,0019	0,8998	-	-	-	-
VTC	-0,1847	0,2103	0,1015	0,9581	-	-	-	-
EMC2	-0,0541	0,0906	0,0773	0,9865	-	-	-	-
UBQ	0,0001	0,1344	0,0001	0,8654	-	-	-	-
BLOCK	-1,0892	0,3868	0,1316	0,7286	-	-	-	-
NAV	0,0020	0,3007	0,0000	0,5840	-	-	-	-
BITCNY	0,0001	0,0460	0,0265	0,9332	-	-	-	-
NVC	-0,0760	0,0917	0,0849	0,9835	-	-	-	-
XDN	-0,2570	0,2535	0,0921	0,9399	-	-	-	-
VIA	-0,1486	0,1852	0,0707	0,9660	-	-	-	-
BAY	-0,9084	0,4383	0,1240	0,7939	-	-	-	-
Burst	0,0139	0,3183	0,2083	0,6587	-	-	-	-
XWC	-0,0354	0,1787	-0,0275	0,9871	-	-	-	-
CLOAK	0,0011	0,0774	0,0964	0,8305	-	-	-	-
BBR	-0,2049	0,4321	0,0412	0,9424	-	-	-	-
UNO	-0,1203	0,0973	0,0445	0,9747	-	-	-	-
NLG	-0,9510	0,3752	0,0719	0,8101	-	-	-	-
BITUSD	-0,9582	1,2114	0,1326	0,8107	-	-	-	-
GAME	-0,0122	0,1091	0,0168	0,9956	-	-	-	-
CSC	0,0024	0,0118	0,0001	0,9883	-	-	-	-
XCP	-0,0705	0,0369	0,0846	0,9855	-	-	-	-
NMC	0,0076	0,2109	0,1639	0,7562	-	-	-	-
FTC	0,0076	0,2109	0,1639	0,7562	-	-	-	-
XPM	-0,1591	0,2176	0,0936	0,9638	-	-	-	-
CRW	0,0001	0,0567	0,0255	0,9304	-	-	-	-
FLO	-0,7312	0,3331	0,0206	0,8311	-	-	-	-
BLK	-0,1577	0,2965	0,0394	0,9640	-	-	-	-
ECC	-	-	-	-	-	-	-	-
DMD	-0,3384	0,2291	0,0004	0,9300	-	-	-	-
POT	-1,2157	0,4251	0,0928	0,7500	-	-	-	-
Moedas	Parâmetros para 2 estados de volatilidade							
	alpha0_1	alpha1_1	alpha2_1	beta_1	alpha0_2	alpha1_2	alpha2_2	beta_2
BTC	0,0001	0,0957	0,0001	0,8915	0,0000	0,0557	0,0001	0,9436
ETH	0,0006	0,2860	0,0001	0,7060	0,0000	0,1630	0,0465	0,8135
XRP	0,0200	0,4542	0,4295	0,6267	0,0566	0,4349	0,0001	0,2340
XLM	0,0001	0,0252	0,1191	0,9315	0,0159	0,5522	0,0509	0,6084
LTC	0,0006	0,0882	0,0741	0,8951	0,0023	0,0639	0,0001	0,9448
XMR	0,0000	0,1886	0,0001	0,7263	0,0003	0,0400	0,0002	0,9429
Tether	-	-	-	-	-	-	-	-
DASH	-0,7501	0,1031	-0,0896	0,8941	-1,5999	0,2459	0,0247	0,6842
DOGE	-0,3952	0,2116	0,0225	0,9602	-0,1228	0,3600	0,1368	0,9599
BTS	-0,6726	0,2446	0,1695	0,9148	-0,0092	0,0359	0,0812	0,9980
BCN	0,0080	0,2050	0,1190	0,7923	0,1213	0,9965	0,0001	0,5731
DGB	0,0025	0,0863	0,0947	0,8878	0,0159	0,0561	0,0001	0,8970
XVG	0,0001	0,9279	0,0001	0,5842	0,0319	0,3698	0,2681	0,6117
MAID	-0,0835	0,1262	0,0264	0,9938	-0,9266	0,2155	-0,0468	0,8043
MONA	0,0171	0,4807	0,3976	0,3754	0,0934	0,4485	0,3877	0,0002
RDD	0,0000	0,0000	0,0674	0,9662	0,0193	0,0605	0,0001	0,7601
Nxt	-1,2008	0,4036	0,0049	0,8011	-6,3312	0,3375	0,1088	0,4995
SYS	0,0184	0,3726	0,0833	0,6394	0,0952	0,1359	0,2349	0,0004
PPC	0,0013	0,1440	0,1082	0,8387	0,0133	0,2775	0,0215	0,7660
NXS	-0,3876	0,3276	0,0804	0,9214	-2,6325	0,6041	-0,0298	0,2851
GRS	0,0006	0,0706	0,0400	0,9232	0,1751	0,2011	0,0001	0,0012
VTC	0,0003	0,1059	0,0001	0,8088	0,0119	0,3205	0,0001	0,0586
EMC2	0,0025	0,1048	0,0674	0,8856	0,1050	0,7638	0,1889	0,1939
UBQ	0,0011	0,0246	0,0001	0,9841	0,0101	0,2024	0,1663	0,7725
BLOCK	-0,0728	0,1294	0,0358	0,9861	-2,5369	-0,6778	0,6259	0,1285
NAV	0,0048	0,5332	0,0002	0,3336	0,0001	0,0938	0,0225	0,8933
BITCNY	0,0127	0,9998	0,0001	0,0001	0,0264	0,5051	0,4948	0,0706

NVC	0,0014	0,0997	0,1738	0,8483	0,0068	0,0629	0,0118	0,9433
XDN	0,0018	0,1064	0,1243	0,8463	0,0140	0,1738	0,0001	0,8566
VIA	0,0101	0,2230	0,0899	0,7721	0,0000	0,0000	0,0022	0,9991
BAY	0,0054	0,1460	0,1295	0,8268	0,1538	0,2627	0,3422	0,0015
Burst	-0,0464	0,0173	0,0069	0,9925	-1,4035	0,5246	0,0389	0,6760
XWC	0,0014	0,1452	0,0000	0,6141	0,0053	0,0326	0,0000	0,9431
CLOAK	0,0056	0,1015	0,1038	0,8754	0,1224	0,9981	0,0016	0,4503
BBR	0,0018	0,0510	0,1162	0,9104	0,0148	0,0853	0,0001	0,9020
UNO	0,0004	0,0906	0,0000	0,7417	0,0049	0,1258	0,0000	0,8273
NLG	0,0001	0,0121	0,0001	0,9893	0,0723	0,7851	0,2146	0,5744
BITUSD	0,0001	0,5529	0,0000	0,3271	0,0283	0,0000	0,0000	0,0067
GAME	-0,1931	0,1457	0,0038	0,9705	-0,0042	0,0256	0,0420	0,9978
CSC	0,0009	0,2844	0,0001	0,6985	0,3226	0,0000	0,0001	0,0463
XCP	-0,7095	0,3328	-0,0152	0,8978	-0,0487	0,0109	0,0968	0,9893
NMC	0,0157	0,5962	0,1355	0,6033	0,0069	0,1432	0,1439	0,8296
FTC	0,0048	0,2160	0,0367	0,8085	0,1056	0,3614	0,0001	0,4786
XPM	-0,2174	0,2571	0,0450	0,9628	-4,4268	0,6445	0,1828	0,0820
CRW	0,0000	0,9474	0,0428	0,0117	0,0000	0,0001	0,0336	0,9830
FLO	-0,6263	0,0583	0,1205	0,8976	-0,4301	0,3189	0,0224	0,8687
BLK	-0,0893	0,0454	0,0815	0,9880	-1,3362	0,3462	0,1252	0,7065
ECC	-	-	-	-	-	-	-	-
DMD	-1,2311	0,5092	-0,0019	0,7739	-7,3724	0,2805	-0,2344	0,5918
POT	0,0132	0,3526	0,2127	0,6647	0,0763	0,2527	0,0001	0,0665

Fonte: Própria.

O parâmetro “alpha0_1” representa o intercepto do modelo para um estado de volatilidade, assim como “alpha0_2” para dois estados de volatilidade. Já “alpha1_1” é o *gamma* para um estado de volatilidade (esta variável explica a intensidade dos choques), e como pode ser notado, todos os *gammas* foram positivos tanto para um como para dois regimes, indicando que os choques positivos são mais fortes que os choques negativos. Da mesma maneira, o “alpha1_2” é o *gamma* do segundo regime para dois estados de volatilidade e novamente os choques positivos permanecem apenas à exceção do BLOCK.

Os parâmetros “alpha2_1” e “alpha2_2” são os erros para um dos estados de volatilidade. Os parâmetros “beta_1” e “beta_2” representam a volatilidade em t-1 para um e dois regimes respectivamente. Analisando primeiramente um estado de volatilidade, em “beta_1” nota-se que a maior parte das moedas são influenciadas pela volatilidade passada do primeiro regime para um estado de volatilidade - com exceção de 15 moedas em que no primeiro regime, para dois estados, apresentou maior influência: ETH, XRP, XML, MAID, RDD, GRS, UBY, BLOCK, BAY, BURST, CLOAK, NLG, FTC, FLO e BLK.

Analisando “beta_2”, para dois estados de volatilidade, foi possível perceber que a maior parte das moedas apresentou uma maior influência da volatilidade passada no primeiro regime, apenas 18 moedas apresentaram uma maior influência

pela volatilidade passada no segundo regime do que no primeiro, elas foram: BTC, ETH, LTC, XMR, BTS, DGB, XVG, NAV, BITCNY, NVC, XDN, VIA, XWC, UNO, GAME, XPC, NMC e CRW.

Para a projeção de volatilidade, dentre as janelas escolhidas de 15, 30, 60 e 90 dias, foram avaliadas as funções perda EQM e QLIKE, bem como o MAE, MAPE e o indicador U de Theil. Os 5 testes de acurácia tiveram resultados muito próximos e indicaram que existe uma maior assertividade da previsão com dois estados de volatilidade para janelas de previsão mais longas. Para ambos os testes os menores valores são preferidos em relação a melhor *performance* do modelo – as tabelas 7, 8, 9 10 e 11 apresentam os resultados para os referidos testes.

Tabela 7: Teste de Acurácia com Função Perda EQM.

Moedas	Para 1 Estado de Volatilidade				Para 2 Estados de Volatilidade			
	90 Dias	60 Dias	30 Dias	15 Dias	90 Dias	60 Dias	30 Dias	15 Dias
BTC	0,0012	0,0011	0,0014	0,0023	0,0010	0,0012	0,0016	0,0026
ETH	0,0049	0,0032	0,0020	0,0016	0,0029	0,0022	0,0016	0,0017
XRP	0,0029	0,0023	0,0022	0,0013	0,0043	0,0048	0,0061	0,0100
XLM	0,0026	0,0021	0,0018	0,0015	0,0022	0,0020	0,0022	0,0024
LTC	0,0015	0,0012	0,0011	0,0017	0,0015	0,0012	0,0011	0,0018
XMR	0,0020	0,0018	0,0017	0,0025	0,0019	0,0017	0,0015	0,0019
Tether	-	-	-	-	-	-	-	-
DASH	0,0026	0,0030	0,0017	0,0020	0,0025	0,0031	0,0018	0,0022
DOGE	0,0036	0,0027	0,0017	0,0009	0,0018	0,0016	0,0012	0,0008
BTS	0,0025	0,0019	0,0019	0,0028	-	-	-	-
BCN	0,0103	0,0054	0,0019	0,0011	0,0082	0,0050	0,0035	0,0028
DGB	0,0021	0,0019	0,0019	0,0027	0,0039	0,0032	0,0026	0,0024
XVG	0,0137	0,0110	0,0073	0,0042	0,0147	0,0122	0,0081	0,0049
MAID	0,0026	0,0025	0,0026	0,0036	0,0022	0,0024	0,0024	0,0034
MONA	0,0111	0,0073	0,0047	0,0032	0,0022	0,0019	0,0019	0,0028
RDD	0,0074	0,0057	0,0036	0,0026	0,0050	0,0039	0,0030	0,0033
Nxt	0,0029	0,0022	0,0024	0,0027	0,0023	0,0020	0,0024	0,0030
SYS	0,0057	0,0054	0,0062	0,0092	0,0048	0,0047	0,0056	0,0082
PPC	0,0041	0,0045	0,0051	0,0040	0,0022	0,0024	0,0033	0,0042
NXS	0,0093	0,0078	0,0068	0,0048	0,0110	0,0056	0,0056	0,0059
GRS	0,0144	0,0125	0,0085	0,0047	0,0081	0,0068	0,0056	0,0045
VTC	0,0046	0,0040	0,0041	0,0051	0,0032	0,0030	0,0036	0,0043
EMC2	0,0050	0,0036	0,0031	0,0036	0,0079	0,0065	0,0063	0,0054
UBQ	0,0027	0,0034	0,0052	0,0094	0,0044	0,0039	0,0043	0,0065
BLOCK	0,0084	0,0081	0,0084	0,0064	-	-	0,0048	0,0047
NAV	0,0069	0,0053	0,0050	0,0036	0,0081	0,0055	0,0049	0,0031
BITCNY	0,0026	0,0018	0,0012	0,0009	0,0010	0,0008	0,0006	0,0004
NVC	0,0532	0,0753	0,1444	0,2741	0,0504	0,0740	0,1461	0,2858
XDN	0,0062	0,0048	0,0042	0,0060	0,0042	0,0036	0,0036	0,0050
VIA	0,0042	0,0029	0,0032	0,0036	0,0030	0,0026	0,0031	0,0037
BAY	0,0058	0,0057	0,0052	0,0040	0,0053	0,0049	0,0048	0,0049
Burst	0,0051	0,0039	0,0035	0,0026	0,0033	0,0025	0,0025	0,0024
XWC	0,0075	0,0044	0,0032	0,0038	0,0078	0,0074	0,0072	0,0055
CLOAK	0,0114	0,0091	0,0062	0,0054	0,0222	0,0239	0,0356	0,0377
BBR	0,0149	0,0099	0,0052	0,0016	0,0063	0,0047	0,0034	0,0019
UNO	0,0045	0,0029	0,0025	0,0020	0,0040	0,0022	0,0021	0,0019
NLG	0,0037	0,0036	0,0028	0,0014	0,0130	0,0110	0,0096	0,0060

BITUSD	0,0079	0,0071	0,0058	0,0036	0,0025	0,0025	0,0023	0,0019
GAME	0,0026	0,0028	0,0037	0,0057	0,0021	0,0027	0,0036	0,0055
CSC	0,0313	0,0285	0,0321	0,0339	0,1105	0,0985	0,0911	0,0656
XCP	0,0020	0,0015	0,0014	0,0013	0,0018	0,0014	0,0014	0,0013
NMC	0,0038	0,0040	0,0029	0,0010	0,0038	0,0043	0,0036	0,0039
FTC	0,0067	0,0061	0,0048	0,0039	0,0053	0,0050	0,0042	0,0040
XPM	0,0045	0,0044	0,0032	0,0033	-	0,0042	0,0030	0,0036
CRW	0,0049	0,0047	0,0062	0,0086	0,0048	0,0048	0,0057	0,0076
FLO	0,0049	0,0044	0,0044	0,0032	-	-	-	-
BLK	0,0139	0,0075	0,0047	0,0045	0,0874	0,0224	0,0057	0,0076
ECC	-	-	-	-	-	-	-	-
DMD	0,0031	0,0028	0,0026	0,0020	-	0,0028	0,0029	0,0029
POT	0,0037	0,0037	0,0043	0,0054	0,0040	0,0039	0,0045	0,0058
Total de Moedas com 2 estados de Vol.					43	45	46	46
Aderência aos Modelos com 2 estados de Vol.					30	29	29	19
% de Otimização das Moedas para 2 Estados					70%	64%	63%	41%

Fonte: Própria.

Tabela 8: Teste de Acurácia com Função Perda QLIKE.

Moedas	Para 1 Estado de Volatilidade				Para 2 Estados de Volatilidade			
	90 Dias	60 Dias	30 Dias	15 Dias	90 Dias	60 Dias	30 Dias	15 Dias
BTC	-2,1905	-1,9539	-1,6594	-1,0544	-2,1942	-1,8624	-1,5039	-0,8003
ETH	-1,7932	-1,7699	-1,8651	-1,6964	-1,8886	-1,8263	-1,8904	-1,6625
XRP	-2,0932	-2,0348	-2,1254	-2,0844	-2,1068	-2,0214	-2,0746	-1,9125
XLM	-1,9814	-1,8773	-1,8246	-1,6248	-2,0248	-1,8929	-1,8009	-1,5490
LTC	-1,9626	-1,8712	-1,8816	-1,5822	-1,9733	-1,8599	-1,8797	-1,5656
XMR	-1,9377	-1,7957	-1,7962	-1,5504	-1,9499	-1,8129	-1,8368	-1,6613
Tether	-	-	-	-	-	-	-	-
DASH	-1,9365	-1,7527	-1,8040	-1,7750	-1,9451	-1,7260	-1,7710	-1,7216
DOGE	-2,1592	-2,1392	-2,1246	-1,9978	-2,3201	-2,2505	-2,1812	-2,0060
BTS	-1,9702	-1,9129	-1,8425	-1,5885	-	-	-	-
BCN	-1,6977	-1,7384	-1,8479	-1,9400	-1,7493	-1,7361	-1,7711	-1,8499
DGB	-1,9045	-1,8002	-1,7603	-1,6095	-1,8005	-1,7369	-1,7482	-1,7015
XVG	-1,5118	-1,4484	-1,4048	-1,3607	-1,4965	-1,4307	-1,3894	-1,3478
MAID	-1,8783	-1,7394	-1,6872	-1,5197	-1,9157	-1,7542	-1,7087	-1,5592
MONA	-1,7046	-1,6812	-1,7844	-1,8049	-2,0798	-1,9316	-1,9462	-1,8176
RDD	-1,6266	-1,6122	-1,5176	-1,2212	-1,7077	-1,6792	-1,5379	-1,1551
Nxt	-1,9551	-1,8484	-1,7114	-1,5662	-2,0103	-1,8734	-1,7106	-1,5513
SYS	-1,7192	-1,6022	-1,4784	-1,1175	-1,7689	-1,6462	-1,5256	-1,1974
PPC	-1,8790	-1,8102	-1,6580	-1,2807	-2,0377	-1,9636	-1,7818	-1,2638
NXS	-1,4872	-1,4413	-1,3668	-1,0300	-1,5234	-1,4956	-1,3883	-0,9578
GRS	-1,4985	-1,5371	-1,5571	-1,5469	-1,6430	-1,6702	-1,6261	-1,5393
VTC	-1,5551	-1,5336	-1,3278	-1,1204	-1,6359	-1,6036	-1,3855	-1,2281
EMC2	-1,8350	-1,8036	-1,7941	-1,6103	-1,7320	-1,6852	-1,6555	-1,5282
UBQ	-1,7283	-1,5215	-1,2054	-0,6579	-1,7248	-1,6665	-1,5974	-1,4280
BLOCK	-1,5411	-1,5232	-1,5288	-1,3928	-	-	-1,6573	-1,4631
NAV	-1,5984	-1,5063	-1,5568	-1,5259	-1,5680	-1,5035	-1,5635	-1,5478
BITCNY	-2,6824	-2,7313	-2,8095	-2,9135	-2,9868	-2,9826	-3,0152	-3,1440
NVC	-1,3545	-1,1301	-0,7529	0,1866	-1,4919	-1,2067	-0,7391	0,4690
XDN	-1,6411	-1,5489	-1,4289	-1,1177	-1,7354	-1,6172	-1,4921	-1,2391
VIA	-1,7065	-1,6375	-1,7234	-1,6513	-1,7641	-1,6568	-1,7286	-1,6463
BAY	-1,6562	-1,6129	-1,5002	-1,2852	-1,6716	-1,6353	-1,5036	-1,2208
Burst	-1,7213	-1,6192	-1,5864	-1,4999	-1,8040	-1,6821	-1,6315	-1,4976
XWC	-1,6917	-1,7416	-1,7630	-1,4653	-1,6540	-1,6259	-1,6042	-1,4414
CLOAK	-1,5550	-1,5199	-1,4972	-1,4724	-1,5040	-1,4190	-1,2863	-1,2062
BBR	-1,4436	-1,4596	-1,6134	-1,6828	-1,6108	-1,5706	-1,6577	-1,6526
UNO	-1,6562	-1,7689	-1,6918	-1,5761	-1,6884	-1,8184	-1,7215	-1,5825
NLG	-2,1218	-2,1193	-2,0399	-1,8764	-1,7988	-1,8283	-1,7800	-1,6931

BITUSD	-1,8249	-1,8509	-2,0158	-2,2937	-2,0601	-2,0468	-2,1609	-2,3399
GAME	-1,8854	-1,7842	-1,6794	-1,2004	-1,9380	-1,7978	-1,6976	-1,2305
CSC	-0,8042	-0,8398	-0,9845	-1,0518	-0,5168	-0,5681	-0,7266	-0,8819
XCP	-1,8900	-1,8342	-1,7186	-1,7104	-1,9063	-1,8474	-1,7208	-1,7076
NMC	-1,7688	-1,6152	-1,6597	-1,6674	-1,7926	-1,6266	-1,6641	-1,5792
FTC	-1,6394	-1,5832	-1,4867	-1,3497	-1,6907	-1,6237	-1,5119	-1,3466
XPM	-1,5599	-1,5571	-1,6986	-1,7521	-	-1,5657	-1,7046	-1,7325
CRW	-1,6916	-1,6016	-1,2940	-1,1283	-1,7009	-1,6084	-1,3396	-1,2194
FLO	-1,4077	-1,3243	-1,3612	-1,3529	-	-	-	-
BLK	-1,0879	-1,2741	-1,4313	-1,3104	-0,9227	-1,2501	-1,4388	-1,2545
ECC	-	-	-	-	-	-	-	-
DMD	-1,7857	-1,7954	-1,7341	-1,4810	-	-1,8210	-1,7403	-1,4676
POT	-1,7584	-1,6447	-1,5178	-1,1307	-1,7408	-1,6286	-1,4943	-1,0893
Total de Moedas com 2 estados de Vol.					43	45	46	46
Aderência aos Modelos com 2 estados de Vol.					32	30	30	16
% de Otimização das Moedas para 2 Estados					74%	67%	65%	35%

Fonte: Própria.

Tabela 9: Teste de Acurácia com MAE.

Moedas	Para 1 Estado de Volatilidade				Para 2 Estados de Volatilidade			
	90 Dias	60 Dias	30 Dias	15 Dias	90 Dias	60 Dias	30 Dias	15 Dias
BTC	0,0290	0,0264	0,0293	0,0409	0,0262	0,0272	0,0316	0,0451
ETH	0,0596	0,0469	0,0379	0,0307	0,0460	0,0383	0,0330	0,0322
XRP	0,0484	0,0431	0,0421	0,0309	0,0499	0,0486	0,0531	0,0612
XLM	0,0457	0,0397	0,0364	0,0323	0,0411	0,0381	0,0391	0,0399
LTC	0,0313	0,0265	0,0269	0,0347	0,0290	0,0260	0,0264	0,0352
XMR	0,0381	0,0355	0,0337	0,0412	0,0380	0,0355	0,0326	0,0370
Tether	-	-	-	-	-	-	-	-
DASH	0,0396	0,0386	0,0315	0,0366	0,0365	0,0380	0,0316	0,0365
DOGE	0,0548	0,0467	0,0357	0,0247	0,0384	0,0352	0,0297	0,0228
BTS	0,0427	0,0361	0,0342	0,0431	-	-	-	-
BCN	0,0880	0,0626	0,0373	0,0287	0,0768	0,0596	0,0476	0,0407
DGB	0,0387	0,0361	0,0343	0,0415	0,0554	0,0485	0,0432	0,0418
XVG	0,1089	0,0951	0,0763	0,0556	0,1130	0,1001	0,0817	0,0619
MAID	0,0430	0,0415	0,0388	0,0473	0,0399	0,0405	0,0384	0,0466
MONA	0,0940	0,0746	0,0586	0,0428	0,0391	0,0333	0,0286	0,0334
RDD	0,0759	0,0648	0,0491	0,0407	0,0607	0,0525	0,0442	0,0458
Nxt	0,0474	0,0393	0,0402	0,0414	0,0409	0,0361	0,0412	0,0440
SYS	0,0629	0,0570	0,0573	0,0626	0,0574	0,0527	0,0558	0,0616
PPC	0,0577	0,0591	0,0619	0,0492	0,0397	0,0417	0,0480	0,0533
NXS	0,0880	0,0792	0,0707	0,0548	0,0829	0,0660	0,0640	0,0618
GRS	0,1126	0,1040	0,0835	0,0596	0,0818	0,0753	0,0677	0,0582
VTC	0,0576	0,0534	0,0503	0,0499	0,0460	0,0453	0,0483	0,0463
EMC2	0,0639	0,0532	0,0491	0,0522	0,0820	0,0737	0,0743	0,0683
UBQ	0,0368	0,0391	0,0463	0,0667	0,0558	0,0507	0,0491	0,0586
BLOCK	0,0836	0,0825	0,0855	0,0729	-	-	0,0613	0,0596
NAV	0,0754	0,0645	0,0619	0,0521	0,0810	0,0652	0,0612	0,0492
BITCNY	0,0485	0,0408	0,0316	0,0281	0,0302	0,0260	0,0206	0,0172
NVC	0,1173	0,1313	0,1916	0,2636	0,0845	0,1003	0,1650	0,2539
XDN	0,0692	0,0572	0,0484	0,0580	0,0564	0,0496	0,0467	0,0555
VIA	0,0544	0,0429	0,0426	0,0418	0,0475	0,0421	0,0448	0,0480
BAY	0,0686	0,0672	0,0637	0,0537	0,0648	0,0616	0,0594	0,0563
Burst	0,0649	0,0549	0,0518	0,0451	0,0518	0,0441	0,0434	0,0417
XWC	0,0748	0,0567	0,0465	0,0464	0,0828	0,0801	0,0800	0,0681
CLOAK	0,0992	0,0871	0,0716	0,0667	0,1219	0,1226	0,1432	0,1518
BBR	0,1083	0,0851	0,0598	0,0342	0,0710	0,0602	0,0494	0,0378
UNO	0,0542	0,0491	0,0467	0,0402	0,0488	0,0425	0,0429	0,0400
NLG	0,0568	0,0559	0,0475	0,0326	0,1055	0,0969	0,0868	0,0648

BITUSD	0,0823	0,0759	0,0668	0,0520	0,0448	0,0443	0,0430	0,0405
GAME	0,0421	0,0419	0,0475	0,0574	0,0360	0,0410	0,0471	0,0572
CSC	0,1573	0,1546	0,1665	0,1756	0,3116	0,2949	0,2868	0,2442
XCP	0,0391	0,0341	0,0328	0,0327	0,0371	0,0324	0,0328	0,0325
NMC	0,0497	0,0476	0,0414	0,0257	0,0474	0,0475	0,0438	0,0378
FTC	0,0751	0,0706	0,0623	0,0548	0,0662	0,0631	0,0570	0,0531
XPM	0,0582	0,0563	0,0504	0,0518	-	0,0539	0,0487	0,0544
CRW	0,0603	0,0574	0,0646	0,0751	0,0618	0,0606	0,0659	0,0777
FLO	0,0592	0,0555	0,0552	0,0456	-	-	-	-
BLK	0,0848	0,0731	0,0612	0,0609	0,1896	0,0944	0,0644	0,0766
ECC	-	-	-	-	-	-	-	-
DMD	0,0471	0,0449	0,0424	0,0337	-	0,0445	0,0447	0,0403
POT	0,0528	0,0508	0,0529	0,0554	0,0547	0,0522	0,0546	0,0574
Total de Moedas com 2 estados de Vol.					43	45	46	46
Aderência aos Modelos com 2 estados de Vol.					30	31	26	20
% de Otimização das Moedas para 2 Estados					70%	69%	57%	43%

Fonte: Própria.

Tabela 10: Teste de Acurácia com MAPE.

Moedas	Para 1 Estado de Volatilidade				Para 2 Estados de Volatilidade			
	90 Dias	60 Dias	30 Dias	15 Dias	90 Dias	60 Dias	30 Dias	15 Dias
BTC	998%	591%	93%	105%	736%	448%	99%	133%
ETH	435%	353%	262%	60%	342%	289%	233%	57%
XRP	546%	392%	446%	351%	635%	555%	768%	1035%
XLM	9845%	396%	301%	144%	8839%	369%	328%	251%
LTC	250%	95%	71%	57%	206%	84%	66%	57%
XMR	1518%	141%	166%	174%	1552%	161%	201%	216%
Tether	-	-	-	-	-	-	-	-
DASH	308%	266%	171%	89%	261%	226%	147%	78%
DOGE	9653%	1396%	335%	130%	7412%	1048%	280%	125%
BTS	492%	312%	162%	173%	-	-	-	-
BCN	11997%	1004%	1469%	2596%	9057%	1224%	1998%	3609%
DGB	753%	396%	240%	110%	1106%	663%	449%	199%
XVG	949%	547%	248%	276%	995%	573%	254%	280%
MAID	1034%	277%	225%	100%	911%	259%	223%	107%
MONA	1439%	515%	311%	136%	628%	205%	142%	80%
RDD	13440%	4525%	311%	146%	11543%	3588%	252%	138%
Nxt	573%	256%	168%	187%	502%	249%	201%	259%
SYS	4045%	5561%	288%	58%	3707%	5108%	282%	64%
PPC	3184%	4035%	803%	120%	2172%	2742%	539%	104%
NXS	469%	325%	294%	50%	413%	266%	245%	53%
GRS	686%	509%	308%	169%	513%	386%	258%	178%
VTC	292%	257%	155%	41%	229%	218%	151%	42%
EMC2	761%	464%	501%	741%	898%	615%	715%	1039%
UBQ	730%	247%	136%	222%	1619%	577%	319%	506%
BLOCK	440%	442%	497%	345%	-	-	343%	223%
NAV	580%	343%	412%	431%	634%	344%	402%	393%
BITCNY	1674%	1327%	614%	465%	1086%	909%	420%	266%
NVC	563%	436%	649%	114%	368%	289%	457%	85%
XDN	474%	256%	153%	72%	395%	230%	162%	93%
VIA	666%	251%	304%	243%	554%	242%	314%	285%
BAY	967%	923%	423%	442%	902%	825%	333%	329%
Burst	2919%	2264%	299%	142%	2388%	1845%	229%	105%
XWC	636%	345%	192%	117%	650%	469%	374%	268%
CLOAK	4013%	372%	258%	251%	3580%	436%	408%	452%
BBR	1046%	386%	258%	147%	720%	285%	236%	194%
UNO	214%	190%	139%	100%	179%	159%	122%	96%
NLG	656%	647%	495%	162%	1114%	1085%	965%	285%

BITUSD	1570%	2004%	2865%	4642%	1432%	1949%	3224%	5752%
GAME	373%	402%	587%	119%	332%	390%	588%	123%
CSC	735%	716%	1238%	990%	1209%	1138%	1880%	1129%
XCP	4618%	1649%	3074%	104%	4669%	1554%	2904%	97%
NMC	285%	234%	293%	69%	271%	232%	323%	179%
FTC	487%	360%	232%	207%	429%	319%	204%	183%
XPM	660%	861%	1408%	2570%	-	892%	1524%	2823%
CRW	513%	249%	195%	213%	554%	288%	252%	295%
FLO	464%	487%	820%	228%	-	-	-	-
BLK	3164%	4679%	8836%	133%	2874%	3914%	7283%	135%
ECC	-	-	-	-	-	-	-	-
DMD	1236%	1246%	761%	47%	-	1090%	704%	60%
POT	745%	896%	281%	110%	771%	925%	281%	108%
Total de Moedas com 2 estados de Vol.					43	45	46	46
Aderência aos Modelos com 2 estados de Vol.					30	29	25	17
% de Otimização das Moedas para 2 Estados					70%	64%	54%	37%

Fonte: Própria.

Tabela 11: Teste de Acurácia com indicador U de Theil.

Moedas	Para 1 Estado de Volatilidade				Para 2 Estados de Volatilidade			
	90 Dias	60 Dias	30 Dias	15 Dias	90 Dias	60 Dias	30 Dias	15 Dias
BTC	0,4111	0,3870	0,4696	0,5745	0,4308	0,4433	0,5121	0,5890
ETH	0,4257	0,3542	0,3412	0,3010	0,3766	0,3275	0,3287	0,3325
XRP	0,4275	0,3754	0,3990	0,3052	0,4968	0,4882	0,5519	0,5841
XLM	0,3842	0,3265	0,2994	0,2531	0,3680	0,3289	0,3298	0,3231
LTC	0,3358	0,2958	0,3141	0,3594	0,3491	0,3162	0,3201	0,3669
XMR	0,3525	0,3233	0,3437	0,4000	0,3392	0,3050	0,3021	0,3231
Tether	-	-	-	-	-	-	-	-
DASH	0,3870	0,3800	0,3320	0,3791	0,4039	0,4132	0,3654	0,4152
DOGE	0,5107	0,4482	0,3720	0,2658	0,4294	0,3877	0,3365	0,2648
BTS	0,3915	0,3476	0,3655	0,4272	-	-	-	-
BCN	0,5374	0,4222	0,2999	0,2682	0,5085	0,4078	0,3570	0,3464
DGB	0,3622	0,3468	0,3697	0,4219	0,3904	0,3412	0,3248	0,3139
XVG	0,5154	0,4449	0,3591	0,2695	0,5227	0,4561	0,3684	0,2798
MAID	0,3674	0,3439	0,3622	0,4168	0,3568	0,3446	0,3497	0,3913
MONA	0,5528	0,4546	0,4110	0,3594	0,3907	0,3412	0,3477	0,3998
RDD	0,4485	0,4052	0,3305	0,2659	0,4132	0,3748	0,3297	0,3195
Nxt	0,4075	0,3455	0,3534	0,3770	0,3795	0,3349	0,3543	0,3730
SYS	0,4256	0,3938	0,4103	0,4497	0,4029	0,3745	0,3838	0,4056
PPC	0,4005	0,3895	0,3659	0,2745	0,3503	0,3454	0,3427	0,3135
NXS	0,4436	0,4039	0,3814	0,3048	0,4784	0,3758	0,3732	0,3461
GRS	0,5046	0,5084	0,4340	0,3313	0,4412	0,4320	0,3807	0,3228
VTC	0,3624	0,3559	0,3564	0,4066	0,3328	0,3242	0,3278	0,3517
EMC2	0,4410	0,3735	0,3551	0,3507	0,4874	0,4309	0,4106	0,3511
UBQ	0,4438	0,4855	0,5685	0,6563	0,3856	0,3580	0,3673	0,4182
BLOCK	0,4251	0,4121	0,4152	0,3332	-	-	0,3745	0,3401
NAV	0,4099	0,3430	0,3469	0,2932	0,4312	0,3462	0,3487	0,2810
BITCNY	0,7076	0,6303	0,5406	0,5354	0,6083	0,5364	0,4645	0,4412
NVC	0,5938	0,6107	0,6578	0,6914	0,6463	0,6662	0,7069	0,7370
XDN	0,4331	0,3719	0,3618	0,4186	0,3822	0,3355	0,3260	0,3516
VIA	0,3760	0,3095	0,3519	0,3671	0,3391	0,2974	0,3375	0,3506
BAY	0,4011	0,3846	0,3455	0,2817	0,4040	0,3868	0,3693	0,3513
Burst	0,4087	0,3394	0,3250	0,2820	0,3727	0,3108	0,3141	0,3047
XWC	0,4742	0,4011	0,3860	0,3917	0,4573	0,4339	0,4226	0,3358
CLOAK	0,4989	0,4401	0,3685	0,3443	0,5808	0,5629	0,5869	0,5816
BBR	0,5016	0,4211	0,3812	0,2466	0,4028	0,3423	0,3262	0,2563
UNO	0,3631	0,3346	0,2998	0,2516	0,3654	0,3080	0,2834	0,2488
NLG	0,4930	0,4880	0,4140	0,2768	0,6356	0,6195	0,5562	0,4210

BITUSD	0,5193	0,4939	0,5016	0,5194	0,3906	0,3803	0,3997	0,4375
GAME	0,3815	0,3875	0,4403	0,4802	0,3730	0,3937	0,4334	0,4679
CSC	0,3935	0,3908	0,4708	0,5159	0,5287	0,5268	0,5902	0,5929
XCP	0,3210	0,2804	0,2554	0,2513	0,3147	0,2751	0,2603	0,2606
NMC	0,3796	0,3654	0,3408	0,2271	0,3837	0,3738	0,3556	0,3858
FTC	0,4165	0,3811	0,3234	0,2705	0,3958	0,3678	0,3212	0,2944
XPM	0,3363	0,3324	0,3343	0,3595	-	0,3424	0,3236	0,3647
CRW	0,4060	0,3917	0,4073	0,4587	0,3894	0,3693	0,3585	0,3912
FLO	0,3118	0,2848	0,2933	0,2576	-	-	-	-
BLK	0,4002	0,3408	0,3124	0,2895	0,5505	0,4412	0,3360	0,3554
ECC	-	-	-	-	-	-	-	-
DMD	0,3543	0,3529	0,3479	0,2977	-	0,3490	0,3483	0,3146
POT	0,3687	0,3460	0,3516	0,3477	0,3791	0,3555	0,3660	0,3698
Total de Moedas com 2 estados de Vol.					43	45	46	46
Aderência aos Modelos com 2 estados de Vol.					25	25	25	18
% de Otimização das Moedas para 2 Estados					58%	56%	54%	39%

Fonte: Própria.

2.6 Conclusões

O objetivo deste estudo foi de entender como é o comportamento da volatilidade das 50 principais moedas digitais, em diferentes estados de volatilidade, considerando o MSGARCH com a melhor modelagem para cada série de dados - seguindo o critério AIC e do Log-Kernel, bem como a convergência de parâmetros e previsão de volatilidade.

O estudo mostrou que para o universo dos criptoativos analisados há influência de dois estados de volatilidade. No caso das moedas com maior capitalização de mercado, como o Bitcoin (BTC) e Ethereum (ETH), a probabilidade de ocorrência do segundo regime é de 50,06% e 57,01%, respectivamente, e quando ocorre, há uma redução na volatilidade. As moedas UBQ e XVG foram as que apresentaram maior probabilidade de ocorrência de um segundo regime com 93,84% e 76,19%, respectivamente, e quando ocorreram, há um aumento da volatilidade (assim como as outras que tiveram uma maior probabilidade de ocorrência do segundo regime).

Por meio da análise dos gráficos de probabilidades filtradas e com auxílio da avaliação dos dias médios de se estar em cada estado de volatilidade nas amostras, foi possível perceber que nos criptoativos com maior probabilidade de ocorrência do segundo regime existe uma maior tendência do aparecimento do segundo estado de volatilidade com a subida de preços, onde existe uma maior volatilidade. A exceção que foi notada cabe apenas ao BTC e ETH, onde o primeiro estado de volatilidade é mais presente na subida de preços, com maior volatilidade.

Em relação aos parâmetros dos modelos, foi possível concluir que em praticamente todas as moedas, tanto para 1 estado, como 2 estados, o coeficiente de assimetria *gamma* foi positivo, o que vai contra o que se esperaria no mercado acionário, invertendo a noção da aversão ao risco ser concentrado na área de perdas - indicando que os choques positivos são mais fortes que os negativos. Apesar de todas as moedas serem influenciadas pela volatilidade no período anterior, esta influência variou dependendo se houve ou não mudança de 1 para 2 estados e também do regime em que a mesma se encontrava. Considerando a comparabilidade de dados, o primeiro regime teve uma maior influência do que o segundo regime.

Em relação a projeção de volatilidade, contemplando as janelas escolhidas de 15, 30, 60 e 90 dias, para se testar a acurácia das previsões foram avaliadas as funções perda EQM e QLIKE, bem como o MAE, MAPE e o indicador U de Theil. Os 5 testes de acurácia tiveram resultados muito próximos e indicaram que existe uma maior assertividade da previsão com dois estados de volatilidade para janelas de previsão mais longas do que nas mais curtas, o que pode vir a auxiliar na elaboração de tendências ou análises destas moedas.

Apesar de este estudo permitir entender como os estados de volatilidade podem influenciar os criptoativos tanto em relação às mudanças positivas e negativas nos preços, bem como na influência de dados passados e na probabilidade de mudança de regimes, há ainda questões abertas para estudos futuros como, por exemplo, uma análise mais detalhada das razões para as diferenças de comportamento encontradas em relação à volatilidade de diversos criptoativos e até mesmo avaliar a quantidade ótima de estados de volatilidade para previsão das moedas no modelo MSGARCH.

Segundo Ensaio: Efeitos Manada e Contágio no Mercado de Criptoativos

Como apontado anteriormente, fenômenos atípicos comportamentais começam a tomar forma no mercado de moedas digitais e tais anomalias podem corroborar para influenciar e explicar a volatilidade desses ativos – volatilidade esta que põem em xeque até mesmo a classificação formal da tipologia das moedas digitais em função do seu caráter especulativo. Autores como Baek e Elbeck (2015), por exemplo, acreditam que o Bitcoin e os demais ativos do gênero sejam classificados como *commodities* especulativos ao invés de moedas ou ativos.

Em relação ao efeito manada, Leclair (2018) aponta que muitas vezes os indivíduos formam suas próprias opiniões/expectativas com investimentos e acabam substituindo suas opiniões/expectativas pelo ponto de vista de outras pessoas/instituições que podem influenciar sensivelmente suas decisões e consequentemente o preço dos ativos. Em especial, para os criptoativos, o autor aponta que acredita que a combinação da incerteza do papel das moedas digitais e aplicabilidade da tecnologia pode estimular o efeito manada neste mercado.

Já no que se refere ao efeito contágio, Huynh, Nguyen e Duong (2018) apontam a importância em se entender como ocorre a transmissão dos choques e inter-relações entre os criptoativos em um mercado eficiente considerado fraco e como essas relações de dependência modelam e afetam investimentos nesses ativos. Os autores, particularmente, ressaltam a cautela ao investir nesses criptoativos devido à disseminação de comovimentos nos preços - fora literatura recente que aponta a existência de bolhas, como por exemplo, no estudo de Cheah e Fry (2015) que identificaram o valor fundamental do Bitcoin como sendo zero.

Neste ensaio, o trabalho foi direcionado da seguinte forma: primeiramente pretende-se explorar um pouco da literatura sobre efeito manada e contágio (apontando, inclusive, alguns dos principais modelos utilizados) e os principais estudos com tais fenômenos comportamentais baseados em criptoativos publicados

até o momento; posteriormente será descrita a metodologia; análise de resultados; e a conclusão.

3.1 Efeito Manada

Uma anomalia financeira no mercado, ou a conhecida ineficiência de mercado, é uma distorção de preços ou rendimentos em um mercado financeiro, que parece contradizer a hipótese do mercado eficiente. Muitas vezes, em períodos de crise e condições extremas de mercado, os desvios ocorrem, e um dos que chama atenção dos investidores (institucionais e individuais), governos e órgãos reguladores é o comportamento de manada ou efeito manada.

O efeito manada foi primeiramente mencionado por de Keynes (1936), onde o autor descreveu o investidor que ignora suas próprias informações e crenças de maneira a seguir um comportamento coletivo, mesmo que as ações do grupo não sejam sustentadas por informações relevantes.

Como observado em Galariotis, Rond e Spyrou (2015), as razões do efeito manada são diversas: analistas podem ter este comportamento para proteger sua reputação; investidores institucionais para proteger sua remuneração; entre outros. Porém, como observam Froot, Scharfstein e Stein (1992), Hirshleifer, Subrahmanyam e Titman (1994), Wermers (1999), Bikhchandani e Sharma (2000) e Choi e Skiba (2015), existem dois tipos de efeitos manada:

- O efeito no qual os investidores têm acesso às mesmas informações (abertas ao grande público) e que por meio das mesmas análises e métodos, chegam a uma mesma conclusão, também conhecido como efeito manada investigativo ou espúrio;
- O efeito que é formado quando os investidores simplesmente ignoram as informações que tem à disposição e tomam decisões observando ou seguindo os outros, seja por motivos de reputação (SCHARFSTEIN E STEIN, 1990; TRUEMAN, 1994), características similares dos produtos financeiros como *momentum* ou hábito de operação de compra ou venda (GOMPERS E METRICK, 2001; BENNETT, SIAS E STARKS, 2003; NOFSINGER E SIAS, 1999; SIAS, 2004) e por modismos (FRIEDMAN, 1984; BARBERIS

E SHLEIFER, 2003). Tal efeito é conhecido como efeito manada intencional ou em cascata.

Os métodos para se medir o efeito manada podem ser divididos em duas grandes categorias: a primeira concentrada em uma abordagem micro, investigando quando tipos específicos de investidores apresentam o comportamento de manada (os principais representantes da abordagem são LAKONISHOK, SHLEIFER E VISHNY, 1992; SIAS, 2004) e a segunda é concentrada em uma abordagem macro, direcionadas às atividades de mercado e preços de produtos financeiros disponíveis para a compra por qualquer investidor (os principais representantes da abordagem são CHRISTIE E HUANG, 1995; CHANG, CHENG E KHORANA, 2000; HWANG E SALMON, 2004).

No método de medida de Lakonishok, Shleifer e Vishny (1992), ou LSV, o cálculo do efeito manada ocorre como uma proporção dos compradores líquidos (administradores de recursos que aumentam suas participações em ações durante determinado trimestre) relativo aos administradores de recursos que negociam aquela ação, menos um fator de ajuste que diminui à medida que o número de administradores de recursos ativos na ação sobe. Se nenhum efeito manada existir, o valor esperado desta métrica não deve variar de período a período, já na presença do efeito manada, deve-se ocorrer a variação significativa nesta medida. A medida LSV de efeito manada, H , é calculada na equação 1.

$$H(i) = |B(i)/(B(i) + S(i)) - p(t)| - AF(i)$$

Eq. (1)

Onde: $B(i)$ é o número de administradores de recursos que são os compradores líquidos; $S(i)$ é o número de administradores de recursos que são os vendedores líquidos (isto é, que diminuem suas participações); $p(t)$ é a proporção esperada da compra pelos administradores de recursos, em relação ao número de administradores de recursos ativos; e o fator de ajuste, $AF(i)$, é o valor esperado de $|B/(B+S)-p|$ na hipótese nula de se ter efeito manada. Lakonishok, Shleifer e Vishny (1992) salientam que, para qualquer ação, AF diminui à medida que o número de administradores de recursos ativos naquela ação sobe.

Sias (2004), argumenta que a proporção de investidores institucionais que compram no trimestre atual vai covariar (em ativos), com a proporção de investidores institucionais que compraram no trimestre anterior. Desta forma, se os investidores institucionais tiveram um comportamento de manada ou seguiram suas próprias negociações dentro ou fora do mesmo título, o efeito manada pode ser avaliado pela estimativa da correlação transversal entre a procura de um ativo por investidores institucionais no trimestre anterior e a demanda para o ativo por investidores institucionais no trimestre atual. Assim, para cada trimestre, será definida a fração institucional de compra (definida na equação 2).

$$FIC\Delta_{k,t} = BI_{k,t} / (BI_{k,t} + SI_{k,t})$$

Eq. (2)

Onde: BI é o número de investidores institucionais que compram o ativo k no trimestre t; e SI é o número de investidores institucionais que venderam o ativo k no trimestre t. Com o intuito de permitir a agregação ao longo do tempo e comparação de diferentes capitalizações de mercado e tipos de investidores, Sias (2004) padronizou a fração de investidores institucionais que compraram ativos k no trimestre t assim como é mostrado na equação 3.

$$\Delta_{k,t} = (FIC\Delta_{k,t} - \overline{FIC\Delta_{k,t}}) / \sigma(FIC\Delta_{k,t})$$

Eq. (3)

Onde: σ é o desvio-padrão da seção transversal do ativo k. Em seguida, a regressão da seção transversal é definida na equação 4.

$$\Delta_{k,t} = \beta\Delta_{k,t-1} + \varepsilon_{k,t}$$

Eq. (4)

Desta maneira, se os investidores institucionais seguiram uns aos outros dentro ou fora dos mesmos títulos (tiveram um comportamento de manada), a fração institucional de compra no trimestre atual vai ser negativamente correlacionada com a fração institucional de compra no trimestre anterior. Da mesma forma, se os investidores institucionais seguiram suas próprias negociações no trimestre anterior, a fração institucional de compra no trimestre atual vai ser

positivamente correlacionada com a fração institucional de compra no trimestre anterior.

Uma abordagem diferente é sugerida por Christie e Huang (1995), conhecido também por método CH, que mede o efeito manada dos investidores em direção ao consenso do mercado. Nesta análise, é proposto que durante os períodos de movimentos extremos de mercado, os investidores estão mais propensos a suprimir as suas próprias crenças e seguir o consenso de mercado.

A medida proposta por Christie e Huang (1995) tem como pressuposto que o efeito manada seja a dispersão transversal dos retornos dos ativos em relação ao retorno médio de mercado. Se os ativos se movem simultaneamente, então não há dispersão, ou seja, há ocorrência de efeito manada. A medida proposta é conhecida por desvio padrão transversal dos retornos ou CSSD (*Cross-Sectional Standard Deviation*), definida por meio da equação 5.

$$CSSD_t = \sqrt{\sum_{i=1}^N (R_{i,t} - R_{m,t})^2 / N - 1}$$

Eq. (5)

Onde: $R_{i,t}$ é o retorno do ativo i no período t ; $R_{m,t}$ é o retorno médio transversal da carteira de mercado no tempo t ; e N é o número de ativos analisados.

Assim, a métrica CH capta a proximidade do retorno do ativo em particular, em relação à média realizada da carteira de mercado e, em seguida, utiliza a regressão especificada na equação 6, com o intuito de examinar a dispersão dos retornos durante os períodos de movimentos extremos de mercado.

$$CSSD_t = \alpha + \gamma_1 D_t^L + \gamma_2 D_t^U + \varepsilon_t$$

Eq. (6)

Onde: $D_t^L = 1$, se os retornos do mercado estiverem na extremidade inferior da distribuição, caso contrário, $D_t^L = 0$; e $D_t^U = 1$, se os retornos do mercado estiverem na extremidade superior da distribuição, caso contrário, $D_t^U = 0$.

A utilização das variáveis binárias permite a identificação de diferenças no comportamento dos investidores nas condições extremas de mercado (positiva e negativa), contra as condições normais de mercado. Assim, caso a dispersão seja

baixa na presença de grandes alterações de mercado, ou seja, *gammas* negativos e estatisticamente significativos, supõe-se ocorrência do efeito manada.

Chang, Cheng e Khorana (2000), desenvolveram o método CCK, uma abordagem alternativa ao método CH para testar o efeito manada, considerando também a questão do consenso do mercado. Chang, Cheng e Khorana (2000), notaram que a abordagem CH é um teste mais rigoroso, no qual exige uma maior magnitude de não-linearidade, a fim de encontrar evidências de efeito manada. Desta forma, o teste de efeito manada pelo método CCK facilita a detecção do efeito ao longo de toda a distribuição de retornos do mercado com o CSAD (*Cross-Sectional Absolute Deviation*), que é o cálculo do desvio absoluto transversal dos retornos (definido por meio da equação 7).

$$CSAD_t = \frac{1}{N} \sum_{i=1}^N |R_{i,t} - R_{m,t}|$$

Eq. (7)

Onde: $R_{i,t}$ é o retorno do ativo i no período t ; $R_{m,t}$ é o retorno médio transversal da carteira de mercado no tempo t ; e N é o número de ativos analisados. Desta forma, em seguida, utiliza a regressão especificada na equação 8, com o intuito de examinar a dispersão dos retornos durante os períodos de movimentos extremos de mercado.

$$CSAD_{i,t} = \alpha + \gamma_1 |R_{m,t}| + \gamma_2 R_{m,t}^2 + \varepsilon_t$$

Eq. (8)

Chang, Cheng e Khorana (2000), desenvolveram o CSAD com base na versão de 1972 do modelo de precificação de ativos financeiros, mais conhecido por CAPM (*Capital Asset Pricing Model*). Modelos como CAPM assumem que a dispersão dos retornos é linearmente relacionada com o retorno de mercado, portanto, na ausência de efeito manada pode-se esperar uma estimativa positiva do coeficiente γ_1 . Por outro lado, no caso do efeito manada ser encontrado em dias de movimentos extremos de mercado, é esperado que a dispersão transversal dos retornos das ações diminuam ou aumentem consideravelmente menos do que proporcionalmente com o retorno de mercado, como modelos de precificação de

ativos lineares implicariam. Desta forma, com o coeficiente γ_2 negativo e estatisticamente significativo, supõe-se ocorrência do efeito manada.

Hwang e Salmon (2004) desenvolveram uma medida alternativa de efeito manada baseada na dispersão transversal das sensibilidades dos ativos com relação aos fatores dentro de um mercado. Como o modelo de Hwang e Salmon (2004) foca no efeito manada oriundo da variação transversal da sensibilidade dos betas e não dos retornos, o modelo é livre da influência dos componentes idiossincráticos. Além disso, como a metodologia é baseada em modelos de estado espaço, o modelo permite o controle de mudanças nos fundamentos e capta a existência do efeito manada não somente em períodos de movimentos extremos, mas também durante condições normais de mercado.

3.2 Efeito Contágio

O efeito contágio tem sua origem no campo da epidemiologia, como uma teoria matemática com o intuito de auxiliar na previsão da velocidade de infecção e da mortalidade de vírus, gripes e demais doenças. Já entre as décadas de 1980 - 1990, como destaca Bekiros (2014), este termo começou a ser utilizado no campo financeiro para apontar o efeito de crises que ocorriam em um mercado e cujo o efeito era disseminado e percebido em outras economias.

Como observado por Lee, Wu e Wang (2007), o efeito contágio não se resume apenas aos eventos financeiros (como a quebra do mercado norte-americano em 1987; a crise mexicana de 1994; crise asiática em 1997; a crise na Rússia em 1998; a crise no Brasil em 1999; a crise argentina em 2001 e 2002; a crise americana do *subprime* em 2008; etc.), mas também, tem origem em comportamentos irracionais de tomada de decisão, mudanças políticas, desastres naturais de grande proporção, entre outras anomalias que possam afetar um país ou conjunto de países.

Segundo Perobelli, Vidal e Securato (2013), na primeira geração de estudos sobre a transmissão de choques internacionais, os estudos analisam os fundamentos macroeconômicos e suas mudanças, que deixariam um país vulnerável a choques externos, justificando assim a propagação das crises e seu impacto distinto em cada país. Na segunda geração de estudos sobre crises financeiras, o foco é direcionado para o impacto das expectativas dos investidores na propagação das crises, assim

como comportamentos irracionais que intensificariam o efeito dos choques. Já os estudos da terceira geração evidenciam a existência do efeito contágio dos choques e formas de mensurá-lo, reconhecendo a existência de certa inter-relação preexistente entre as economias e o contágio como uma quebra nesta estrutura de relações.

O procedimento clássico para medir esse efeito foi sugerido por Sims (1980) conhecido como modelo de vetores autorregressivos (VAR) e é uma técnica recorrente, sendo capaz de estimar diversas variáveis simultaneamente, evitando os problemas de identificação dos parâmetros em modelos multiequacionais.

O CoVar (vetores autorregressivos condicionais), uma evolução do VAR, é um modelo multivariado definido no trabalho de Adrian e Brunnermeier (2011) seguindo estimações quantílicas, ele é capaz de captar efeitos de transbordamento negativo, diferente da medida fornecida pelo modelo univariado VAR, que mede o risco individual inerente ao processo temporal sem levar em conta o efeito de *spillover*.

Tendo em vista a ampla utilização dos modelos baseados na metodologia multivariada GARCH (heteroscedasticidade condicional autorregressiva generalizada), diferentes estruturas de correlação e distribuição de resíduos surgiram em diversos trabalhos abordando o problema de interdependência e contágio (como os de LOMBARDI ET AL., 2004; MARÇAL E PEREIRA, 2008; FILETTI, HOTTA E ZEVALLOS, 2008; TSAY, 2010; entre outros).

Modelos paramétricos de cópulas também buscam identificar efeitos de contágio, este é um método geral para formular distribuições multivariadas de maneira que diversos tipos gerais de dependência possam ser representados. Assim, a função cópula contém todas as informações da distribuição de probabilidade que independem das distribuições marginais. Dessa forma, pode-se dizer que as cópulas codificam a dependência entre as variáveis. Com essa construção, as distribuições conjuntas de variáveis aleatórias podem ser decompostas em distribuições marginais de cada uma das variáveis (alguns autores que utilizaram esta abordagem são por exemplo CHOLLETE, DE LA PEÑA E LU, 2005; RODRIGUEZ, 2007; entre outros).

Modelos baseados em redes Bayesianas tem sido utilizados para se avaliar contágio, a representação das redes é feita por meio de um grafo acíclico direcionado (do inglês DAGs), no qual os nós representam variáveis de um domínio

e os arcos representam a dependência condicional entre as variáveis e utilizam conjuntamente um modelo de correção de erros (para a estrutura de longo prazo) e o modelo VAR (para a estrutura de curto prazo), como visto em Viale, Bessler e Kolari (2014).

O modelo desenvolvido por Forbes e Rigobon (2002), conhecido como teste FR, amplamente utilizado para medir o contágio, foi desenvolvido em função dos modelos anteriores não distinguirem bem o comovimento e o contágio, pois eles se concentravam principalmente nos canais pelos quais os choques negativos se propagam. Após o trabalho de Forbes e Rigobon (2002), os pesquisadores passaram a enfatizar as diferenças entre o comportamento causado pela interdependência normal e o contágio causado pela mudança estrutural.

Forbes e Rigobon (2002) em seu estudo, buscaram analisar o efeito do contágio do *crash* da bolsa americana de 1987, do colapso do peso mexicano de 1994 e da crise asiática de 1997 nos mercados asiáticos, principais membros da OECD (Organização para a Cooperação e Desenvolvimento Econômico), economias latinas e alguns países emergentes. O efeito contágio da interdependência apontou uma interdependência quando o comovimento entre mercados não aumentou significativamente após o choque causado por uma crise em alguma economia, enquanto no efeito contágio é percebido um significativo aumento no comovimento durante um choque qualquer.

Como visto em Kynigakis (2015), outras metodologias recentes que consideram momentos de ordem superior no mercado têm sido consideradas em estudos de contágio, como uma expansão do teste FR que considera a coassimetria (FRY, MARTIN E TANG, 2010), cocurtose e covolatilidade (FRY-MCKIBBIN E HSIAO, 2018). Momentos de ordem superior nas distribuições univariadas de retornos de ativos durante crises financeiras, como assimetria e curtose, fornecem informações adicionais sobre as preferências de retorno de risco do investidor. A importância de identificar o papel dos momentos de ordem superior também se aplica à identificação da importância dos movimentos entre os momentos nas distribuições multivariadas.

O teste de contágio de Li e Zhu (2014), não paramétrico, é baseado no teste paramétrico de Forbes e Rigobon (2002) e teve como objetivo investigar o efeito das crises asiática de 1997 e do *subprime* de 2007 em mercados asiáticos, países do G7 e economias latinas. Os autores utilizam o coeficiente de correlação de

classificação de Kendall, que não depende de restrições da normalidade bivariada. O teste não paramétrico é capaz de detectar padrões de contágios tanto lineares quanto não lineares. Amplamente usados por sua simplicidade e acurácia, são utilizados após aplicação inicial do VAR (APERGIS E CHRISTOU, 2017). Ambas as metodologias estão explicadas com maior detalhe na próxima seção - onde são incorporadas as modificações para aplicação nos criptoativos.

3.3 Principais Estudos Anteriores

Vidal-Tomás et al. (2018) analisaram o efeito manada no mercado digital usando CSSD e CSAD (com a abordagem de CHANG, CHENG E KHORANA 2000; CHIANG E ZHENG, 2010) durante o período de janeiro de 2015 a dezembro de 2017 para 65 criptoativos. Os autores empregaram uma carteira de mercado igualmente ponderada para calcular os retornos de mercado nos dois modelos. Observando os resultados, os autores encontraram um efeito manada no modelo CSSD, mas não no modelo CSAD. Foi possível observar que a dispersão extrema de retornos é explicada pelos modelos de precificação de ativos racionais, apesar do efeito manada ocorrer durante as baixas de mercado, o que destaca a ineficiência e o risco dos criptoativos. Os autores também concluíram que as moedas digitais menores estão apresentando efeito manada com as moedas maiores e que o efeito manada não pode ser atribuído apenas ao Bitcoin.

Bouri, Gupta e Roubaud (2018) estudaram o efeito manada em 14 principais criptoativos (Bitcoin, Ethereum, Ripple, Litecoin, Stellar, Dash, Nem, Monero, Bytecoin, Verge, Siacoin, BitShares, Decred e Dogecoin) durante o período de abril de 2013 a maio de 2018. Os autores analisaram o efeito manada por meio da abordagem CSAD (usando o retorno do mercado como uma média ponderada baseada no percentual de capitalização total dos 14 criptoativos) e um teste de robustez para detectar quebras estruturais na amostra (cinco quebras foram detectadas). O teste BDS foi aplicado aos resíduos do modelo (o teste de não linearidade de BROCK ET AL., 1996). Os resultados do modelo sugeriram que não havia efeito manada. No entanto, a presença de quebras estruturais e não linearidades na série de dados sugeriu que a aplicação do modelo não foi apropriada. Os autores conduziram uma análise com janelas de dados, e seus resultados

detectaram um efeito manada significativo, que varia ao longo do tempo. Utilizando uma regressão logística, os autores também descobriram que o efeito manada tendia a ocorrer com o aumento da incerteza.

Huynh, Nguyen e Duong, (2018) analisaram o contágio entre três criptoativos (Bitcoin, Litecoin e Ripple) durante o período de 2013 - 2017. Os autores avaliaram as relações usando a abordagem de cópulas para entender o movimento do retorno das criptocorrências baseado no preço. O objetivo dos autores foi de entender se o risco de contágio entre esses criptoativos ocorre ou não em caso de quedas bruscas no mercado (também chamado pelos autores de evento de *crashing*). Os resultados mostram que, com base nas análises gráficas de Kendall, todos os pares de criptoativos têm dependência de estrutura e, com base nos gráficos de Chi, existe uma dependência de cauda esquerda particularmente forte (isto é, o estudo indicou a existência de risco de contágio entre os criptoativos analisados). Os autores também concluíram que as três metodologias, ou seja, as estimativas de Kendall, Chi e Copulas, produzem resultados consistentes.

3.4 Metodologia e Base de Dados

As bases diárias de dados foram obtidas por meio do *website* crix.hu-berlin.de para o índice CRIX e por meio da base do *website* coinmarketcap para os criptoativos (com valores dolarizados). O levantamento inicial contemplou dados de 2013 – 2018, porém, para igualar o tamanho das amostras máximas entre as maiores moedas o recorte foi reduzido para 1.344 dados diários, abordando desta maneira um período total do recorte de dados de 03/2015 – 11/2018 (considerando dados diários e disponibilidade de dados), com o ranqueamento de moedas efetuado em 11/2018 - representado na tabela 1.

Tabela 1: Seleção dos 50 Criptoativos.

1	2	3	4	5	6
BTC Bitcoin	ETH Ethereum	XRP Ripple	XLM Stellar Lumens	LTC Litecoin	XMR Monero
7	8	9	10	11	12
Tether Tether Dollar	DASH Dash	DOGE Dogecoin	BTS BitShares	BCN Bytecoin	DGB DigiByte
13	14	15	16	17	18
XVG Verge	MAID MaidSafeCoin	MONA Monacoin	RDD ReddCoin	Nxt Nxt	SYS Syscoin

19	20	21	22	23	24
PPC Peercoin	NXS Nexus	GRS Groestlcoin	VTC VertCoin	EMC2 Einsteinium	UBQ Ubiq
25	26	27	28	29	30
BLOCK Blocknet	NAV NavCoin	BITCNY bitCNY	NVC Novacoin	XDN DigitalNote	VIA ViaCoin
31	32	33	34	35	36
BAY BitBay	BURST Burst	XWC WhiteCoin	CLOAK CloakCoin	BBR Boolberry	UNO Unobtanium
37	38	39	40	41	42
NLG Gulden	BITUSD BitUSD	GAME GameCredits	CSC CassinoCoin	XCP Counterparty	NMC Namecoin
43	44	45	46	47	48
FTC Feathercoin	XPM PrimeCoin	CRW Crown	FLO FlorinCoin	BLK BlackCoin	ECC ECC
49	50				
DMD Diamond	POT PotCoin				

Fonte: Própria.

Para facilitar o entendimento da metodologia, optou-se por subdividi-la em 3 etapas: apontando primeiramente o cálculo do índice CRIX; em segundo lugar a metodologia explorada no efeito manada com os modelos clássicos de Christie e Huang (1995), Chang, Cheng e Khorana (2000) e o modelo de estado e espaço com o filtro de Kalman de Hwang Salmon (2004); e finalmente a metodologia de contágio com Forbes e Rigobon (2002) e suas extensões considerando momentos de ordem superior elaboradas por Fry, Martin e Tang (2010) e Fry-McKibbin e Hsiao (2018). Os modelos possuem modificações para adaptação ao mercado digital, que seguem nos itens 3.1, 3.2 e 3.3.

3.4.1 Composição e Cálculo do Índice CRIX

Como observado por Elendner et al. (2016), o portfólio de 75 criptos no qual se baseia o CRIX (CRyptocurrency IndeX) apresenta um menor risco do que qualquer criptoativo individualmente e possui um rebalanceamento mensal. Este índice foi escolhido por apresentar a maior base de dados disponíveis em caráter diário e também por ter sido elaborado seguindo métricas robustas econométricas.

Segundo Trimborn e Härdle (2016), a ideia básica de qualquer índice de preços é o peso dos preços de seus bens constituintes pelas quantidades de bens

comprados ou consumidos. Logo, baseado na fórmula de Laspeyres, os autores desenvolveram uma adaptação para o CRIX que pode ser notado na equação 9.

$$CRIX_t(k, \beta) = \frac{\sum_{i=1}^k \beta_{i,t_n^-} P_{i,t} Q_{i,t_n^-}}{Divisor(k)_{t_n^-}}$$

Eq. (9)

Onde: a variável $P_{i,t}$ é o preço do ativo “i” no período “t”; $Q_{i,t}$ é a quantidade do ativo “i” no momento “t”; β_{i,t_n^-} é o fator de ajuste para o ativo “i” no ponto de tempo t_n^- , onde “n” indica o enésimo fator de ajuste e t_n^- o último ponto em que Q_{i,t_n^-} , o $Divisor(k)_{t_n^-}$ e β_{i,t_n^-} foram atualizados. O Divisor “k” garante que o valor do índice do CRIX tenha um valor predefinido na data de início (é definido na equação 10).

$$Divisor(k, \beta)_0 = \frac{\sum_{i=1}^k \beta_{i0} P_{i0} Q_{i0}}{Valor\ Inicial}$$

Eq. (10)

Onde o valor inicial pode ser definido como 100, 1.000 ou 10.000, garantindo que um desenvolvimento positivo ou negativo do período base seja revelado. Sempre que as mudanças na estrutura do CRIX ocorrem, o Divisor (k) é ajustado de tal forma que somente as mudanças de preços são refletidas pelo índice.

O método de escolha das moedas depende do critério AIC e é proposto para reagir rapidamente às mudanças do mercado e, portanto, permite criar um índice econometricamente robusto, aplicando validação cruzada (CV), validação cruzada total (FCV), validação cruzada generalizada (GCV) e validação cruzada total generalizada (GFCV). Alguns estudos interessantes com CRIX incluem Elendner et al. (2016), Chen et al. (2016), Trimbom, Li e Härdle (2017) e Chen et al. (2018).

3.4.2 Efeito Manada

A primeira metodologia que foi utilizada neste trabalho para avaliar o efeito manada considera a medida proposta por Christie e Huang (1995), assim como exposto anteriormente no referencial teórico, sendo conhecida pelo desvio padrão

transversal dos retornos ou CSSD (*Cross-Sectional Standard Deviation*). Esta metodologia foi modificada na equação 11 ao se substituir o retorno de mercado pelo retorno do índice CRIX, com o intuito de se aplicar ao mercado de criptoativos.

$$CSSD_t = \sqrt{\sum_{i=1}^N (R_{i,t} - R_{CRIX\ Index})^2 / N - 1}$$

Eq. (11)

$$CSSD_t = \alpha + \gamma_1 D_t^L + \gamma_2 D_t^U + \varepsilon_t$$

Eq. (6)

A segunda metodologia proposta para se avaliar o efeito manada neste trabalho é o método de Chang, Cheng e Khorana (2000), o método CCK é uma abordagem alternativa ao método CH para testar o efeito manada. Desta forma, aplicou-se o CSAD (*Cross-Sectional Absolute Deviation*), que é o cálculo do desvio absoluto transversal dos retornos (já definido por meio da equação 7) com a modificação para o mercado de moedas digitais substituindo o retorno de mercado pelo retorno do índice CRIX na equação 12 e 13 - foi utilizada a regressão robusta no CSSD e no CSAD para se evitar *outliers*.

$$CSAD_t = \frac{1}{N} \sum_{i=1}^N |R_{i,t} - R_{CRIX\ Index}|$$

Eq. (12)

$$CSAD_{i,t} = \alpha + \gamma_1 |R_{CRIX\ INDEX,t}| + \gamma_2 R_{CRIX\ INDEX,t}^2 + \varepsilon_t$$

Eq. (13)

A terceira metodologia proposta para se avaliar o efeito manada neste trabalho contemplou o método de Hwang e Salmon (2004), onde será estimado o modelo de estado e espaço com o filtro de Kalman. Na mesma linha da abordagem CSAD, Hwang e Salmon (2004) também consideram como uma medida de manada adequada aquela incorporada na relação risco-retorno, focando na variância transversal do fator de sensibilidades baseado em um modelo de estado e espaço. Ao contrário da abordagem da CSSD, o modelo de estado e espaço é capaz de

detectar o comportamento de manada durante períodos de normalidade de mercado, permitindo uma investigação dinâmica ao longo do tempo.

Para se desenvolver o modelo de Hwang e Salmon (2004), foram calculados os desvios padrões diários dos conjuntos de betas diários de todas as moedas (que foram obtidos pela regressão simples entre cada moeda e o índice CRIX, em base de janela de dados semanais) e após isto, dos resultados, foram obtidos os logs (onde puderam ser aplicadas as equações 14 e 15 por meio do *software* Eviews 10 seguindo os códigos: @signal log_devbetas = c (1) + SV1 + [var = exp (c(2))] e @state SV1=c(3)*SV1(-1)+[var=exp(c(4))] modelo de estado e espaço.

$$\log[Std(\beta_{imt}^b)] = \mu_m + H_{mt} + v_{mt} \quad \text{Eq. (14)}$$

$$H_{mt} = \phi_m H_{mt-1} + \eta_{mt} \quad \text{Eq. (15)}$$

Onde: $\mu_m = E(\log[Std(\beta_{imt}^b)])$ é assumido como sendo constante no curto prazo; e, $v_{mt} \sim iid(0, \sigma_{m\eta}^2)$; $E(\cdot)$ e $Std(\cdot)$ representam o valor esperado e o desvio padrão da seção transversal, respectivamente; β_{it} é a medida sistemática de risco; $H_{mt} = \log(1 - h_{mt})$; e, $\eta_{mt} \sim iid(0, \sigma_{m\eta}^2)$. Quando $\sigma_{m\eta}^2 = 0$, não existe efeito manada, o que implica em $H_{mt} = 0$ para todos t .

As equações (14) e (15) representam o modelo básico de estado espaço com estimadores de filtro de Kalman. Neste estudo, o foco está na variável H_{mt} , que varia ao longo do tempo. Um valor estatisticamente significativo para $\sigma_{m\eta}^2$ pode ser interpretado como sendo representativo para o efeito manada e um valor estatisticamente significativo para ϕ_m dá suporte para um modelo autorregressivo do efeito manada em particular.

3.4.3 Efeito Contágio

A primeira metodologia para se medir o efeito contágio nos criptoativos será composta pela modificação nos testes FR de contágio paramétrico de Forbes e

Rigobon (2002), que é baseado no coeficiente de Pearson para correlação entre mercados. O coeficiente de Pearson, no teste FR, é definido na equação 16.

$$v_{y|x_i} = \frac{\delta}{\sqrt{1 + \left(\frac{\sigma_{y,i}^2 - \sigma_{x,i}^2}{\sigma_{x,i}^2} \right) (1 - \delta^2)}}$$

Eq. (16)

Onde: σ de x e y representam as variâncias das moedas x e y respectivamente, sendo x representado pelo Bitcoin e y pelas demais moedas; δ é o coeficiente de correlação entre duas moedas.

O teste estatístico FR para medir a presença do efeito contágio da moeda “i” para a moeda “j” é definido na equação 17 considerando a modificação na fórmula original. Para melhora das propriedades da amostra finita da estatística de teste, os autores fazem uso da transformação de Fisher.

$$FR(i \rightarrow j) = \frac{\frac{1}{2} \ln \left(\frac{1 + \hat{v}_{y|x_i}}{1 - \hat{v}_{y|x_i}} \right) + \frac{1}{2} \ln \left(\frac{1 + \delta}{1 - \delta} \right)}{\sqrt{\frac{1}{T-3} + \frac{1}{T-3}}}$$

Eq. (17)

Onde: o termo δ é o coeficiente de correlação entre as duas moedas; T é o número de amostra a ser comparado para o mercado de moedas digitais (no caso deste estudo, são 1.344 observações). O valor crítico obtido no teste t deve ser comparado com o teste FR na distribuição normal onde $H_0: \hat{v}_{y|x_i} \leq \hat{p}_x$ (que não apresenta o contágio) e $H_1: \hat{v}_{y|x_i} > \hat{p}_x$ (que apresenta o contágio).

O segundo, terceiro e quarto métodos para avaliar o efeito de contágio usam uma extensão do teste FR baseado nos critérios definidos por Fry, Martin e Tang, (2010) e Fry-McKibbin e Hsiao (2018). Momentos de ordem superior nas distribuições univariadas de retornos de ativos durante a crise financeira, como assimetria e curtose, fornecem informações adicionais sobre as preferências dos investidores em relação ao risco x retorno. A importância de identificar o papel dos momentos de ordem superior também se aplica à importância de identificar os movimentos entre esses momentos nas distribuições multivariadas.

A equação 18 define o teste de coassimetria de Fry, Martin e Tang (2010), modificado para comparar as moedas de forma diferente da fórmula original, que avalia o contágio entre diferentes mercados nos períodos pré e pós- crise. As mesmas modificações aplicam-se aos testes de cocurtose e covolatilidade nas equações 19 e 20, respectivamente; ambos são baseados em (FRY-MCKIBBIN E HSIAO 2018).

$$CS = \left[\frac{\left(\frac{1}{T} \sum_{t=1}^T y \left(\frac{y - \hat{\mu}_y}{\hat{\sigma}_y} \right) \left(\frac{y - \hat{\mu}_y}{\hat{\sigma}_y} \right)^1 \right) - \left(\frac{1}{T} \sum_{t=1}^T x \left(\frac{x - \hat{\mu}_x}{\hat{\sigma}_x} \right) \left(\frac{x - \hat{\mu}_x}{\hat{\sigma}_x} \right)^2 \right)}{\sqrt{\left(\frac{4v}{T} y | x_i^{+2} \right) \left(\frac{4\delta^2 + 2}{T} \right)}} \right]^2$$

Eq. (18)

$$CK = \left[\frac{\left(\frac{1}{T} \sum_{t=1}^T y \left(\frac{y - \hat{\mu}_y}{\hat{\sigma}_y} \right) \left(\frac{y - \hat{\mu}_y}{\hat{\sigma}_y} \right)^1 - 3v y | x_i \right) - \left(\frac{1}{T} \sum_{t=1}^T x \left(\frac{x - \hat{\mu}_x}{\hat{\sigma}_x} \right) \left(\frac{x - \hat{\mu}_x}{\hat{\sigma}_x} \right)^3 - 3\delta \right)}{\sqrt{\left(\frac{18v^2}{T} y | x_i^{+6} \right) \left(\frac{18\delta^2 + 6}{T} \right)}} \right]^2$$

Eq. (19)

$$CVol = \left[\frac{\left(\frac{1}{T} \sum_{t=1}^T y \left(\frac{y - \hat{\mu}_y}{\hat{\sigma}_y} \right) \left(\frac{y - \hat{\mu}_y}{\hat{\sigma}_y} \right)^2 - (1 + 2v^2 y | x_i) \right) - \left(\frac{1}{T} \sum_{t=1}^T x \left(\frac{x - \hat{\mu}_x}{\hat{\sigma}_x} \right) \left(\frac{x - \hat{\mu}_x}{\hat{\sigma}_x} \right)^2 - (1 + 2\delta^2) \right)}{\sqrt{\left(\frac{4v^4}{T} y | x_i^{+4} + \frac{16v^2}{T} y | x_i^{+4} \right) \left(\frac{4\delta^4 + 16\delta^2 + 4}{T} \right)}} \right]^2$$

Eq. (20)

Para as equações de coassimetria (CS), cocurtose (CK) e covolatilidade (CVol), o valor crítico obtido no teste t deve ser comparado com os respectivos testes na distribuição normal onde diferente do teste unicaudal do modelo FR, nestes modelos ocorre um teste bicaudal em que a hipótese nula não apresenta o contágio e a hipótese alternativa apresenta o contágio.

É importante acrescentar que no trabalho de Forbes e Rigobon (2002) os autores apontam a necessidade de se efetuar o estudo comparativo antes e durante uma “crise”, porém, os mesmos autores apontam em seu trabalho que é obvio que

o contágio também pode ocorrer em outros períodos, porém, durante eventos atípicos de mercado (crises), esses efeitos são mais pronunciados.

3.5 Resultados

3.5.1 Efeito Manada

Primeiramente é apresentado o sumário estatístico do CSSD e CSAD consolidado e anual ao longo das observações (tabela 2). É possível fazer uma comparação com o mercado acionário ao se considerar os dados do estudo de Chen (2013) em mercados desenvolvidos e emergentes durante 2000 – 2009 (tabela 3).

É possível notar que para os criptoativos, o retorno diário médio no período é relativamente alto - sendo próximo ao mercado do Canadá. Porém, o desvio padrão do retorno diário, do CSSD e CSAD é completamente diferente, apontando um desvio padrão muito elevado para os criptoativos. Desta forma, pode-se interpretar que os criptoativos possuem uma maior variação de mercado e maior retorno, com um maior risco.

O CSSD e CSAD médios e o desvio no período de 2015- 2018 são bastante elevados ao se comparar com os mercados da tabela 3. Quando se avalia os anos separadamente, pode-se notar uma proximidade maior com o mercado do Canadá.

Tabela 2: Sumário Estatístico de Retorno, CSSD e CSAD (em porcentagem).

Moedas		Observações Diárias	
49		1344	
Média			
Período	Retorno Diário	CSSD	CSAD
2015-2018	0,2509	11,6624	6,8156
2015	-0,0290	12,4402	6,6949
2016	0,2555	12,8196	6,6697
2017	1,1877	12,2845	7,3571
2018	-0,5716	8,8838	6,4734
Desvio Padrão			
Período	Retorno Diário	CSSD	CSAD
2015-2018	10,8860	6,0497	2,6274
2015	12,2124	4,8841	1,9115
2016	12,5460	5,5548	1,9951
2017	11,7342	5,6953	2,3959
2018	6,7543	7,0684	3,7714

Fonte: Própria.

Tabela 3: Sumário Estatístico do Mercado Acionário Global 2000-2009 (em porcentagem).

Mercados Desenvolvidos							
País	Ações	Média			Desvio Padrão		
		Ret.	CSSD	CSAD	Ret.	CSSD	CSAD
Alemanha	1556	0,0490	5,2540	2,3670	0,7560	1,6160	0,7410
Austrália	1154	0,1120	5,5810	2,7940	0,8310	1,4980	0,8290
Áustria	83	0,0450	2,7560	1,3050	0,6320	1,8890	0,7450
Bélgica	178	0,2280	6,9360	2,1920	0,7230	3,3030	0,9110
Canadá	2392	0,3120	8,4850	3,8920	0,8480	2,7420	1,4490
Dinamarca	168	0,0420	2,6170	1,3950	0,6400	1,3000	0,6560
Espanha	105	0,0310	1,9770	1,2830	0,8530	0,9360	0,5280
Estados Unidos	3797	0,0860	4,0050	2,2220	1,2100	1,4100	0,9210
Finlândia	122	0,0370	2,9370	1,7250	0,8780	1,3180	0,7100
França	637	0,0610	3,8550	1,7440	0,5960	1,1910	0,5650
Grécia	247	-0,0410	2,8440	1,9140	1,6970	0,9770	0,6380
Holanda	110	0,0280	2,9030	1,6780	0,9750	1,5010	0,6810
Hong Kong	846	0,0820	4,4170	2,3750	1,1680	1,5440	0,9310
Inglaterra	1150	0,0160	3,3170	1,5010	0,6000	1,1300	0,5740
Irlanda	40	0,0820	3,7930	2,1530	1,0600	2,4050	1,1680
Israel	471	0,0350	3,2530	1,6150	0,8060	1,2800	0,7180
Itália	248	0,0040	2,2240	1,4510	0,9480	0,9290	0,5590
Japão	2457	0,0260	2,6770	1,7050	1,0560	0,9140	0,6270
Noruega	140	0,0500	3,2650	1,9110	0,9460	1,4640	0,7760
Nova Zelândia	97	0,0440	3,5260	1,5500	0,5930	2,0230	0,6350
Portugal	56	0,0360	2,6890	1,2960	0,7090	2,3120	0,7650
Singapura	500	0,0870	4,8880	2,4530	1,1710	1,8050	0,8830
Suíça	212	0,0280	2,3780	1,4150	0,7030	1,0400	0,5820
Mercados Emergentes							
País	Ações	Média			Desvio Padrão		
		Ret.	CSSD	CSAD	Ret.	CSSD	CSAD
África do Sul	284	0,1460	5,1830	1,9820	0,5870	2,0680	0,6620
Brasil	446	0,1220	3,8510	1,4130	0,6110	1,7540	0,6790
Chile	201	0,0430	1,6550	0,6490	0,3070	1,1040	0,3430
China	1206	0,0660	2,0400	1,4620	1,8540	0,9220	0,7000
Coréia do Sul	1310	0,0670	3,7080	2,5270	1,6740	1,1770	0,9290
Egito	98	0,0890	2,8180	1,6830	1,2070	1,8640	0,7740
Eslováquia	26	0,1270	1,9490	1,0900	1,4420	3,0660	1,9610
Filipinas	213	0,1010	4,0840	1,7900	0,8920	1,6940	0,9040
Hungria	16	0,0780	2,6830	1,7180	1,2610	2,6950	1,3500
Índia	1392	0,1130	3,5140	2,2700	1,4710	1,1660	0,7720
Indonésia	297	0,0930	4,2420	2,1160	0,9970	1,6430	0,9570
Malásia	764	0,0520	3,7580	1,9650	1,1660	1,6870	0,8030
México	119	0,0590	2,1750	1,1050	0,5910	1,2160	0,5590
Polônia	113	0,1020	4,1090	2,3650	1,0850	1,8280	0,8540
República Checa	17	0,0510	1,5690	0,9750	0,7150	1,3060	0,7890
Rússia	94	0,1020	2,7030	0,8090	0,6900	3,4370	1,2240
Tailândia	404	0,0640	3,0160	1,6400	0,9480	1,2280	0,7120
Taiwan	640	0,0430	2,3620	1,7490	1,5230	0,7390	0,6180
Turquia	274	0,1060	2,9960	1,9880	2,0630	1,0560	0,7250
Venezuela	47	0,0890	2,1590	0,9170	0,5810	1,8560	0,8360

Fonte: Chen (2013).

As tabelas 4 e 5 especificam os resultados dos coeficientes dos modelos CSSD e CSAD. É possível observar na tabela 4 o efeito manada nos resultados do modelo CSSD durante o período de queda de mercado (para todas as séries de dados), uma vez que y_1 é negativo e significativo. Por outro lado, na tabela 5, nota-

se que γ_2 é negativo e não significativo com $\alpha = 10\%$ (indicando um efeito manada fraco com $\alpha = 15\%$) para todos os períodos, exceto para 2018, onde é negativo e significativo (indicando um claro efeito manada).

Tabela 4: Resultado do teste CSSD.

$$CSSD_t = \alpha + \gamma_1 D_t^L + \gamma_2 D_t^U + \varepsilon_t$$

Critério para os Extremos de 1%					
Variáveis	2015 - 2018	2015	2016	2017	2018
α	0,1077***	0,1165***	0,1202***	0,1128***	0,0785***
γ_1	-0,0717***	-0,0618**	-0,0775***	-0,0663***	-0,0451***
γ_2	0,2288***	0,1927***	0,2145***	0,2231***	0,2731***
Critério para os Extremos de 2%					
Variáveis	2015 - 2018	2015	2016	2017	2018
α	0,1080***	0,1167***	0,1203***	0,1126***	0,0788***
γ_1	-0,0692***	-0,0591***	-0,0732***	-0,0631***	-0,0440***
γ_2	0,1962***	0,1692***	0,1956***	0,1829***	0,1546***
Critério para os Extremos de 5%					
Variáveis	2015 - 2018	2015	2016	2017	2018
α	0,1077***	0,1167***	0,1199***	0,1123***	0,0786***
γ_1	-0,0628***	-0,0562***	-0,0650***	-0,0564***	-0,0410***
γ_2	0,1467***	0,1319***	0,1553***	0,1397***	0,1029***
Critério para os Extremos de 10%					
Variáveis	2015 - 2018	2015	2016	2017	2018
α	0,1069***	0,1157***	0,1187***	0,1123***	0,0779***
γ_1	-0,0557***	-0,0512***	-0,0573***	-0,0501***	-0,0364***
γ_2	0,1146***	0,1072***	0,1213***	0,1130***	0,0776***

Onde γ_1 negativo e estatisticamente significativo significa a presença de efeito manada na queda de mercado e caso contrário não há efeito manada; já γ_2 negativo e estatisticamente significativo significa a presença de efeito manada na subida de mercado e caso contrário não há efeito manada. * $p < 0.10$; ** $p < 0.05$; *** $p < 0.01$.

Fonte: Própria.

Tabela 5: Resultado do teste CSAD.

$$CSAD_{i,t} = \alpha + \gamma_1 |R_{CRIX\ INDEX,t}| + \gamma_2 R_{CRIX\ INDEX,t}^2 + \varepsilon_t$$

Período	Variáveis	Coefficientes	Erro Padrão	Probabilidade
2015-2018	α	0,0581***	0,0009	0,0000
	γ_1	0,3307***	0,0414	0,0000
	γ_2	-0,4713	0,2980	0,1137
2015	α	0,0636***	0,0017	0,0000
	γ_1	-0,072	0,1231	0,5593
	γ_2	4,0942***	1,3111	0,0018
2016	α	0,0612***	0,0014	0,0000
	γ_1	0,2386**	0,1046	0,0225
	γ_2	1,0832	0,9311	0,2447
2017	α	0,0649***	0,0020	0,0000
	γ_1	0,2444***	0,0755	0,0012
	γ_2	-0,7077	0,4928	0,1510
2018	α	0,0392***	0,0020	0,0000
	γ_1	0,6677***	0,0754	0,0000
	γ_2	-1,3282***	0,4847	0,0061

Onde γ_2 representa o desvio dos retornos quadrados de mercado e para existir efeito manada este coeficiente precisa ser negativo e estatisticamente significativo. * $p < 0.10$; ** $p < 0.05$; *** $p < 0.01$.

Fonte: Própria.

Nos resultados do modelo HS, na tabela 6, o coeficiente associado ao efeito manada ϕ_m é positivo e significativo em todas as séries de dados (indicando efeito manada no período e a cada ano). É possível notar que no período completo (2015 - 2018), H_{mt} é altamente persistente, com o termo ϕ_m igual a 0.8525 e o coeficiente de η_{mt} , representando o logaritmo do termo de erro de variância, também altamente significativo.

Tabela 6: Resultado Modelo HS de estado espaço com filtro de Kalman.

$\log[Std(\beta_{imt}^b)] = \mu_m + H_{mt} + v_{mt}$					
$H_{mt} = \phi_m H_{mt-1} + \eta_{mt}$					
Coeficientes					
	2015 - 2018	2015	2016	2017	2018
μ_m	-0,5740***	-0,5715***	-0,6313***	-0,5626***	-0,5052***
v_{mt}	0,0039***	0,0052***	0,0001***	0,0042***	0,0062***
ϕ_m	0,8525***	0,9186***	0,8281***	0,8760***	0,7026***
η_{mt}	0,0103***	0,0025***	0,0187***	0,0105***	0,0075***

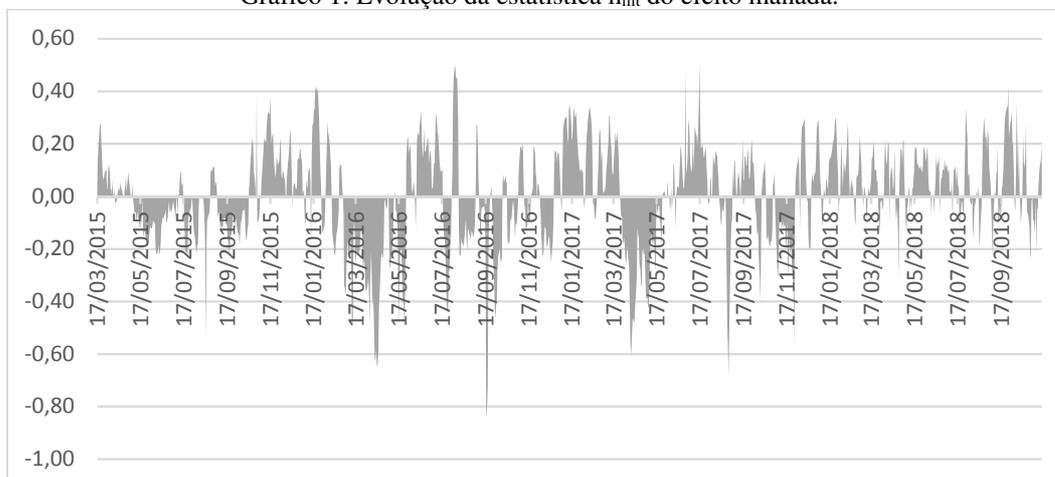
Onde ϕ_m positivo e estatisticamente significativo significa a presença de efeito manada. *p<0.10; **p<0.05 and ***p<0.01

Fonte: Própria.

O gráfico 1 mostra a evolução da medida estatística ($h_{mt}=1-\exp(-H_{mt})$) do efeito manada no período de 2015 a 2018 - embora o efeito manada esteja presente nas moedas observadas, valores extremos de manada reversa são notados.

De maneira geral, como visto em Elkhaldi e Abelfatfeh (2014), o efeito manada e o efeito manada reverso são mecanismos que agem sinergicamente. O efeito manada reverso é sinônimo de reversão à média de β_{imt} em valores de equilíbrio de longo prazo. Quando o efeito manada é confirmado, o efeito manada reverso deve ocorrer gradualmente a fim de fazer um ajuste sistemático

Gráfico 1: Evolução da estatística h_{mt} do efeito manada.



Fonte: Própria.

Em 2015, particularmente, somente no início do ano pode-se notar um comportamento positivo no efeito manada, que pode ter sido influenciado pelo ataque de *hackers* na *exchange* de moedas digitais Bitstamp (a empresa perdeu um total de US \$ 5,1 milhões).

De maio a novembro de 2015, a predominância foi um comportamento de manada reverso, onde notícias positivas foram destaque, como: registros na captação de recursos para Ofertas Iniciais de Moedas (ICOs) - na Coinbase e Stealth 21 Inc.; a NASDAQ divulgou sua pesquisa sobre soluções *blockchain*; o Bitcoin foi declarado uma *commodity* pelo regulador dos EUA; o Tribunal de Justiça Europeu determinou que a troca de Bitcoin e "moedas digitais" não está sujeita ao imposto sobre valor agregado na União Européia; o Bitcoin apareceu proeminentemente na primeira página da "The Economist"; e o comitê Unicode aceitou o símbolo monetário Bitcoin.

Entre meados de dezembro de 2015 até março de 2016, foi possível observar um movimento positivo no efeito manada. Alguns destaques deste período são: o *fork* do Bitcoin para o Bitcoin Unlimited (em 15 de janeiro de 2016); o *fork do* Bitcoin para Bitcoin Classic (em 10 de fevereiro de 2017); os esforços agressivos do Japão para a adoção de moedas digitais em finanças e pagamentos; a chegada de uma nova *exchange* de moedas digitais chamada BitSquare; o Parlamento Europeu votou a favor do Bitcoin; o anúncio de que a cidade suíça de Zug e alguns países europeus começariam a aceitar o Bitcoin para pagamentos de serviços públicos.

Do final de junho de 2016 até setembro de 2016, alguns casos predominantes de efeito manada podem ser notados e algumas notícias interessantes foram apontadas: a recompensa de mineração caiu de 25 Bitcoins (BTC) por bloco para 12,5 BTC; os Bitcoins da Bitfinex foram roubados em 08 de agosto de 2016 causando desconforto no mercado; a BitFinex anunciou um plano de reembolso para portadores de *tokens*; e um escândalo de *bug* de memória ocorreu na rede Ethereum.

Entre o final de setembro de 2016 e fevereiro de 2017, foi possível notar um efeito manada reverso e algumas novidades neste período: desvalorização do yuan; eleições nos Estados Unidos (com o chamado "efeito Trump"); a *Securities and Exchange Commission* (SEC) dos EUA rejeitou o ETF da Bitcoin (*Exchange Traded Funds*); o Banco da China tentou regular as moedas digitais e reprimir todos os negócios com Bitcoin.

No final de fevereiro de 2017 até abril de 2017, fatores como: o Brexit (referindo-se à decisão do Reino Unido de deixar a União Européia); as eleições francesas (com a posição do presidente Macron sobre moedas digitais); e o anúncio da reforma tributária pelo presidente dos EUA, Donald Trump, aparentemente impulsionou o efeito manada no mercado.

De maio de 2017 até julho de 2017, uma reversão no efeito manada foi observado, e as principais notícias observadas foram: a declaração do Japão de que o Bitcoin seria aceito como um método de pagamento legal; e a Conferência Anual de Consenso em Nova York, onde um plano foi delineado para a adoção do SegWit com um *fork* planejado para ocorrer em seis meses e modificação para um tamanho de bloco de 2MB.

Entre agosto e setembro de 2017, o efeito manada foi mais proeminente e foi acompanhado por notícias como: o *fork* do SegWit (em 23 de agosto de 2017); a regulamentação da China sobre empresas que levantaram dinheiro através de ICOs; e o pronunciamento do Bitcoin como fraude pelo CEO do JP Morgan (Jamie Dimon). No final de outubro de 2017, o CME Group anunciou planos para introduzir o mercado de futuros de Bitcoin até o final do ano, aparentemente estimulando uma reversão do efeito manada.

De novembro de 2017 até dezembro de 2017, foi observada uma reversão no efeito manada, acompanhada de novidades como: o cancelamento do Segwit2X e um novo *fork* do Bitcoin (em 12 de novembro de 2017 para o Bitcoin Gold); a aprovação da *Commodities Futures Trading Commission* (CFTC) sobre futuros negócios de Bitcoin; e o preço do Bitcoin atingindo o maior valor de \$ 20.000.

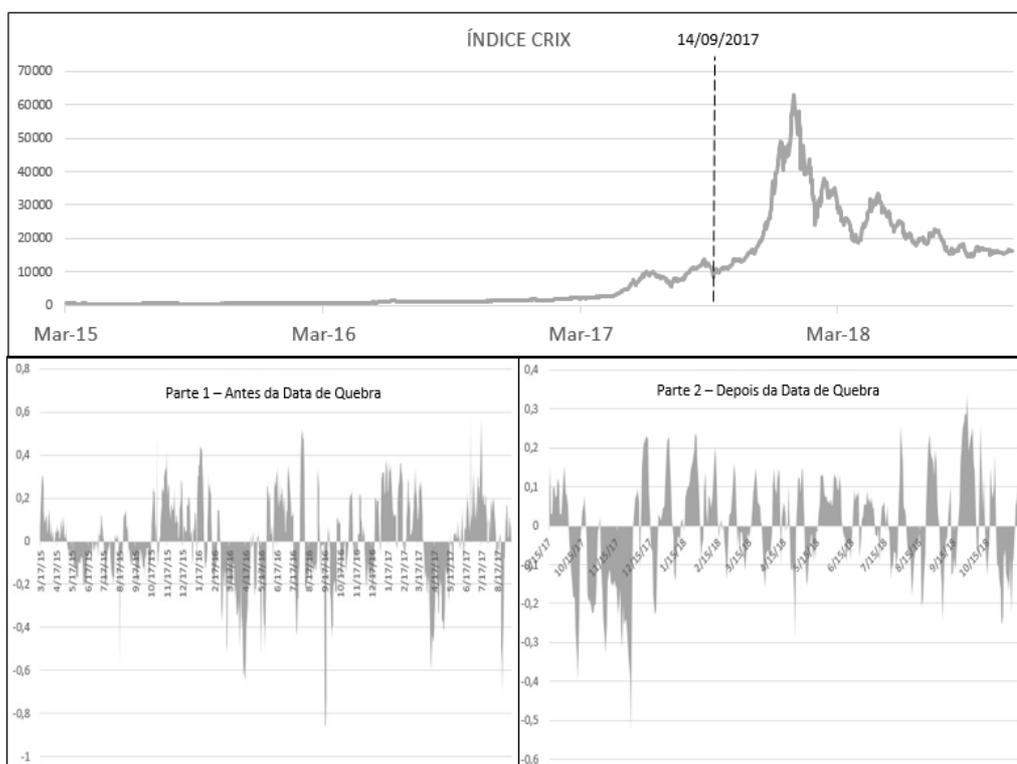
Durante 2018, o efeito manada foi dominado por um cenário de pessimismo em torno do mercado digital, uma vez que o Bitcoin despencou depois de atingir o preço máximo de US \$ 20.000. Embora, por um lado, a crise de liquidez tenha forçado as pessoas a realizar seus investimentos em moedas digitais, o que era esperado, dada a falta de entusiasmo no mercado digital, por outro lado os especialistas e fãs de criptos permaneceram positivos e esperançosos sobre o futuro do Bitcoin e do mercado digital.

Portanto, é possível conjecturar que os investidores do mercado de moedas digitais tendem a ser mais afetados por informações / influências negativas quando existe efeito manada, do que por informações / influências positivas (quando há um efeito manada reverso). Ou seja, observa-se que um investidor é mais avesso ao

risco no domínio da perda e que o Bitcoin impulsiona / direciona os fluxos de investimento em criptos.

Para uma análise complementar, foi realizado um teste de robustez na série temporal apresentada anteriormente no gráfico 1, onde foi realizado o teste de raiz unitária Zivot-Andrews (ZIVOT E ANDREWS, 1992) para se avaliar a data de quebra estrutural e foi encontrado um intervalo de data em 14 de setembro de 2017 no CRIX INDEX (que representa o mercado). O gráfico 2 representa o resultado do teste de Zivot-Andrews, bem como as séries temporais nos períodos antes (Parte 1) e depois (Parte 2) da data da quebra estrutural.

Gráfico 2: Teste Zivot-Andrews com o efeito manada.



Fonte: Própria.

Mesmo analisando os períodos de maneira separada, foi possível encontrar efeito manada nos dois casos (como pode ser melhor visualizado na tabela 7).

Tabela 7: Teste HS para os períodos antes e depois da quebra estrutural de data.

Parte 1: Antes da data de quebra				
	Coefficient	Std. Error	z-Statistic	Prob.
μ_m	-0.5950***	0.0262	-22.7256	0.0000
u_{mt}	0.0024***	0.1711	-35.2345	0.0000
\emptyset_m	0.8612***	0.0180	47.9382	0.0000

η_{mt}	0.0114***	0.0646	-69.1592	0.0000
Parte 2: Depois da data de quebra				
	Coefficient	Std. Error	z-Statistic	Prob.
μ_m	-0.5288***	0.0205	-25.7808	0.0000
v_{mt}	0.0064***	0.1943	-25.9661	0.0000
ϕ_m	0.7664***	0.0472	16.2263	0.0000
η_{mt}	0.0084***	0.2259	-21.1081	0.0000

Onde ϕ_m positivo e estatisticamente significativo indica a presença do efeito manada e v_{mt} aponta a volatilidade.
*p: <0.10, **: p<0.05; ***: p<0.01.

Fonte: Própria.

Embora os resultados do coeficiente ϕ_m mostrem semelhança, os dados da “Parte 2” indicam um valor menor no efeito manada, o que pode indicar uma reversão no efeito manada influenciado pela queda após dezembro de 2017. É importante observar o aumento da volatilidade v_{mt} nesta segunda parte, o que também pode influenciar essa diferença encontrada nos períodos.

3.5.2 Efeito Contágio

Após a realização do teste de contágio paramétrico segundo Forbes e Rigobon (2002), com o Bitcoin como base de interação entre as outras 49 moedas, foi possível perceber que os resultados obtidos no teste FR foram contra a rejeição da hipótese nula (sem contágio). A tabela 8 mostra os resultados de todo o período (2015 – 2018), onde CT significa que houve contágio e “-” “não. Além disso, é apresentado o resultado por ano na tabela 9.

Tabela 8: Teste de Contágio FR para 2015 - 2018.

Moeda	ETH	XRP	XLM	LTC	XMR	Tether	DASH	DOGE
Teste FR	3,69***	0,79***	6,75***	13,01***	9,95***	-1,99***	9,82***	11,1***
Efeito	CT	-	CT	CT	CT	-	CT	CT
Moeda	BTS	BCN	DGB	XVG	MAID	MONA	RDD	Nxt
Teste FR	8,09***	4,67***	6,11***	3,87***	8,75***	5,66***	4,48***	9,29***
Efeito	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	SYS	PPC	NXS	GRS	VTC	EMC2	UBQ	BLOCK
Teste FR	6,71***	10,19***	4,39***	3,81***	5,33***	5,78***	2,71***	4,23***
Efeito	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	NAV	BITCNY	NVC	XDN	VIA	BAY	Burst	XWC
Teste FR	4,56***	0,82***	6,93***	6,81***	5,68***	6,74***	6,83***	5,05***
Efeito	CT	-	CT	CT	CT	CT	CT	CT
Moeda	CLOAK	BBR	UNO	NLG	BITUSD	GAME	CSC	XCP
Teste FR	3,34***	3,45***	7,52***	6,32***	1,42**	4,54***	0,40***	6,45***
Efeito	CT	CT	CT	CT	-	CT	-	CT
Moeda	NMC	FTC	XPM	CRW	FLO	BLK	ECC	DMD
Teste FR	6,90***	5,52***	8,05***	1,44**	5,19***	8,8***	0,64***	7,87***
Efeito	CT	CT	CT	-	CT	CT	-	CT

Moeda	POT
Teste FR	6,06***
Efeito	CT

*p<0,10; **p<0,05; ***p<0,01.
Fonte: Própria.

Em algumas moedas, como XRP, Tether, BITCNY, BITUSD, CSC, CRW e ECC, não foi possível encontrar contágio pelo Bitcoin. A maioria dessas moedas compartilha a estabilidade de preços em função de possuírem moedas associadas (ao dólar americano, por exemplo) e tem controle inflacionário em diferentes formas. Apenas o Tether, o BITCNY e o ECC foram consistentes, não apresentando nenhum contágio com o Bitcoin ao longo de todos os anos (como pode ser vista na tabela 9).

Tabela 9: Teste de Contágio FR por ano.

Moedas em que não houve contágio					
2015 - 2018	2015	2016		2017	2018
XRP	ETH	ETH	VIA	XRP	XRP
Tether	XRP	XRP	BAY	Tether	Tether
BITCNY	Tether	XLM	Burst	BCN	BITCNY
BITUSD	XVG	XMR	XWC	DGB	BITUSD
CSC	MONA	Tether	CLOAK	XVG	CSC
CRW	RDD	DASH	BBR	RDD	NMC
ECC	NXS	BTS	NLG	GRS	
	VTC	BCN	BITUSD	UBQ	
	UBQ	DGB	GAME	CLOAK	
	BLOCK	XVG	CSC	BBR	
	NAV	MAID	XCP	CSC	
	BITCNY	MONA	FTC	ECC	
	BAY	RDD	XPM		
	XWC	Nxt	CRW		
	CLOAK	SYS	FLO		
	BBR	NXS	BLK		
	BITUSD	GRS	ECC		
	GAME	VTC	POT		
	CSC	EMC2			
	FTC	UBQ			
	CRW	BLOCK			
	FLO	NAV			
	ECC	BITCNY			
	DMD	XDN			

Fonte: Própria.

Na tabela 10, o teste de contágio de coassimetria (CS) foi capaz de capturar o contágio de Bitcoin durante todo o período de 2015 até 2018. No entanto, é interessante observar que nos resultados do teste CS por ano, o Tether apareceu em 2015 e o BITUSD em 2016.

Tabela 10: Teste de Contágio de Coasimetria de 2015 – 2018.

Moeda	ETH	XRP	XLM	LTC	XMR	Tether	DASH	DOGE
Teste de CS	688,33	3680,51	1613,29	268,96	412,72	153,96	385,01	352,63
Efeito	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	BTS	BCN	DGB	XVG	MAID	MONA	RDD	Nxt
Teste de CS	358,05	371,85	2560,10	223,40	22,29	1861,67	748,94	241,20
Efeito	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	SYS	PPC	NXS	GRS	VTC	EMC2	UBQ	BLOCK
Teste de CS	279,08	7,13	229,45	1089,17	899,72	1422,03	38252,61	115,40
Efeito	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	NAV	BITCNY	NVC	XDN	VIA	BAY	Burst	XWC
Teste de CS	2237,21	1099,18	504,38	1258,01	371,67	220,59	371,05	1090,01
Efeito	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	CLOAK	BBR	UNO	NLG	BITUSD	GAME	CSC	XCP
Teste de CS	730,12	270,71	6,35	246,57	12,61	840,11	43015,33	543,955
Efeito	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	NMC	FTC	XPM	CRW	FLO	BLK	ECC	DMD
Teste de CS	189,66	44,97	628,95	134,13	359,16	702,94	93,13	406,42
Efeito	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	POT							
Teste de CS	139,42							
Efeito	CT							

*p<0,10; **p<0,05; ***p<0,01.

Fonte: Própria.

Tabela 11: Teste de Contágio de Coasimetria por ano.

Moedas em que não houve contágio				
2015 - 2018	2015	2016	2017	2018
-	XMR	BITUSD	MAID	DGB
	Tether		VIA	Nxt
	MAID		BBR	VIA
	RDD		XPM	Burst
	UBQ			XWC
	BLOCK			FTC
	XDN			POT
	UNO			

Fonte: Própria.

No anexo (8.2.1), foram adicionadas as tabelas com os testes completos da courtose e da covolatilidade. Ambos os testes indicaram contágio do Bitcoin em relação as moedas analisadas no período de 2015 - 2018, e inclusive, ao longo dos anos.

Como visto em Hsiao (2012), a cocurtose e a covolatilidade, que são observadas em mercados financeiros que exibem uma relação negativa no período em que não há crise e mudam para uma relação positiva no período de crise. Mas em função dos elevados valores encontrados para estes testes com os criptoativos, pode-se interpretar que em comparação os modelos anteriores, o contágio foi ainda mais generalizado (KYNIGAKIS, 2015).

3.6 Conclusões

Este estudo teve como objetivo analisar a dinâmica comportamental do mercado de moedas digitais, avaliando o efeito manada e o efeito contágio no período de março de 2015 a novembro de 2018, utilizando 1.344 observações diárias de 50 moedas com maior liquidez e volume de mercado digital.

Com relação ao efeito manada, o modelo CSAD modificado detectou um efeito manada fraco (estatisticamente significativo em $\alpha = 15\%$) e o modelo CSSD modificado detectou um efeito manada forte estatisticamente significativo no movimento de queda de mercado. O modelo de espaço de estado de Hwang e Salmon (2004) com o filtro de Kalman capturou com sucesso em maior quantidade o comportamento de manada positivo e revelou alguns períodos extremos de manada reversa (ou manada negativa).

A partir dos resultados notados com o efeito manada, foi possível perceber uma interdependência das demais moedas com o CRIX, de maneira que as expectativas racionais acabaram sendo deixadas de lado para se seguir o consenso de mercado em situações de estresse. Também foi possível notar uma tendência que pode ser aproveitada por investidores no mercado de moedas digitais em que as notícias negativas e positivas mostraram influência no comportamento positivo de manada, ou seja, os investidores de criptoativos são mais afetados por informações negativas do que por informações positivas, mostrando uma aversão ao risco no domínio da perda (que coincide com a queda de mercado na modelagem vista com o CSSD).

No que se refere ao efeito de contágio, o teste FR modificado foi capaz de encontrar evidências de contágio do Bitcoin em outras moedas em todos os casos, com exceção do Tether Dollar, BITCNY e ECC (em cada ano e em todo o período).

Estas moedas têm particularidades de controle de lastro e regras inflacionárias que as tornam imunes aos efeitos de mercado que o Bitcoin propaga no ambiente digital.

Nos outros três modelos de contágio, percebidos como extensões do modelo FR, considerando momentos de ordem superior, elaborados por Fry, Martin e Tang, (2010) e Fry-McKibbin e Hsiao (2018), ambos os testes indicaram contágio do Bitcoin em relação as moedas analisadas no período de 2015 – 2018 (é interessante dar destaque que ao longo dos anos o Tether Dollar, em 2015, e o BITUSD, em 2016, não apresentaram contágio em relação ao Bitcoin).

Logo, a presença do contágio indica que os investidores devem considerar cuidado ao investir nestes criptoativos devido à dispersão do comovimento no preço e atentar para a oportunidade de que para a queda do preço do Bitcoin existe uma tendência de queda nas demais (o mesmo se aplica na subida de preços, ou seja, existe uma previsibilidade de comportamento maior do que o esperado). A diversificação de portfólio nesse mercado deve ser realizada com atenção, considerando *stable coins*, ou outras moedas que não tenham potencial de efeito contágio – tal como o efeito manada (que expõem o investidor a um risco adicional).

Como sugestão para pesquisas futuras, seria interessante avaliar o comportamento de manada e de contágio entre as principais *exchanges* de moedas digitais, antes e depois de períodos de crise ou em situações que levaram o mercado a períodos extremos de queda – como, por exemplo, após o Bitcoin chegar até seu ápice de alta no final de 2017 e redução de valor ao longo de 2018.

4

Terceiro Ensaio: O Efeito do *Feedback Trading* no Mercado de Criptoativos

Não há dúvidas que alguns investidores buscam descobrir tendências em históricos de preços passados e muitas vezes baseiam seus portfólios na expectativa de que essas tendências persistam ao longo dos períodos futuros (ainda mais no mercado de moedas digitais em que a análise técnica é amplamente utilizada). Na literatura de finanças comportamentais esse tipo de mentalidade é comumente associado ao fenômeno de *feedback trading* - neste fenômeno, além de investigar se o investidor utiliza informações passadas para tomar decisões futuras (similar ao fenômeno de *momentum*), o foco também está na tomada decisões dos investidores.

Como visto em Sentana e Wadhvani (1992), existem dois tipos de investidores que o modelo de *feedback trading* capta: o *trader* racional que é o investidor que compra ativos do mercado acionário na baixa e vende na alta, gerando uma maximização de recursos; e o chamado *noise trader* (ou *trader* positivo, como é chamado pelos referidos autores), que segue um comportamento errático no mercado acionário em que o mesmo compra na alta e vende na baixa.

Bohl e Reitz (2004) apontam que uma das consequências da existência de um grande número de *feedback traders* no mercado é a autocorrelação dos retornos e a previsibilidade parcial dos retornos dos ativos. Mas o ponto que mais interessa na literatura é identificar o *noise trader*, cuja estratégia está em consonância com extrapolação de tendências, análises técnicas, ordens de *stop-loss* e de *portfolio insurance* (ANTONIOU, KOUTMOS E PES CETTO, 2011). Segundo Antoniou, Koutmos e Pericli (2005), o principal ponto é que o *noise trader* desestabiliza o mercado e os preços dos ativos são afastados dos seus valores fundamentais.

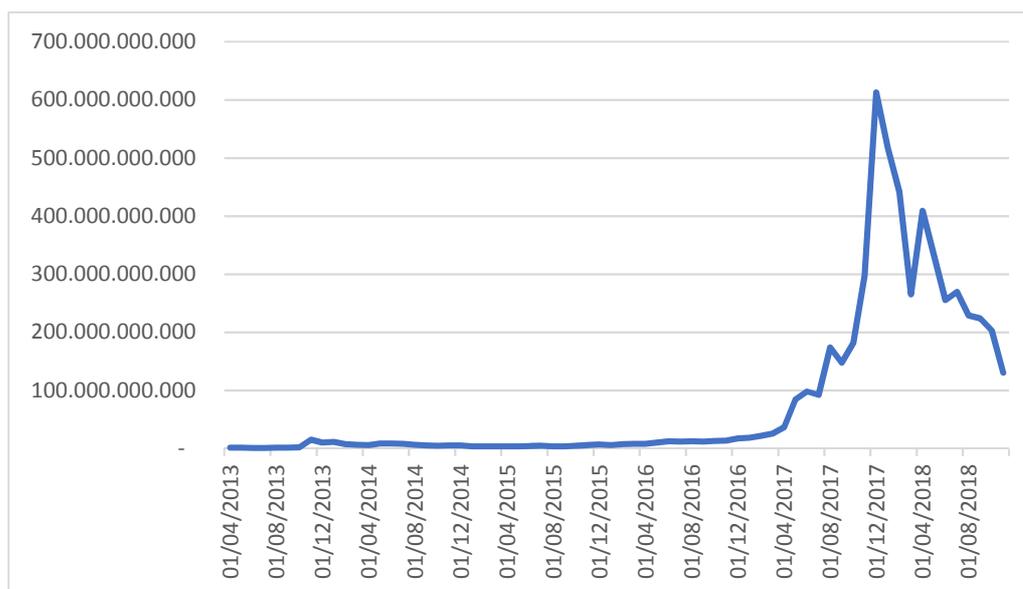
Neste ensaio, o trabalho foi direcionado da seguinte forma: primeiramente, pretende-se explorar um pouco da literatura sobre o mercado de criptoativos, o efeito *feedback trading* (apontando os principais modelos utilizados para se medir este efeito) e estudos referentes a este fenômeno comportamental baseados em

criptoativos, publicados até o momento; posteriormente será descrita a metodologia; análise de resultados; e a conclusão.

4.1 O Mercado de Moedas Digitais

O mercado de criptos cresceu exponencialmente desde 2009 com o lançamento da primeira moeda digital: o Bitcoin. Desde então, a consolidação de investimentos neste mercado com o aumento da capitalização de mercado vem chamando a atenção de grandes investidores, bancos e fundos de investimentos - apesar da queda de mercado vista desde 01/18. O gráfico 1 retrata a evolução mensal da capitalização de mercado de todas as moedas digitais (que já passam de 2.000) considerando o maior período de dados disponíveis de 04/13 – 11/18.

Gráfico 1: Capitalização Mensal de Mercado em dólares (USD).

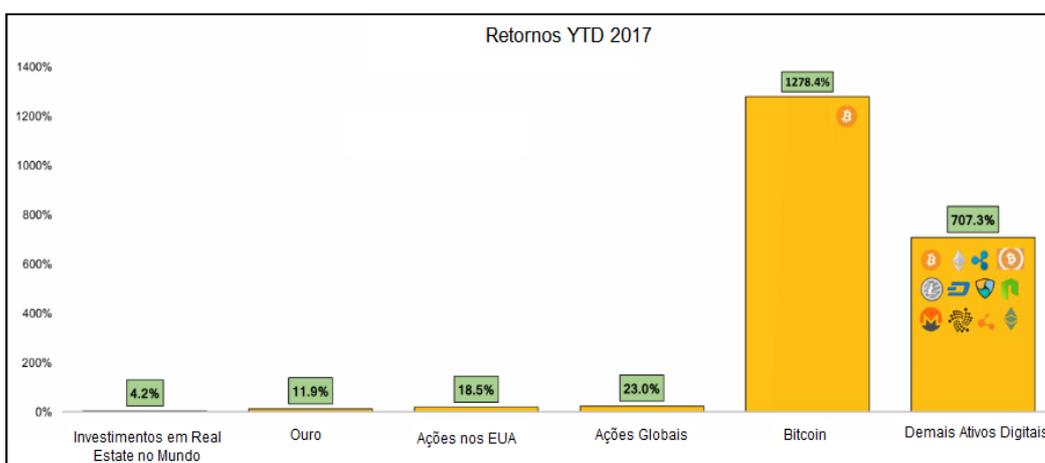


Fonte: Coinmarketcap (2018).

Foi possível notar que ao longo dos meses houve um crescimento médio de 15% e um crescimento acumulado de 1.011,25% em toda a série. Com o maior valor diário de capitalização de mercado registrado em 07/01/2018 como US\$813.871.000.000 e com um volume de negociações em US\$ 44.060.500.000. O menor valor de capitalização de mercado diário registrado nesta série foi em 05/07/2013 com US\$810.821.000.

Ainda aproveitando o gráfico 1, é possível notar o otimismo com as moedas digitais no ano de 2017, pois apenas neste ano houve um crescimento de capitalização de mercado acumulado de 488,98% e como pode ser visto no gráfico 2, os retornos acumulados diários apenas do Bitcoin no ano de 2017 chegam a 1.278,4%, seguido pelo conjunto das demais moedas digitais em 707,3% e deixando claro a divergência com ativos tradicionais no mercado, como ouro, ações globais, ações do mercado norte americano ou até mesmo investimentos em imóveis (*Real Estate*) pelo mundo.

Gráfico 2: Retorno Acumulados Diários de 2017.



Fonte: CoinDesk (2018).

Não apenas o crescimento de investimentos ou valorização dos ativos digitais impressionam, mas também o novo ecossistema criado em conjunto com esta nova tecnologia que movimenta bilhões de dólares em nível global. Alguns dos principais exemplos de novos *players* no mercado digital são:

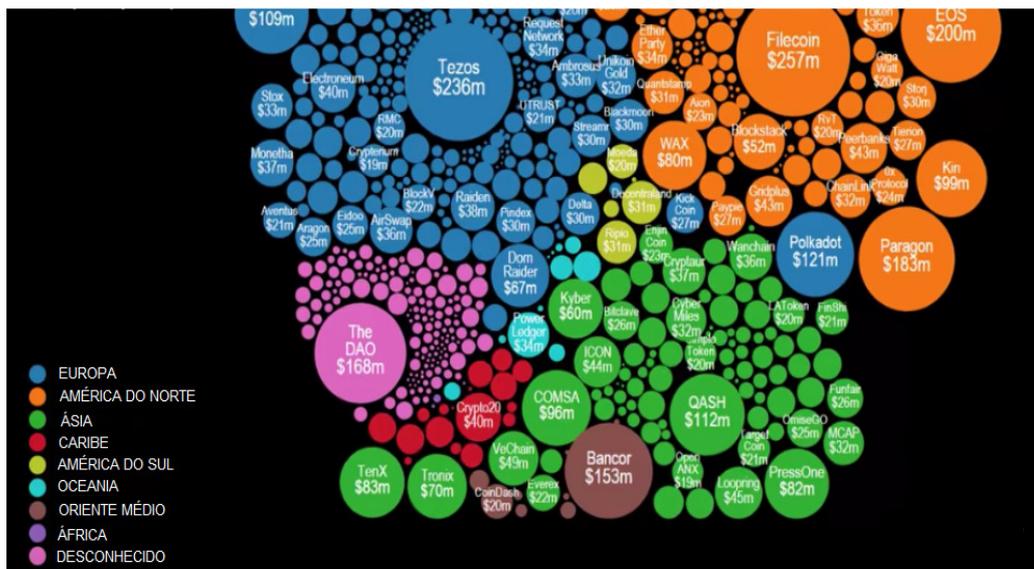
- *Exchanges*: são corretoras que comercializam moedas digitais, ou seja, onde usuários se cadastram para vender e comprar Bitcoins ou outras moedas digitais. Alguns exemplos são a Binance ou a Poloniex;
- Empresas de *Brokerage*: são corretoras similares as *exchanges*, porém com autorização do órgão regulamentador para operação (como a SEC nos EUA, por exemplo), que apenas pode negociar ativos registrados para venda pelo

órgão regulador. Exemplos são: a Bitfinex, Noble Markets, BTCC, entre outras;

- *Wallets (soft e hard)*: são carteiras digitais para armazenamento seguro da moeda digital. Existem modalidades mais complexas e que garantem maior segurança (ex. Trezor) e uma segurança mais “branda” (ex. Coinkite);
- Empresas de Investimentos em Criptos: desenvolvidas para operar com empréstimos ou investimentos em fundos de moedas digitais, como por exemplo a Bitbond;
- Bancos: criação de bancos digitais (que não existem fisicamente) que operam com moedas digitais e muitos não cobram taxas para envio ou recebimento de remessas, mas possuem seus próprios cartões (ex. Moni Bank);
- Plataformas de Pagamento Digital: processadores de pagamentos *on-line* facilitando pagamentos em moedas digitais para negócios *on-line* incluindo integrações com processadores *on-line* (ex. GoCoin);
- Empresas de Base de Dados: empresas especializadas em gerar bases de dados financeiras para o mercado digital, bem como dados históricos, etc (ex. coinmarketcap);
- ATMs: empresas operadoras de caixas automáticos para saque de moeda corrente a partir de moedas digitais e compra de criptos com moedas correntes (ex. Lamassu).

É importante acrescentar que graças as captações por meio dos ICOs (do inglês *Inicial Coin Offer*) ou ITOs (do inglês *Inicial Token Offer*), como pode ser visto no gráfico 3, que foi possível desenvolver este mercado, impulsionando novas tecnologias que surgiram embrionariamente em *startups* e atualmente são valiosas com grande prospecção de crescimento.

Gráfico 3: Levantamento dos principais ICOs de 2014 – 2017.



Fonte: Business Insider UK (2018).

Em 2017, particularmente, foi o melhor ano para os ICOs, alguns levantando valores iniciais de mais de US\$ 200 milhões (como Filecoin, Tezos e EOS) e outros entre US\$ 200 milhões e US\$ 100 milhões (Paragon, DAO, Bancor, Polkadot, QASH e Status). Com bilhões de dólares investidos em novos projetos, investidores e especuladores aguardam ansiosamente para ver qual moeda será o próximo Bitcoin ou Ethereum.

Em relação a regulamentação e fiscalização das moedas digitais no Brasil, até o presente momento apenas discute-se a temática na Câmara e no Senado Federal. Porém, alguns órgãos normativos já vêm tomando uma posição quanto a tais ativos e desde 2014 estão definindo comunicados e instruções normativas. Dentre os principais órgãos e medidas destacam-se: os comunicados do BACEN Nº 25.306/14 e Nº 31.379/17; a instrução normativa da CVM Nº 555/14; e a instrução normativa da Receita Federal Brasileira (RFB) Nº 1.888/19.

O BACEN em seu comunicado inicial Nº 25.306/14 primeiramente esclarece que tais moedas não podem ser confundidas com moedas eletrônicas que são tratadas pela lei 12.865/13), apontando também sobre os riscos de garantia das moedas digitais, já que não possuem emissão por autoridade monetária e algumas teriam sua emissão controlada por entidades não financeiras, não tendo garantia de conversão ou lastro. O Bacen também ressalta a questão da pouca aceitação como meio de troca e alta volatilidade de tais ativos. Outro ponto que consta no

comunicado é o receio da instituição em que tais moedas possam ser utilizadas de maneira ilícita (como por exemplo, para lavagem de dinheiro, evasão fiscal, financiamento do tráfico de drogas, etc.) e também da maneira que são armazenadas em carteiras digitais, que não possuem garantias.

Posteriormente, em 2017, o BACEN em seu comunicado N° 31.379/17 aponta para o crescente interesse por tais ativos no que se refere aos aspectos de sua natureza, legais e regulamentares. Neste comunicado são reforçados os pontos anteriormente vistos, porém, são ressaltados novos pontos importantes: sanções legais que podem recair sobre indivíduos que utilizarem as moedas digitais para fins ilícitos; os mecanismos para liquidação e transferências internacionais deveriam respeitar as regras cambiais; reforça o comunicado anterior em que não há risco para o sistema financeiro nacional e para o sistema de pagamentos – apontam, inclusive, que organismos internacionais ainda não veem necessidade de regulamentação.

A CVM em sua instrução N° 555/14 ressaltou que os investimentos em criptoativos poderiam ser realizados apenas no exterior de maneira indireta por meio de aquisições de cotas em fundos e por meio de derivativos financeiros - para o caso destes investimentos serem regulamentados nos mercados externos em questão. Assim como o BACEN, a CVM atenta para os riscos com tais investimentos e principalmente em relação as questões ilícitas que podem ocorrer neste mercado (operações fraudulentas, manipulação de preços, lavagem de dinheiro, etc). A CVM aponta a importância em se operar em empresas submetidas a regulação de órgãos reguladores que tenham o poder de coibir práticas ilegais. É interessante notar que a CVM apontou que os gestores de investimentos façam diligências para minimizar riscos nos investimentos nestes ativos que são:

“(i) se o *software* base é livre e de código fonte aberto (*free open source software*) ou fechado; (ii) se a tecnologia é pública, transparente, acessível e verificável por qualquer usuário; (iii) se há arranjos que suscitem conflitos de interesse ou a concentração de poderes excessivos no emissor ou promotor do criptoativo, ou o uso de técnicas agressivas de venda, (iv) a liquidez de negociação do criptoativo, (v) a natureza da rede, dos protocolos de consenso e validação, e do *software* utilizados, ou (vi) o perfil do time de desenvolvedores, bem como seu grau de envolvimento com o projeto”. (CVM, INSTRUÇÃO NORMATIVA N° 555/14).

A Receita Federal Brasileira (RFB) em sua instrução normativa Nº 1.888/19 institui e disciplina a obrigatoriedade de prestação de informações junto a RFB no que se refere as operações realizadas com criptoativos. Segundo o normativo, as informações devem ser prestadas por meio do sistema de Coleta Nacional (disponibilizado no e-CAC). No que se refere a conversão da moeda, deve ser realizada pelo dólar PTAX divulgada pelo BACEN. Neste normativo, caso as operações mensais (isolada ou em conjunto) ultrapassem R\$30.000, tanto pessoas físicas, como jurídicas e *exchanges* de moedas digitais devem declarar - seja para permuta, doação, cessão temporária, compra e venda, emissão, dação em pagamento, retirada ou transferência para *exchange*, entre outras operações de transferência de criptoativos (que devem ser declaradas mensalmente).

No caso de não haver prestação de contas seguindo o normativo da receita, existem algumas penalidades a serem observadas:

“I - Pela prestação extemporânea:

- a) R\$ 500,00 por mês ou fração de mês, se o declarante for pessoa jurídica em início de atividade, imune ou isenta, optante pelo Regime Especial Unificado de Arrecadação de Tributos e Contribuições devidos pelas Microempresas e Empresas de Pequeno Porte (Simples Nacional), instituído pela Lei Complementar nº 123, de 14 de dezembro de 2006, ou que na última declaração apresentada tenha apurado o Imposto sobre a Renda da Pessoa Jurídica (IRPJ) com base no Lucro Presumido;
- b) R\$ 1.500,00 por mês ou fração de mês, se o declarante for pessoa jurídica não incluída na alínea "a"; ou
- c) R\$ 100,00 por mês ou fração, se pessoa física;

II - Pela prestação com informações inexatas, incompletas ou incorretas ou com omissão de informação:

- a) 3% do valor da operação a que se refere a informação omitida, inexata, incorreta ou incompleta, não inferior a R\$ 100,00, se o declarante for pessoa jurídica; ou
- b) 1,5% do valor da operação a que se refere a informação omitida, inexata, incorreta ou incompleta, se o declarante for pessoa física; e

III - Pelo não cumprimento à intimação da RFB para cumprir obrigação acessória ou para prestar esclarecimentos nos prazos estipulados pela autoridade fiscal, o valor de R\$ 500,00 (quinhentos reais) por mês-calendário.”. (RFB, INSTRUÇÃO NORMATIVA Nº 1.888/19).

Logo, é possível notar certa preocupação/precaução dos respectivos órgãos apontados anteriormente em relação aos criptoativos. Há um consenso que pontua

a falta de regulamentação e fiscalização do setor, que representa riscos aos investidores ou empresas que trabalham diretamente com estes ativos.

Apesar da minimização dos riscos de ordem econômico-financeira apontado pelo BACEN, este novo mercado de moedas digitais já chegou em mais de 800 bilhões de dólares em capitalização em 2018. Caso estas moedas comecem efetivamente a serem utilizadas na compra de bens e serviços no dia a dia (após uma eventual regulamentação dos parlamentares brasileiros, por exemplo) e se intensifique o uso cotidiano em meios de pagamentos, se tornará um trabalho árduo fiscalizar compras/vendas fora de *exchanges* licenciadas.

Também será complicado detectar ilicitudes (as apontadas anteriormente) e mesmo questões ligadas a política monetária - já que são ativos criados sem uma autoridade central e podem adentrar na economia de qualquer país do mundo - sem limitação de fronteiras, sem um valor fundamental, sem lastros mais conservadores, entre outros. As expectativas mais conservadoras apontam para uma futura adesão dos países a esta evolução monetária para transformação de suas próprias moedas individuais ou de grupos de países (como a União Europeia, por exemplo) no meio digital.

4.2 Comportamento do Investidor e Modelos de *Feedback Trading*

Um número crescente de estudos empíricos encontrou evidências de uma relação entre sentimento do investidor e retornos do mercado. Isso, por sua vez, motivou muitos pesquisadores a explorar o poder explicativo do sentimento para várias anomalias bem documentadas, incluindo o efeito de tamanho (BAKER E WURGLER, 2006), efeito valor (FRAZZINI E LAMONT, 2008), e efeito *momentum* (ANTONIOU, DOUKAS E SUBRAHMANYAM, 2010). A conclusão geral desta literatura é que os achados relativos ao sentimento é, pelo menos, uma explicação parcial para essas anomalias de precificação de ativos.

De maneira geral, a literatura tem se concentrado principalmente na estratégia de *feedback trading* positivo, em que os investidores compram ativos quando os preços sobem e vendem quando os preços caem, o caso inverso é o caso do *feedback trading* negativo. Existem evidências desse tipo de comportamento que são encontradas tanto para investidores individuais quanto institucionais

(NOFSINGER E SIAS, 1999) e também em uma ampla variedade de mercados; ver, por exemplo, Sentana e Wadhwani (1992) para evidência de *feedback trading* no mercado de ações norte-americano, Antoniou, Koutmos e Pericli (2005) para os mercados de ações do G-7, Laopodis (2005) para mercados de câmbio, Salm e Schuppli (2010) para mercados futuros de índices, e Chau, Deesomsak e Lau (2011) para os mercados de fundos negociados em bolsa (ETF).

A perspectiva tradicional (FRIEDMAN, 1953; FAMA, 1965), argumenta que os especuladores racionais com estratégias mais lucrativas compram quando os preços estão baixos e vendem quando estão altos, eliminando os choques de mercado e amortecendo uma flutuação excessiva dos preços. No entanto, os defensores dos modelos de PFT (*Positive Feedback Trading*) acreditam que esse ponto de vista pode estar incompleto, quando alguns participantes do mercado adotam estratégias baseadas em *feedback trading*.

No caso desta forma específica desestabilizadora de *noise trading* (prática em que as decisões de comprar, vender ou manter ativos são irracionais e erráticas), a negociação com interferência pode aumentar a variação dos retornos em relação à variabilidade dos valores fundamentais causados pelo fluxo de informação para os mercados e, conseqüentemente, reduz a correlação nas séries de retornos dos ativos.

Os investidores com reações sustentadas em estratégias de *feedback trading* compram os valores depois que os preços sobem e vendem depois que os preços caem. Existem muitas formas de comportamento comuns nos mercados financeiros, que podem ser descritas como PFT. Uma das tendências mais fortes em investimentos, documentado tanto no nível prático (SHILLER, 1990) quanto teórico (FRANKEL E FROOT, 1986), é a tendência de extrapolar ou seguir a tendência.

Também pode ser uma consequência das ordens de *stop-loss* (OSLER, 2005), que vendem em resposta a um declínio nos preços. Outro tipo de PFT é a liquidação de posições detidas por investidores que não cumpram seus compromissos de margem (HIROSE, KATO E BREMER, 2009), bem como uma estratégia de investimento que era popular até o *crash* de 1987, o que levou os investidores institucionais a aumentar a exposição aos títulos de ações quando os preços subiam e diminuir a exposição aos títulos de ações quando os preços desciam.

A metodologia mais comum para se avaliar empiricamente os fluxos informacionais de alta frequência do *feedback trading* é o modelo vetorial

autorregressivo (VAR) de Hasbrouck (1991). Seu modelo foi originalmente aplicado a dados de alta frequência por segundo, onde a direção da causalidade é explicitamente do fluxo de ordens para os retornos dos preços dos ativos. Hasbrouck (1991) introduz um choque no processo de negociação, representando informações privadas, e calcula o efeito acumulado no retorno do ativo. Quanto maior o efeito acumulado, ou resposta ao impulso, mais transações de informações são identificadas. Esses modelos VAR tornaram-se padrão na literatura para dados de alta frequência; alguns exemplos incluem Dufour e Engle (2000) e Engle e Patton (2004) para ações, Evans (2002) e Payne (2003) para moedas e Cohen e Shin (2003) e Green (2003) para títulos do tesouro.

Outro modelo que se tornou amplamente utilizado foi o de Sentana e Wadhvani (1992), que desenvolveram um modelo de comportamento do investidor que produz uma implicação testável da presença de *feedback trading*, sendo este modelo seminal empírico o mais utilizado desde então. Utilizando dados diários de índices do mercado de ações norte-americano no período de 1885 a 1988, encontraram evidências positivas de *feedback trading*, mais pronunciadas em mercados pessimistas do que em mercados otimistas.

Sentana e Wadhvani (1992) desenvolveram um modelo teórico que consiste em dois grupos de investidores: (i) investidores racionais cuja demanda por ativos depende do retorno esperado ajustado ao risco; e (ii) *feedback traders* cuja demanda depende dos valores anteriores dos ativos. Este modelo implica que os retornos reais são gerados como um processo autorregressivo simples, no qual o parâmetro em retornos defasados é uma função da variância condicional, ou seja, a existência de uma relação entre autocorrelação e volatilidade.

O modelo de Sentana e Wadhvani (1992), que incorpora as inovações trazidas por Bollerslev (1986) com o modelo GARCH, será utilizado neste estudo. Koutmos (2014), inclusive, fez uma extensa revisão da literatura existente sobre modelos de *feedback trading* positivo e suas aplicações a mercados de títulos, câmbio, futuro de índices e ações individuais, apontando a necessidade da generalização dos modelos para aplicação na investigação do comportamento dos investidores para mercados de ativos individuais, para além dos agregados.

Como o assunto envolvendo moedas digitais ainda é recente, existem poucos estudos que incorporam o *feedback trading* no universo digital. Mas vale apontar o estudo de Bozza (2019) que buscou avaliar a existência do efeito de *feedback*

trading para os criptoativos Bitcoin, Ethereum, Litecoin e Dash (com o máximo período de dados disponíveis por cada moeda, sendo: o BTC de 2013 – 2018; ETH de 2015 – 2018; LTC de 2013 – 2018; DASH de 2017 – 2018). Neste estudo foram analisados dados por segundo, minuto, hora e dia. O resultado do modelo indicou a existência de *feedback trading* negativo para todos os criptoativos nas granularidades de tempo segundo e minuto e *feedback trading* negativo para a granularidade de tempo hora a hora para Litecoin e Dash. A autora acredita que uma hipótese sobre a existência de *feedback trading* negativo para estes criptoativos possa ser devido ao uso de *bots* (programas de computador que utilizam diversos indicadores para reconhecer tendências de mercado e executar negociações automaticamente).

4.3 Metodologia e Base de Dados

Os dados diários dos criptoativos foram obtidos por meio da base do *website* coinmarketcap em valores dolarizados. O levantamento inicial contemplou dados de 2013 – 2018, porém, para igualar o tamanho das amostras máximas entre as maiores moedas o recorte foi reduzido para 1.344 dados diários, abordando desta maneira um período total do recorte de dados de 03/2015 – 11/2018 (considerando dados diários e disponibilidade de dados), com o ranqueamento efetuado em 11/2018 - representado na tabela 1.

Tabela 1: Seleção dos 50 Criptoativos.

1	2	3	4	5	6
BTC Bitcoin	ETH Ethereum	XRP Ripple	XLM Stellar Lumens	LTC Litecoin	XMR Monero
7	8	9	10	11	12
Tether Tether Dollar	DASH Dash	DOGE Dogecoin	BTS BitShares	BCN Bytecoin	DGB DigiByte
13	14	15	16	17	18
XVG Verge	MAID MaidSafeCoin	MONA Monacoin	RDD ReddCoin	Nxt Nxt	SYS Syscoin
19	20	21	22	23	24
PPC Peercoin	NXS Nexus	GRS Groestlcoin	VTC VertCoin	EMC2 Einsteinium	UBQ Ubiq
25	26	27	28	29	30
BLOCK Blocknet	NAV NavCoin	BITCNY bitCNY	NVC Novacoin	XDN DigitalNote	VIA ViaCoin
31	32	33	34	35	36
BAY BitBay	BURST Burst	XWC WhiteCoin	CLOAK CloakCoin	BBR Boolberry	UNO Unobtanium

37	38	39	40	41	42
NLG Gulden	BITUSD BitUSD	GAME GameCredits	CSC CassinoCoin	XCP Counterparty	NMC Namecoin
43	44	45	46	47	48
FTC Feathercoin	XPM PrimeCoin	CRW Crown	FLO FlorinCoin	BLK BlackCoin	ECC ECC
49	50				
DMD Diamond	POT PotCoin				

Fonte: Própria.

Para examinar as evidências de *feedback trading* na amostra, empregou-se o modelo seminal de Sentana e Wadhvani (1992), já consagrado na literatura. Neste modelo, existem dois tipos de investidores: investidores racionais e *feedback traders*. O investidor racional procura maximizar sua utilidade média-variância esperada de acordo com a seguinte função de demanda (equação 1).

$$Q_t = \frac{E_{t-1}(r_t) - \alpha}{\theta \sigma_t^2}$$

Eq. (1)

Onde Q_t é a fração de cotas demandada, $E_{t-1}(r_t)$ mede a expectativa de retorno das cotas para o período t baseado em informações do período t-1, α é o retorno livre de risco, θ é o coeficiente de aversão ao risco e σ_t^2 é a variância condicional no período t. A demanda por cotas do *feedback trader* é função do retorno passado, dada segundo a equação 2.

$$Y_t = \gamma r_{t-1}$$

Eq. (2)

Onde Y_t é a quantidade de cotas demandada pelos *feedback traders* e r_{t-1} é o retorno das cotas no período anterior (SENTANA E WADHWANI, 1992). Para *feedback trading* positivo, γ será maior do que zero, e para *feedback trading* negativo, menor do que zero. Num mercado em equilíbrio, todas as cotas são demandadas, e a equação geral do mercado será vista na equação 3.

$$Q_t + Y_t = 1$$

Eq. (3)

Substituindo as equações (1) e (2) em (3), obtêm-se:

$$E_{t-1}(r_t) = \alpha - \gamma r_{t-1} \theta \sigma_t^2 + \theta \sigma_t^2 \quad \text{Eq. (4)}$$

Assumindo que os retornos realizados sejam iguais aos retornos esperados acrescidos de um erro estocástico, $r_t = E_{t-1}(r_t) + \varepsilon_t$, se obtêm a equação 5.

$$r_t = \alpha - \gamma r_{t-1} \theta \sigma_t^2 + \theta \sigma_t^2 + \varepsilon_t \quad \text{Eq. (5)}$$

A equação (5) revela que a autocorrelação de primeira ordem dos retornos varia em função do risco de mercado σ_t^2 , conforme indicado no termo $\gamma r_{t-1} \theta \sigma_t^2$, enquanto seu sinal dependerá do sinal do termo relativo ao *feedback trading* γ , sendo que *feedback trading* positivo acarretará autocorrelação negativa, e vice-versa.

Ao apontar a questão de que a autocorrelação observada pode ser oriunda tanto de *feedback trading* quanto de fricções existentes no mercado, Sentana e Wadwhani (1992) propuseram o modelo representado pela equação 6.

$$r_t = \alpha + \theta \sigma_t^2 + (\phi_0 + \phi_1 \sigma_t^2) r_{t-1} + \varepsilon_t \quad \text{Eq. (6)}$$

A equação (6) captura o efeito das fricções existentes no mercado através do coeficiente ϕ_0 , enquanto ϕ_1 captura a presença de *feedback trading*. Como $\phi_1 = -\theta\gamma$, isto sugere que, se $\phi_1 < 0$, e estatisticamente significativo, *feedback traders* positivos são dominantes no mercado, e vice-versa.

Conforme indicado na equação (6), a volatilidade da série de retornos é variável ao longo do tempo. O modelo GARCH, proposto por Bollerslev (1986), é comumente utilizado, pois captura não só a heterogeneidade da variância, como também a distribuição leptocúrtica, seguida pela maioria das séries financeiras diárias. O modelo captura ainda, agrupamentos de volatilidade, onde grandes mudanças no preço de um ativo tendem a provocar grande aumento da volatilidade, ao passo que pequenas alterações nesses preços tendem a provocar pequenos aumentos de volatilidade.

Para estimar empiricamente a equação (6), a variância condicional foi definida como um processo assimétrico GARCH (GLOSTEN, JAGANNATAHAN E RUNKLE, 1993), vista na equação 7.

$$\sigma_t^2 = \omega + \beta \varepsilon_{t-1}^2 + \lambda \sigma_{t-1}^2 + \delta S_{t-1} \varepsilon_{t-1}^2$$

Eq. (7)

Na equação (7), δ captura a assimetria de volatilidade após choques positivos ou negativos. S_{t-1} é uma variável binária, que assume o valor 1 se o choque no tempo t-1 for negativo e zero em caso contrário. Um valor significativamente positivo de δ indica que um choque negativo aumenta a volatilidade mais intensamente do que um choque positivo.

Para avaliar a robustez do GJR GARCH (1,1), foi realizado o teste de viés de sinais de Engle e Ng (1993), que examina se existe assimetria na volatilidade após choques positivos e negativos, não explicados pelo modelo GARCH utilizado - determinando se um modelo GARCH simétrico é adequado.

De acordo com este teste, os resíduos padronizados ao quadrado são regredidos contra uma constante e uma variável binária que assume o valor de 1 no caso do resíduo em t-1 ser negativo e o valor zero caso contrário. Se o coeficiente da variável binária for estatisticamente significativo, isto implica que choques positivos e negativos têm diferentes impactos na heteroscedasticidade, incrementando a capacidade explicativa do modelo (a equação 8 demonstra o modelo).

$$(\varepsilon_t / \sigma_t)^2 = \alpha + \theta S_{t-1} + u_t$$

Eq. (8)

Outros modelos documentados por Bollerslev (2008), como TGARCH e EGARCH podem ser mais apropriados para capturar outro fenômeno muito comum nas séries financeiras, conhecido como efeito de alavancagem: choques negativos tendem a criar mais volatilidade do que choques positivos. Sentana e Wadhvani (1992) sustentam, corroborados por Shi, Chiang e Liang (2012), que a escolha de modelos menos parcimoniosos teria pouca influência na verificação de *feedback trading*, objeto principal deste estudo.

4.4 Resultados

Dos 50 criptoativos analisados, apenas cinco mostraram evidências de *feedback trading*: Bitcoin, Ethereum, Tether, CassinoCoin e ECC. Os resultados serão concentrados nestes cinco criptoativos - os resultados completos estão disponíveis no anexo por meio dos itens 8.3.1 e 8.3.2.

A tabela 2 apresenta os resultados do teste SW para os criptoativos referidos acima. Com relação à variância condicional, δ é positivo e estatisticamente significativo para todos os casos, indicando que os choques negativos tendem a aumentar a volatilidade em uma intensidade maior do que os choques positivos, o que é típico para os ativos financeiros. A razão $(\beta + \delta) / \beta$ foi positiva e acima de 1, indicando que a volatilidade aumenta nos períodos em que o mercado encolhe, em comparação com o crescimento do mercado.

Tabela 2: Resultado do teste SW de *feedback trading*

	BTC	ETH	TETHER	CSC	ECC
α	0,0007	0,0005	7,06E-05***	0,0260	-0,0108*
θ	1,6186*	0,2772	-46,4200***	-0,2566	-0,0018
ϕ_0	0,1552***	0,0712**	-2,0590***	0,0003	-0,2550
ϕ_1	-50,8226***	-1,2016**	27,1840***	-1,7442**	-0,2915**
ω	1,24E-05***	0,0003***	-1,41E-09***	0,0291***	2,02E-07
β	0,1463***	0,3207***	0,7652***	0,0704***	0,0087
λ	-0,0663***	-0,0650*	1,8609***	-0,0718***	0,0892***
δ	0,8947***	0,6940***	0,7166***	0,6245***	0,9540***
$(\beta + \delta)/\beta$	7,1152	3,1644	1,9365	9,8698	110,3789

Onde ϕ_1 é o coeficiente que indica a presença do efeito de *feedback trading*. Sendo um valor negativo, indica a presença de *traders* positivos (*noise trader*) e em caso de ser positivo indica a presença de *traders* negativos (racionais). *p<0,10; **p<0,05; ***p<0,01

Fonte: Própria.

Em relação à equação principal, observou-se que o coeficiente ϕ_0 é significativo e positivo para BTC, ETH e CSC e significativo e negativo para o Tether e o ECC respectivamente, indicando autocorrelação de primeira ordem positiva para BTC, ETH e CSC e negativa para os outros. O coeficiente ϕ_1 de *feedback trading*, principal objeto desta investigação, mostrou-se estatisticamente significativo, sendo negativo para BTC, ETH, CSC e ECC (indicando a presença de *feedback traders* positivos, indo contra o estudo de BOZZA, 2019) e positivo para Tether, sugerindo a presença de *feedback traders* negativos para este ativo.

É importante apontar que a relação contrária obtida no estudo de Bozza (2019) para o BTC e ETH (que utilizou o modelo de *feedback trading* de HASBROUCK, 1991) não é algo incomum, já que, assim como observado por Antoniou, Koutmos e Pericli (2005), diferentes modelos de negociação de *feedback trading* têm implicações diferentes para o padrão de autocorrelação dos retornos das ações. Por exemplo, os modelos de *feedback trading* usados por Shiller (1984), Cutler, Poterba e Summers (1990) e Sentana e Wadhvani (1992) implicam em uma autocorrelação positiva de retornos de curto prazo.

A tabela 3 mostra a visão geral dos dados e é possível ver que o BTC foi persistente ao longo do tempo e o Tether ao longo de todos os períodos observados. A maioria dos ϕ_1 positivos (indicando a presença de *feedback traders* negativos) pode ser observada em moedas que são mais estáveis, que têm controle inflacionário ou moedas menores (mostrando uma estratégia mais assertiva, já que o *feedback trader* positivo é o conhecido *noise trader*, com o comportamento errático de comprar na alta e vender na baixa).

Tabela 3: Visão geral dos dados para os resultados de *feedback trading*.

2015						
	RDD	CSC	NMC	FTC		
ϕ_1	-25,11***	-0,74*	-39,94***	-2,69***		
2016						
	BTC	XRP	DOGE	XVG	RDD	UBQ
ϕ_1	-111,68**	11,17**	6,34**	5,16**	8,21**	-20,55**
	UNO	BITUSD	XCP			
ϕ_1	-44,55***	-1,27**	4,80***			
2017						
	ETH	DGB	XVG	NXS	VTC	CRW
ϕ_1	-17,53***	4,62***	-1,57*	26,43*	-8,45**	8,00**
2018						
	BCN	DGB	MONA	RDD	BURST	CLOAK
ϕ_1	-0,82***	24,25*	-6,74***	15,38***	38,32***	60,56*
	GAME					
ϕ_1	98,79***					
2015 - 2016						
	BTC	XRP	TETHER	XVG	VTC	BITCNY
ϕ_1	-117,75***	-14,36**	4199,56***	6,95***	2,84***	0,61**
	NMC					
ϕ_1	-10,47*					
2015 - 2017						
	BTC	TETHER	DGB	UBQ	GAME	
ϕ_1	-37,38**	2,35***	2,89*	0,14**	-2,10*	
2015 - 2018						
	BTC	ETH	TETHER	CSC	ECC	
ϕ_1	-50,82***	-1,20**	27,18***	-1,74**	-0,29**	

Onde ϕ_1 é o coeficiente que indica a presença do efeito de *feedback trading*. Sendo um valor negativo, indica a presença de *traders* positivos (*noise trader*) e em caso de ser positivo indica a presença de *traders* negativos (racionais). *p<0,10; **p<0,05 e ***p<0,01

Fonte: Própria

No teste de vícios de sinais de Engle e Ng (1993), tabela 4, como o coeficiente da variável binária θ foi estatisticamente significativo, em pelo menos 10%, de 46 dos 50 criptoativos, pode-se perceber que a estrutura assimétrica GARCH (1,1) capta assimetria na volatilidade da amostra (para todo o período de 2015 - 2018) de maneira parcimoniosa, excluindo-se BAY, UNO, XDN e TETHER.

Tabela 4: Resultado do teste de vícios de sinais.

$(\varepsilon_t/\sigma_t)^2 = \alpha + \theta s_{t-1} + u_t$						
	BTC	ETH	XRP	XLM	LTC	XMR
α	1.604,7890***	339,111***5	327,2099***	840,9433***	101,9153***	338,9466***
θ	-816,9756***	182,7546***	131,1377***	-825,9767***	-100,8091***	-163,3454***
	Tether	DASH	DOGE	BTS	BCN	DGB
α	135835,7000	381,1268***	206,7928***	162,3752***	62,1214***	72,8184***
θ	542526,7000	-43,7943***	574,6752***	-1,1758***	78,0477***	21,8444***
	XVG	MAID	MONA	RDD	Nxt	SYS
α	72,3597***	204,2358***	112,9468***	60,3147***	292,0566***	35,8541***
θ	-42,7267***	83,8112***	359,2571***	52,2322***	-66,2055***	-5,0852***
	PPC	NXS	GRS	VTC	EMC2	UBQ
α	469,1626***	79,5325***	30,2808***	134,4100***	54,9619***	36,2772***
θ	-186,9422***	27,4390***	20,2111***	28,5765***	51,9517***	22,0901***
	BLOCK	NAV	BITCNY	NVC	XDN	VIA
α	80,5476***	100,4403***	35,7425	217,0804***	105,8521***	159,8922***
θ	-0,5072**	-9,2360***	600,8046*	161,3231***	-0,4141	-73,5155***
	BAY	BURST	XWC	CLOAK	BBR	UNO
α	127,3994**	182,1084***	97,8788***	105,5127***	1.880,4050***	239,4187**
θ	-46,3018	-39,0481***	-82,3109***	-89,3215***	-1.879,7270***	-116,851
	NLG	BITUSD	GAME	CSC	XCP	NMC
α	237,3777***	47,8390***	64,4332***	0,8291***	175,1002***	308,1622***
θ	-193,3394***	0,0238*	43,2629***	-0,7430***	-25,6408***	-14,2967***
	FTC	XPM	CRW	FLO	BLK	ECC
α	64,5820***	205,3599***	6,2345***	57,4817***	74,2239***	4,4986***
θ	-62,1213***	-50,6593***	1,6318***	52,3930***	156,7807***	-2,2730***
	DMD	POT				
α	165,9167***	134,7560***				
θ	5,1260***	-41,7879***				

*p<0,10; **p<0,05 e ***p<0,01

Fonte: Própria.

Como visto anteriormente, é importante lembrar que Sentana e Wadhvani (1992) e Shi, Chiang e Liang (2012) apontaram que modelos menos parcimoniosos teriam pouca influência na verificação de *feedback trading* (caso contrário visto no Tether).

4.5 Conclusões

Este estudo teve por objetivo avaliar um fenômeno comportamental conhecido como *feedback trading* no mercado de moedas digitais envolvendo os 50 maiores criptoativos (em capitalização de mercado e liquidez) no período de 03/2015 – 11/2018. O intuito foi entender se o chamado *noise trader* pode impactar este mercado e afetar a eficiência do mesmo.

Utilizando o modelo proposto por Sentana e Wadhwani (1992), que incorpora os resultados obtidos por Bollerslev (1986) com o modelo GARCH, foi possível capturar o *feedback trading* negativo no TETHER e o *feedback trading* positivo no BTC, ETH, CSC e ECC, cuja adequação do modelo utilizado foi confirmada posteriormente pelo teste de viés de sinais de Engle e Ng (1993), com exceção do TETHER - que contrariou a afirmação de Sentana e Wadhwani (1992) e Shi, Chiang e Liang (2012) ao apontarem que modelos menos parcimoniosos teriam pouca influência na verificação de *feedback trading* (até porque o TETHER foi o mais significativo dos 5 ativos).

Assim, pode-se constatar a presença de investidores que utilizam dados passados para operar com compra e venda destes 5 criptoativos, o que inclusive era esperado, já que não existem modelos de precificação eficazes para ativos digitais - ou seja, configura-se como uma limitação deste mercado se utilizar em grande parte de análise técnica (também conhecida como análise gráfica), baseada na utilização de tendências e gráficos para a tomada de decisão dos investidores – logo, com a existência do fenômeno de *feedback trading* a previsibilidade parcial dos retornos destes ativos pode ocorrer no mercado e contribui para sua ineficiência.

De forma adicional, é possível notar, observando todo o período e os dados gerais, que as moedas estáveis (com controle inflacionário ou baseadas em ativos conhecidos, como o dólar, por exemplo) tendem a atrair investidores mais assertivos e o oposto pode ser notado com um efeito de *feedback trading* positivo (com a presença de *noise traders*) em moedas mais populares e menos estáveis (como Bitcoin, por exemplo) - muitas vezes as notícias de altas que a própria mídia divulga induz o investidor inexperiente a comprar em períodos de grande otimismo, e quando esses períodos passam, este mesmo investidor realiza sua posição no mercado.

Como estudos futuros, pode-se sugerir a análise de dados de alta frequência para se avaliar o *feedback trading* em um conjunto maior de moedas dos vistos no estudo de Bozza (2019) - até porque a quantidade de dados históricos disponíveis ainda são uma grande limitação para estudos – porém, adicionando o estudo de eventos e de notícias por meio de ferramentas de buscas (como o google trends) para buscar alguma relação entre os eventos, notícias e *o noise trader*.

5 Considerações Finais

Por meio deste estudo, foi possível entender que em âmbito da mudança de estado de volatilidade há uma forte influência dos dois estados de volatilidade. No caso das moedas com maior capitalização de mercado, como o Bitcoin (BTC) e Ethereum (ETH), por exemplo, a probabilidade de ocorrência do segundo regime foi de 50,06% e 57,01%, respectivamente, mas quando ocorre, há uma redução na volatilidade para estes criptoativos. As moedas UBQ e XVG foram as que apresentaram maior probabilidade de ocorrência de um segundo regime (com 93,84% e 76,19%, respectivamente), e quando ocorreram, há um aumento da volatilidade (assim como as outras que tiveram uma maior probabilidade de ocorrência do segundo regime).

Por meio da análise dos gráficos de probabilidades filtradas e com auxílio da avaliação dos dias médios de se estar em cada estado de volatilidade nas amostras, foi possível perceber que nos criptoativos com maior probabilidade de ocorrência do segundo regime existe uma maior tendência do aparecimento do segundo estado de volatilidade com a subida de preços, onde existe uma maior volatilidade. A exceção que foi notada cabe apenas ao BTC e ETH, onde o primeiro estado de volatilidade é mais presente na subida de preços, com maior volatilidade.

Em relação aos parâmetros dos modelos de volatilidade, foi possível concluir que em praticamente todas as moedas (tanto no caso do primeiro estado, como no segundo – em ambos os regimes) o coeficiente de assimetria *gamma* é positivo, o que vai contra o que se esperaria no mercado acionário, invertendo a noção da aversão ao risco ser concentrado na área de perdas (indicando que os choques positivos são mais fortes que os negativos). Apesar de todas as moedas serem influenciadas pela volatilidade no período anterior, esta influência variou dependendo se houve ou não mudança de 1 para 2 estados e também do regime em que a mesma se encontrava. Considerando a comparabilidade de dados, o primeiro regime teve uma maior influência.

Em relação a projeção de volatilidade, contemplando as janelas escolhidas de 15, 30, 60 e 90 dias, para se testar a acurácia das previsões foram avaliadas as funções perda EQM e QLIKE, bem como o MAE, MAPE e o indicador U de Theil. Os 5 testes de acurácia tiveram resultados muito próximos e indicaram que existe uma maior assertividade da previsão com dois estados de volatilidade para janelas de previsão mais longas do que nas mais curtas, o que pode vir a auxiliar na elaboração de tendências ou análises destas moedas.

Com relação ao efeito manada, o modelo CSAD modificado detectou um efeito manada fraco (estatisticamente significativo ao nível de 15%) e o modelo CSSD modificado detectou um efeito manada forte estatisticamente significativo no movimento de queda de mercado. O modelo de espaço de estado de Hwang e Salmon (2004) com o filtro de Kalman capturou com sucesso em maior quantidade o comportamento de manada positivo e revelou alguns períodos extremos de manada reversa (ou manada negativa). É possível conjecturar que os investidores de criptoativos tendem a ser mais afetados por informações / influências negativas quando existe efeito manada positivo, do que por informações / influências positivas (quando há um efeito manada reverso, negativo), ou seja, observa-se que um investidor é mais avesso ao risco no domínio da perda (que coincide com a queda de mercado na modelagem vista com o CSSD).

Em relação ao efeito contágio, o teste FR modificado conseguiu captar contágio do Bitcoin em outras moedas em praticamente todos os casos com exceção do Tether Dollar, BITCNY e ECC (em cada ano e em todo o período), que tipicamente possuem controle inflacionário e particularidades de aplicação que deixaram estas moedas com uma imunidade em relação aos efeitos de mercado que o Bitcoin acaba propagando no meio digital. Nos três demais modelos de contágio que são considerados extensões do modelo FR considerando momentos de ordem superior elaboradas por Fry, Martin e Tang (2010) e Fry-McKibbin e Hsiao (2018), ambos os testes indicaram contágio do Bitcoin em relação as moedas analisadas no período de 2015 – 2018 (é interessante dar destaque que ao longo dos anos o Tether Dollar, em 2015, e o BITUSD, em 2016, não apresentaram contágio em relação ao Bitcoin).

Desta forma, a presença do contágio indica que os investidores devem considerar cuidado ao investir nestes criptoativos devido à dispersão do comovimento no preço e atentar para a oportunidade de que para a queda do preço

do Bitcoin existe uma tendência de queda nas demais (o mesmo se aplica na subida de preços, ou seja, existe uma previsibilidade de comportamento maior do que o esperado). A diversificação de portfólio nesse mercado deve ser realizada com atenção, considerando *stable coins*, ou outras moedas que não tenham potencial de efeito contágio - bem como com o efeito manada (que expõem o investidor a um risco adicional).

Em relação ao fenômeno de *feedback trading*, ao se utilizar o modelo proposto por Sentana e Wadhvani (1992), que incorpora as inovações trazidas por Bollerslev (1986) com o modelo GARCH, foi possível captar *feedback trading* negativo no TETHER e positivo nas moedas BTC, ETH, CSC e ECC, cuja adequação do modelo utilizado foi confirmada posteriormente pelo teste de viés de sinais de Engle e Ng (1993), com exceção do TETHER - que contrariou a afirmação de Sentana e Wadhvani (1992) e Shi, Chiang e Liang (2012) ao apontarem que modelos menos parcimoniosos teriam pouca influência na verificação de *feedback trading* (até porque o TETHER foi o mais significativo dos 5 ativos). Assim, pode-se notar a presença de investidores que utilizam dados passados para operar com compra e venda destas moedas - logo, com a existência do fenômeno de *feedback trading* a previsibilidade parcial dos retornos destes ativos pode ocorrer no mercado e contribui para sua ineficiência.

Desta forma, é possível notar, observando todo o período e os dados gerais, que as moedas estáveis (com controle inflacionário ou baseadas em ativos conhecidos, como o dólar, por exemplo) tendem a atrair investidores mais assertivos e o oposto pode ser notado com um efeito de *feedback trading* positivo (com a presença de *noise traders*) em moedas mais populares e menos estáveis (como Bitcoin, por exemplo) - muitas vezes as notícias de altas que a própria mídia divulga induz o investidor inexperiente a comprar em períodos de grande otimismo, e quando esses períodos passam, este mesmo investidor realiza sua posição no mercado.

Finalmente, como visto nos três ensaios, as particularidades das moedas digitais as tornam um fenômeno único. A maior acurácia de previsão do MSGARCH com dois regimes de volatilidade e a confirmação da existência de efeitos comportamentais como efeito manada, contágio e o *feedback trading* direcionam estes ativos com maior intensidade para um caminho voltado para a especulação – apesar da tecnologia disruptiva e com diversas aplicações, estes

ativos ainda não tiveram uma grande popularidade, até o momento, para o consumo e utilização cotidiana - que pode ser explicado por diversos fatores, como a própria ausência de regulamentação, por exemplo.

A questão da regulamentação, em particular, tende a reduzir a ineficiência de mercado com o aparecimento de efeitos comportamentais de forma tão proeminente - efeitos estes que geram problemas de apreçamento. Além disso, o potencial ganho com a entrada de mais investidores institucionais no mercado de moedas digitais pode também trazer *players* mais racionais, reduzindo potencialmente o caráter especulativo destes investimentos. Como apontado anteriormente, as expectativas mais conservadoras apontam para uma futura adesão dos países a esta evolução monetária para transformação de suas próprias moedas individuais ou de grupos de países (como a União Europeia, por exemplo) no meio digital – o que poderia levar os atuais criptoativos para uma classe de ativos menos utilizada em função do caráter especulativo e pela ausência de controles por entidades fiscalizadoras de governos locais e órgãos internacionais.

Como sugestões para futuros estudos, sugere-se que possam ser analisadas com maior detalhamento as diferenças de comportamento encontradas com relação à volatilidade nos criptoativos, além de estimar estados ótimos de volatilidade em modelos MSGARCH para previsão de volatilidade. Em relação aos fenômenos comportamentais, sugere-se avaliar os efeitos manada e contágio entre as principais *exchanges* de moedas digitais antes e depois de períodos de crise ou de situações que levem o mercado a quedas extremas e para o *feedback trading* pode-se sugerir a análise de dados de alta frequência em conjunto com estudo de eventos e notícias.

ABREU, D.; BRUNNERMEIER M. Bubbles and crashes. **Econometrica**, v. 71, n. 1, p. 173-204, 2003.

ADRIAN, T.; BRUNNERMEIER, M. K. CoVaR. **NBER Working Paper**, n. 17454, 1–43, 2011.

ALBUQUERQUE, B. S. D.; CALLADO, M. D. C. Understanding Bitcoins: Facts and Questions. **Revista Brasileira de Economia**, v. 69, n. 1, p. 3-16, 2015.

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

ANTONIOU, C.; DOUKAS, J. A.; SUBRAHMANYAM, A. Investor sentiment and price momentum. **SSRN Elibrary**, 2010. Available at SSRN: <<https://ssrn.com/abstract=1479197>>, Access in: June 22, 2019.

ANTONIOU, A.; KOUTMOS, G.; PERICLI, A. Index futures and positive feedback trading: Evidence from major stock exchanges. **Journal of Empirical Finance**, v. 12, n. 2, p. 219-238, 2005.

ANTONIOU, A.; KOUTMOS, G.; PESCIOTTO, G. Positive feedback trading: evidence from futures markets. **Global Business and Economics Review**, v. 13, n. 1, p. 13-25, 2011

APERGIS, N.; CHRISTOU, C. Contagion across exchange rates: New evidence on the role of information spillovers and eight major exchange rates. **Journal of Economic Studies**, v. 44, n. 1, p. 24-35, 2017.

ARDIA, D. **Financial Risk Management with Bayesian Estimation of GARCH Models: Theory and Applications**. 1ª Ed. Springer, Heidelberg. 2008.

ARDIA, D.; BLUTEAU, K.; BOUDT, K.; CATANIA, L. Forecasting risk with Markov-switching GARCH models: A large-scale performance study. **International Journal of Forecasting**, v. 34, n. 4, p. 733-747, 2017.

ARDIA, D.; BLUTEAU, K.; RÜEDE, M.; Regime changes in Bitcoin GARCH volatility dynamics. **Finance Research Letters**, v. 29, p. 266-271, 2019.

ARDIA, D.; BLUTEAU, K.; BOUDT, K. CATANIA, L.; TROTTIER, D. A. Markov-Switching GARCH Models in R: The MSGARCH Package. **Journal of Statistical Software**, Forthcoming (accepted in 2018).

ARNOLD, L. G. Anything is Possible: On the Existence and Uniqueness of Equilibria in the Shleifer-Vishny Model of Limits of Arbitrage. **Review of Finance**, v. 13, n. 3, p. 521-53, 2009.

BACEN - BANCO CENTRAL DO BRASIL. **Comunicado Nº 25.306**, de 19 de fevereiro de 2014. Disponível em:<<https://www3.bcb.gov.br/normativo/detalharNormativo.do?method=detalharNormativo&N=114009277>>. Acesso: 15/08/2019.

BACEN - BANCO CENTRAL DO BRASIL. **Comunicado N° 31.379**, de 16 de novembro de 2017. Disponível em:< <https://www.bcb.gov.br/estabilidade/financeira/exibenormativo?tipo=comunicado&numero=31379>>. Acesso em: 15/08/2019.

BAEK, C.; ELBECK, M. Bitcoins as an investment or speculative vehicle? A first look. **Applied Economics Letters**, v. 22, n. 1, p. 30-34, 2015.

BAKER, M.; WURGLER, J. Investor sentiment and the cross-section of stock returns. **Journal of Finance**, v. 61, n. 4, p. 1125-1165, 2006.

BARBER, B. M.; TERRANCE O. The internet and the investor. **Journal of Economic Perspectives**, v. 15, n. 1, p. 41–54, 2001.

BARBERIS, A.; SHLEIFER, A. Style investing. **Journal of Financial Economics**, v. 68, n. 2, p. 161–199, 2003.

BARBOSA, P. C. L. **Bitcoin e Moedas Fiat: Um Estudo de Volatilidade Comparada**. 75f. Monografia (MBA em Ciências Econômicas) - Fundação Instituto de Pesquisas Econômicas, São Paulo, SP, Brasil. 2016.

BASU, R. Financial contagion and investor “learning”: an empirical investigation. **International Monetary Fund Working Paper**, n. WP/02/218, 2002.

BAUWENS, L; BACKER B; DUFAYS A. A Bayesian Method of Change-Point Estimation with Recurrent Regimes: Application to GARCH Models. **Journal of Empirical Finance**, v. 29, n. C, p. 207-229, 2014.

BAUWENS, L.; PREMINGER, A.; ROMBOUTS, J. V. K. Theory and inference for a Markov switching GARCH model. **Econometrics Journal**, v. 13, n. 2, p. 218–244, 2010.

BARIVIERA, A. F.; BASGALL, M. J.; HASPERUÉ, W.; NAIIOUF, M. Some stylized facts of the Bitcoin market. **Physica A: Statistical Mechanics and Its Applications**, v. 484, n. 1, p. 82–90, 2017.

BAUR, D. G.; DIMPFL, T.; KUCK, K. Bitcoin, gold and the US dollar – A replication and extension. **Financial Research Letters**, v. 25, n. 1, p. 103–110, 2018.

BEIRNE, J.; CAPORALE, G. M.; SCHULZE-GHATTAS, M.; SPAGNOLO, N. Volatility Spillovers and Contagions from Mature to Emerging Stock Markets. **ECB Working Paper**, n. 1113, 2009.

BEKAERT, G.; EHRMANN, M.; FRATZSCHER, M.; MEHL, A. The global crisis and equity market contagion. **Journal of Finance**, v. 69, n. 1, p. 2597–2649, 2014.

BEKAERT, G.; HODRICK, R. J. Characterizing predictable components in excess returns on equity and foreign exchange markets. **The Journal of Finance**, v. 47, n. 2, p. 467–509, 1992.

BEKIROS, S. D. Contagion, decoupling and the spillover effects of the US financial crisis: Evidence from the BRIC markets. **International Review of Financial Analysis**, v. 33, n. 1, p. 58–69, 2014.

BENNETT, J. A.; SIAS, R. W.; STARKS, L. T. Greener pastures and the impact of dynamic institutional preferences. **Review of Financial Studies**, v. 16, n. 4, p. 1203–1238, 2003.

BENSAÏDA, A. Herding effect on idiosyncratic volatility in U.S. industries. **Finance Research Letters**, v. 23, n. 1, p. 121-132, 2017.

BIKHCHANDANI, S.; SHARMA, S. Herd behavior in financial markets. **IMF Staff Papers**, v. 47, n. 3, p. 279–310, 2000.

BITSHARES WEBSITE - **Bitshares Blockchain**. Disponível em <<https://bitshares.org/>>, visualizado em: 05 de maio de 2019.

BOHL, M. T.; REITZ, S. The influence of positive feedback trading on return autocorrelation: Evidence for the German stock market. In: **Aktuelle Entwicklungen im Finanzdienstleistungsbereich**. Physica, Heidelberg, p. 221-233, 2004.

BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. **Journal of Econometrics**, v. 31, n. 3, p. 307– 327, 1986.

BOLLERSLEV, T. Modeling the coherence in short-run nominal exchange rates: A multivariate generalized ARCH model. **Review of Economics and Statistics**, v. 72, n. 3, p. 498-505, 1990.

BOLLERSLEV, T. Glossary to arch (garch). **CREATES Research Paper**, Duke University, 2008.

BOUOYOUR, J.; REFK S.; AVIRAL-KUMAR T. Is Bitcoin business in-come or speculative foolery? New ideas through an improved frequency domain anal-ysis. **Annals of Financial Economics**, v. 10, n. 1, p. 1-23, 2015.

BOURI, E.; AZZI, G.; DYHRBERG, A. H. On the return-volatility relationship in the Bitcoin market around the price crash of 2013. **Economics: The Open-Access, Open-Assessment E-Journal**, v. 11, n. 2, p. 1–16, 2017.

BOURI, E.; GUPTA, R.; ROUBAUD, D. Herding Behavior in Cryptocurrencies. **Finance Research Letters**, v. 29, n. 1, p. 216-221, 2018.

BOUOYOUR, J.; SELMI, R. Bitcoin Price: Is it Really That New Round of Volatility Can Be on Way? **MPRA Paper**, n. 65580, 2015.

BOZZA, C. C. **Análise de feedback trading para criptoativos usando VAR**. 42f. Dissertação (Mestrado em Administração de Empresas) - Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, 2019.

BRITO, J.; CASTILLO, A. Bitcoin: A Primer for Policymakers. **Policy: A Journal of Public Policy and Ideas**, v. 29, n. 4, p. 3-12, 2013.

BROCK, W.; DECHERT, D.; SCHEINKMAN, J.; LEBARON, B. A test for independence based on the correlation dimension. **Econometric Reviews** v. 15, n. 3, p. 197–235, 1996.

BRUNNERMEIER, M.; PEDERSEN, L. Predatory trading. **Journal of Finance** v. 60, n. 4, p. 1825-1863, 2005.

BRYANS, D. Bitcoin and Money Laundering: Mining for an Effective Solution. **Indiana Law Journal**, v. 89, n. 1, p. 441-472, 2014.

BUSINESS INSIDER UK. **This animation shows the explosion in ICO funding over the last four years**. 2017. Disponível em: <<http://uk.businessinsider.com/>>, visualizado em: 24/05/2018.

CAI, J. A Markov model of switching-regime ARCH. **Journal of Business & Economic Statistics**, v. 12, n. 1, p. 309–316, 1994.

CAMPBELL, S. A review of backtesting and backtesting procedure. **Finance and Economics Discussion Series**, Divisions of Research & Statistics and Monetary Affairs, Federal Reserve Board, Washington D.C, 2005.

CASARIN, R.; SARTORE, D.; TRONZANO, M. A Bayesian Markov-Switching Correlation Model for Contagion Analysis on Exchange Rate Markets. **Journal of Business & Economic Statistics**, v. 36, n. 1, p. 101-114, 2018.

CERMAK, V. Can Bitcoin become a viable alternative to fiat currencies? An empirical analysis of Bitcoin's volatility based on a GARCH model. **SSRN Electronic Journal**. 2017. Available at: <<https://ssrn.com/abstract=2961405>>, Access in: June 22, 2019.

CHANG, E. C.; CHENG, J. W.; KHORANA, A. An examination of herd behavior in equity markets: An international perspective. **Journal of Banking & Finance**, v. 24, n. 1, p. 1651–1679, 2000.

CHAU, F.; DEESOMSAK, R.; LAU, M. C. K. Investor sentiment and feedback trading: Evidence from the exchange-traded fund markets. **International Review of Financial Analysis**, v. 20, n. 5, p. 292-305, 2011.

CHEAH, E.T.; FRY, J. Speculative bubbles in bitcoin markets? An empirical investigation into the fundamental value of bitcoin. **Economics Letters**, v. 130, n. 1, p. 32–36, 2015.

CHEN, T. Do Investors Herd in Global Stock Markets? **The Journal of Behavioral Finance**, v. 14, n. 1, p. 230–239, 2013.

CHEN, S.; CHEN, C. YI-HSUAN; HÄRDLE, W.; LEE, T. M.; ONG, B. A first econometric analysis of the CRIX family. **SFB 649 Working Paper**, n. 2016-031, 2016.

CHEN, C. YI-HSUAN; HÄRDLE, W. K.; HOU, A. J.; WANG, W. Pricing Cryptocurrency Options: The Case of CRIX and Bitcoin. **IRTG 1792 Discussion Paper**, n. 2018-004, 2018.

CHEN, C.; ZHOU, Z. G. Portfolio returns, market volatility, and seasonality. **Review of Quantitative Finance and Accounting**, v. 17, n. 1, p. 27-43, 2001.

CHEUNG, A. W.-K.; ROCA, E.; SU, J.-J. Crypto-currency bubbles: an application of the Phillips, Shi and Yu (2013) methodology on Mt. Gox bitcoin prices. **Applied Economics**, v. 47, n. 23, p. 2348-2358, 2015.

CHIANG, T. C.; ZHENG, D. An empirical analysis of herd behavior in global stock markets. **Journal of Banking and Finance**, v. 34, n. 8, p. 1911-1921, 2010.

CHOI, N.; SKIBA, H. Institutional herding in international markets. **Journal of Banking & Finance**, v. 55, n. 1, p. 246-259, 2015.

CHOLLETE, L.; DE LA PEÑA, V.; LU, C. Comovement of international financial markets. **SSRN Electronic Journal**, n. 675382, 2005.

CHRISTIE, W. G.; HUANG, R. D. Following the pied piper: Do individual returns herd around the market? **Financial Analysts Journal**, v. 51, n. 4, p. 31–37, 1995.

CHU, J.; CHAN, S.; NADARAJAH, S.; OSTERRIEDER, J. GARCH Modelling of Cryptocurrencies. **Journal of Risk Financial Management**, v. 10, n. 4, 2-15, 2017.

CIAIAN, P.; RAJCANIOVA, M.; KANCS, D. The economics of BitCoin Price Formation. **Applied Economics**, v. 48, n. 19, p. 1799-1815, 2016.

CIPRIANI, M.; GUARINO, A. Herd Behavior and Contagion in Financial Markets. **The Journal of Theoretical Economics**, v. 8, n. (1), p. 1-56, 2008.

COHEN, B.; SHIN, H. Positive feedback trading under stress: Evidence from the US Treasury securities market. **BIS Working Paper**, n. 122, 2003.

COINDESK WEBSITE. **Coindesk**. Disponível em: <<https://www.coindesk.com/>> Acesso em: 24/05/2018.

COINMARKETCAP WEBSITE – **Top Cryptocurrencies by Market Capitalization**. disponível em: <<https://coinmarketcap.com/>>. Acesso em: 17/12/2017.

CORBET, S.; LUCEY, B. M.; URQUHART, A.; YAROVAYA, L. Cryptocurrencies as a Financial Asset: A Systematic Analysis. **SSRN Electronic Journal**, 2018. Available at: <<https://ssrn.com/abstract=3143122>>. Acesso em: 22/06/2019.

CHRISTOFFERSEN P. F. "Evaluating Interval Rorecasts." **International Economic Review**, v. 39, n. 4, p. 841-862, 1998.

CRYPTOCOMPARE WEBSITE - **Cryptocompare**. Disponível em: <<https://www.cryptocompare.com>> Visualizado em: 17 de dez. de 2017.

CRYPTO INDEX WEBSITE – **Crypto Index**. disponível em: <crix.hu-berlin.de>, Visualizado em: 17 de dez. de 2017.

CUTLER, D. M.; POTERBA, J. M.; SUMMERS, L. H. Speculative dynamics and the role of feedback traders. **The American Economic Review**, v. 80, n. 2, p. 63–68, 1990.

CVM – COMISSÃO DE VALORES MOBILIÁRIOS. **Instrução Normativa N° 555**, de 17 de dezembro de 2014. Disponível em: <<http://www.cvm.gov.br/legislacao/instrucoes/inst555.html>>. Acesso em: 15/08/2019.

DASHCOIN WEBSITE. **Your money, your way**. Disponível em: <<https://www.dash.org/>>, visualizado em: 24/05/2018.

DE LONG, J. B.; SHLEIFER, A.; SUMMERS, L. H.; WALDMAN, R. J. Positive feedback investment strategies and destabilizing rational speculation. **Journal of Finance**, v. 45, n. 2, p. 379-395, 1990.

DEMIRER, R.; KUTAN, A. M.; CHEN, C. D. Do investors herd in emerging stock markets? Evidence from the Taiwanese market. **Journal of Economic Behavior & Organization**, v. 76, n. 2, p. 283-295, 2010.

DOGECOIN WEBSITE - **What is Dogecoin?** disponível em <<https://dogecoin.com/>>, visualizado em: 05 de maio de 2019.

- DUEKER, M. Markov Switching in GARCH Processes and Mean-Reverting Stock-Market Volatility. **Journal of Business & Economic Statistics**, v. 17, n. 1, p. 26-34, 1997.
- DUFOUR, A.; ENGLE, R. Time and the Price Impact of a Trade. **Journal of Finance**, v. 55, n. 6, p. 2467–2498, 2000.
- DUNGEY, M.; ZHUMABEKOVA, D. Testing for contagion using correlations: some words of caution. **Pacific Basin Working Paper**, n. PB01-09, 2001.
- DWYER, G. P. The economics of Bitcoin and similar private digital currencies. **Journal of Financial Stability**, v. 17, n. 1, p. 81–91, 2015.
- DYHRBERG, A. H. Bitcoin, gold and the dollar –A GARCH volatility analysis. **Finance Research Letters**, v. 16, n. 1, p. 85–92, 2016.
- ECONOMOU, F.; KATSIKAS, E.; VICKERS, G. Testing for herding in the Athens Stock Exchange during the crisis period. **Finance Research Letters**, v. 18, n. 1, p. 334-341, 2016.
- ELENDNER, H.; TRIMBORN, S.; ONG, B.; LEE, T. M. The Cross-Section of Crypto-Currencies as Financial Assets: An Overview. **SFB 649 Discussion Paper**, n. 2016-038, 2016.
- ELKHALDI, A.; ABELFATTEH, Y. B. Testing Herding Effects on Financial Assets Pricing: The Case of the Tunisian Stock Market. **British Journal of Economics, Management & Trade**, v. 4, n. 7, p. 1046-1059, 2014.
- ENGLE, R. F.; ITO, T.; LIN, W. Meteor showers or heat waves? Heteroskedastic intra daily volatility in the foreign exchange market. **Econometrica**, v. 58, n. 3, p. 525–542, 1990.
- ENGLE, R.; PATTON, A. Impacts of trades in an error-correction model of quote prices. **Journal of Financial Markets**, v. 7, n. 1, p. 1–25, 2004.
- ENGLE, R. F.; NG, V. K. Measuring and testing the impact of news on volatility. **The Journal of Finance**, v. 48, n. 5, p. 1749-1778, 1993.
- ENGLE, R. F. Dynamic conditional correlation: A simple class of multivariate generalized autoregressive conditional heteroskedasticity models. **Journal of Business and Economic Statistics**, v. 20, n. 3, p. 339-350, 2002.
- ETHEREUM WEBSITE – **Ethereum**. disponível em <Ethereum.org>, visualizado em: 17 de out. de 2017.
- EVANS, M. FX trading and exchange rate dynamics. **Journal of Finance**, v. 57, n. 6, p. 2405–2447, 2002.
- EXTANCE, A. Bitcoin and Beyond. **Nature**, v. 526, n. 7571, p. 21-23, 2015.
- FAMA, E. F. The behavior of stock market prices. **Journal of Business**, v. 38, n. 1, p. 34-105, 1965.
- FILETTI, J. P.; HOTTA, L. K.; ZEVALLOS, M. Analysis of contagion in emerging markets. **Journal of Data Science**, v. 6, n. 1, p. 601–626, 2008.
- FORBES, K. J.; RIGOBON, R. No contagion, only interdependence: measuring stock market comovements. **Journal of Finance**, v. 57, n. 5, p. 2223–2261, 2002.

FRANKEL, J. A.; FROOT, K. A. The dollar as an irrational speculative bubble: The tale of fundamentalists and chartists. **Marcus Wallenberg paper on international finance**, v. 1, n. 1, p. 27-55, 1986.

FRAZZINI, A.; LAMONT A. O. Dumb money: Mutual fund flows and the crosssection of stock returns. **Journal of Financial Economics**, v. 88, n. 2, p. 299-322, 2008.

FRIEDMAN, B. M. A comment: stock prices and social dynamics. **Brookings Papers on Economic Activity**, v. 2, n. 1, p. 504–508, 1984.

FRIEDMAN, B. M. The case for flexible exchange rates. Essays in positive economics. **University of Chicago Press**, v. 1970, n. 1, p. 3-43, 1953.

FROOT, K.; SCHARFSTEIN, D.; STEIN, J. Herd on the street: informational inefficiencies in a market with short-term speculation. **The Journal of Finance**, v. 47, n. 1, p. 1461–1484, 1992.

FRY, R. A., MARTIN, V. L., TANG, C. A new class of tests of contagion with applications. **Journal of Business and Economic Statistics**, v. 28, n. 3, p. 423-437, 2010.

FRY-MCKIBBIN, R.; HSIAO, C Y-L. Extremal dependence tests for contagion. **Econometric Reviews**, v. 37, n. 6, p. 626-649, 2018.

GALARIOTIS, E. C.; RONG, W.; SPYROU S. I. Herding on fundamental information: A comparative study. **Journal of Banking & Finance**, v. 50, n. 1, p. 589-598, 2015.

GKILLAS, K.; KATSIAMPA, P. An application of extreme value theory to cryptocurrencies. **Economics Letters**, v. 164, n. 1, p. 109–111, 2018.

GLOSTEN, L. R.; JAGANNATHAN, R.; RUNKLE, D. E. Relationship between the expected value and the volatility of the nominal excess return on stocks. **Journal of Finance**, v. 48, n. 5, p. 1779-1801, 1993.

GOLDFELD, S. M.; QUANDT, R. E. A Markov Model for Switching Regressions. **Journal of Econometrics**, v. 1, n. 1, p. 3-16, 1973.

GOMPERS, P. A.; METRICK, A. Institutional investors and equity prices. **Quarterly Journal of Economics**, v. 116, n. 1, p. 229–259, 2001.

GRAY, S. Modeling the conditional distribution of interest rates as a regime-switching process. **Journal of Financial Economics**, v. 42, n. 1, p. 27-62, 1996.

GREEN, C. Economic news and the impact of trading on bond prices. **Journal of Finance**, v. 59, n. 3, p. 1201 - 1233, 2003.

GUIA DO BITCOIN - **Guia do Bitcoin**. Disponível em: <<https://guiadobitcoin.com.br>>. Acesso em: 17/12/2017.

HAMILTON, J. D. **Times Series Analysis**. 1st ed., Oxford. 1994.

HAMILTON, J. D. A new approach to the economic analysis of nonstationary time series and the business cycle. **Econometrica: Journal of the Econometric Society**, v. 57, n. 2, p. 357-384, 1989.

HAMILTON, J. D.; SUSMEL, R. Autoregressive Conditional Heteroskedasticity and Changes in Regime. **Journal of Econometrics**, v. 64, n. 1-2, p. 307-333, 1994.

- HANKE, J. E.; WICHERN, D. W.; REITSCH, A. G. **Business forecasting**. 7. Ed. New York: Prentice Hall, 2001.
- HANNAN, E. J.; QUINN, B. G. "The Determination of the order of an autoregression", **Journal of the Royal Statistical Society**, v. 41, n. 1, p. 190–195, 1979.
- HANSEN, P.R.; LUNDE, A. Consistent Ranking of Volatility Models. **Journal of Econometrics**, v. 131, n. 1-2, p. 97-121, 2006
- HASBROUCK, J. Measuring the Information Content of Stock Trades. **Journal of Finance**, v. 46, n. 1, p. 179–206, 1991.
- HAUBRICH, J. G.; ORR, A. Bitcoin versus the Dollar. **Federal Reserve: Bank of Cleveland**, p. 2–4, 2014. Disponível em: <<https://www.clevelandfed.org/en/newsroom-and-events/publications/economic-trends/2014-economic-trends/et20140814-bitcoin-versus-the-dollar.aspx>>. Acesso em: 27/09/2017.
- HENTSCHEL, L. All in the family Nesting symmetric and asymmetric GARCH models. **Journal of Financial Economics**, v. 39, n. 1, p. 71-104, 1995.
- HERNANDEZ, R. G. **Distribuição alfa estável aplicada a risco de mercado**. Dissertação (Mestrado em Economia) - Fundação Getúlio Vargas de São Paulo. São Paulo, 103 p., 2016.
- HIROSE, T.; KATO, H. K.; BREMER, M. Can margin traders predict future stock returns in Japan? **Pacific-basin Finance Journal**, v. 17, n. 1, p. 41-57, 2009.
- HIRSHLEIFER, D.; SUBRAHMANYAM, A.; TITMAN, S. Security analysis and trading patterns when some investors receive information before others. **Journal of Finance**, v. 49, n. 5, p. 1665–1698, 1994.
- HSIAO, C. Y.-L. A New Test of Financial Contagion with Application to the US Banking Sector. **SSRN Electronic Journal**, 2012. Available at: <https://papers.ssrn.com/sol3/papers.cfm?abstract_id=2131672>, Access in: June 22, 2019.
- HU, B.; MCINISH, T.; MILLER, J.; ZENG, L. Intraday price behavior of cryptocurrencies. **Finance Research Letters**, v. 28, n. 1, p. 337-342, 2018.
- HURLBURT, G. F.; BOJANOVA, I. Bitcoin: Benefit or Curse? **IT Professional**, v. 16, n. 3, p. 10-15, 2014.
- HURST, H. E. Long term storage capacity of reservoirs. **Transactions of the American society of civil engineers**, v. 55, n. 1, p. 400-410, 1951.
- HUYNH T. L. D.; NGUYEN S. P.; DUONG D. Contagion Risk Measured by Return Among Cryptocurrencies, 2018. in: Anh L., Dong L., Kreinovich V., Thach N. (Eds.) **Econometrics for Financial Applications. ECONVN 2018**. Studies in Computational Intelligence, vol 760. Springer, Cham., 987-998, 2018.
- HWANG, S.; SALMON, M. Market stress and herding. **Journal of Empirical Finance**, v. 11, n. 4, p. 585-616, 2004.
- IAVORACHI, M. The Bitcoin Project and the Free Market. **CES Working Papers**, v. 5, n. 4, p. 529-534, 2013.

KABIR, M. H.; SHAKUR, S. Regime-dependent herding behavior in Asian and Latin American stock markets. **Pacific-Basin Finance Journal**, v. 47, n. 1, p. 60-78, 2018.

KARPOFF, J. M. The relationship between price changes and trading volume: a survey. **Journal of Financial and Quantitative Analysis**, v. 22, n. 1, p. 109-126, 1987.

KATSIAMPA, P. Volatility estimation for Bitcoin: A comparison of GARCH models. **Economics Letters**, v. 158, n. 1, p. 3-6, 2017.

KEYNES, J. M. **The General Theory of Employment, Interest and Money**. 1st ed. Macmillan, New York, 1936.

KIM, C. J.; NELSON, C. R. **State-Space Models with Regime Switching**. 1st ed. Cambridge: The MIT Press, 1999.

KLAASSEN, F. Improving GARCH volatility forecasts with regime-switching GARCH. **Empirical Economics**, v. 27, n. (2), p. 363-394, 2002.

KOUTMOS, G. Positive feedback trading: a review. **Review of Behavioral Finance**, v. 6, n. 2, p. 155-162, 2014.

KRAMER, L. Intraday stock returns, time-varying risk premia, and diurnal mood variation. **SSRN Electronic Journal**, 2001. Available at: <<https://ssrn.com/abstract=248293>>, Access in: June 22, 2019.

KUPIEC, P. H. "Techniques for Verifying the Accuracy of Risk Measurement Models." **The Journal of Derivatives**, v. 3, n. 2, p. 73-84, 1995.

KYNIGAKIS, J. **Testing for Contagion among Financial Markets**. 63f. Master Dissertation. Department of Banking & Financial Management, University of Piraeus, Piraeus, Greece, 2015.

LAKONISHOK, J.; SHLEIFER, A.; VISHNY, R. W. The impact of institutional trading on stock prices. **Journal of Financial Economics**, v. 32, n. 1, p. 23-43, 1992.

LAOPODIS, N. Feedback trading and autocorrelation interactions in the foreign exchange market: Further evidence. **Economics Modelling**, v. 22, n.1, p. 811-827, 2005.

LECLAIR, E. M. Herding in the cryptocurrency market. Discussion paper ECON 5029, **6th Annual Doctoral Workshop in Applied Econometrics**, Ryerson University, Canada, 2018.

LEE, B. S.; RUI, O. M. Dynamic Relationship between Stock Returns and Trading Volume: Domestic and Cross Country Evidence. **Journal of Banking and Finance**, v. 26, n. 1, p. 51-78, 2002.

LEE, H.; WU, H.; WANG, J. Contagion effect in financial markets after the South-East Asia Tsunami. **Research in International Business and Finance**, v. 21, n. 2, p. 281-296, 2007.

LETRA, I. J. S. **What drives cryptocurrency value? A volatility and predictability analysis**. 49f. Dissertação (Mestrado em Decisão Económica e Empresarial) - Instituto Superior de Economia e Gestão, Universidade de Lisboa, 2016.

LI, M-Y L.; LIN, H-W W. Examining the Volatility of Taiwan Stock Index Returns via a Three-Volatility-Regime Markov-Switching ARCH Model. **Review of Quantitative Finance and Accounting**, v. 21, n. 2, p. 123–139, 2003

LI, M-Y L.; LIN, H-W W. Estimating value-at-risk via Markov switching ARCH models – an empirical study on stock index returns. **Applied Economics Letters**, v. 11, n. 11, p. 679–691, 2004.

LI, F.; ZHU, H. Testing for financial contagion based on a nonparametric measure of the cross-market correlation. **Review of Financial Economics**, v. 23, n. 3, p. 141-147, 2014.

LITECOIN WEBSITE. **The Cryptocurrency for Payments**. Disponível em: <<https://litecoin.org/>>, visualizado em: 24/05/2018.

LITTLE, E. M. Bitcoin. **The Investment Lawyer**, v. 21, n. 5, p. 22-26, 2014.

LOMBARDI, I. T.; GALVÃO, A. B.; LAURINI, M. P.; VALLS PEREIRA, P. L. A dinâmica do contágio entre Brasil e Argentina. In: **IV Encontro Brasileiro de Finanças**, Rio de Janeiro, Brasil, 2004.

LONGSTAFF, F. A. The subprime credit crisis and contagion in financial markets. **Journal of Financial Economics**, v. 97, n. 3, p. 436-450, 2010.

MCALEER, M; DA VEIGA B. "Forecasting Value-at-Risk with a Parsimonious Portfolio Spillover GARCH (PS-GARCH) Model." **Journal of Forecasting**, v. 27, n. 1, p. 1-19, 2008.

MAFTEI, L. Bitcoin - Between Legal and Informal. **CES Working Papers**, v. 6, n. 3, p. 53-59, 2014.

MARÇAL, E. F.; PEREIRA, P. L. V. Testing Contagion Hypothesis from multivariate volatility models. **Revista de Econometria**, v. 28, n. 2, p. 67-87, 2008.

MARCUCCI, J. Forecasting stock market volatility with regime-switching GARCH models. **Studies in Nonlinear Dynamics & Econometrics**, v. 9, n. 4, p. 1-42, 2005.

MARKOV, A. A. Rasprostranenie zakona bol'shih chisel na velichiny, zavisyaschie drug ot druga. **Izvestiya Fiziko-matematicheskogo obschestva pri Kazanskom universitete**, v. 15, n. 135-156, p. 18, 1906.

MIGHRI, Z.; ALSAGGAF, M. I. Volatility Spillovers among the Cryptocurrency Time Series. **International Journal of Economics and Financial Issues**, v. 9, n. 3, p. 81-90, 2019.

MONERO WEBSITE. Disponível em: <<https://getmonero.org/>>, visualizado em: 24/05/2018.

NAGATA, S.; OYA, K. Volatility Forecast Comparison with Biased Proxy. **Discussion Paper Series**, Center for the Study of Finance and Insurance, Osaka University, 2012.

NAKAMOTO, S. **Bitcoin: A peer-to-peer electronic cash system**, 2008. Disponível em:< <http://bitcoin.org/bitcoin.pdf>>, Acesso em: 08/2018.

NEGURITA, O. Bitcoin - Between Legal and Financial Performance. **Contemporary Readings in Law and Social Justice**, v. 6, n. 1, p. 242-248, 2014.

NELSON, D. B. Conditional heteroskedasticity in asset returns: A new approach. **Econometrica**, v. 59, n. 2, p. 347-370, 1991.

NGUYEN, C.; BHATTI, M. I.; HENRY, D. Are Vietnam and Chinese stock markets out of the US contagion effect in extreme events? **Physica A: Statistical Mechanics and its Applications**, v. 480, n. 15, p. 10-21, 2017.

NOFSINGER, J. R.; SIAS, R. W. Herding and feedback trading by institutional and individual investors. **Journal of Finance**, v. 54, n. 1, p. 2263-2295, 1999.

OLIVEIRA, A. B.; PEREIRA, P. L. V. Mudanças de Regime e Persistência dos Choques sobre a Volatilidade para a Série de Preços do Petróleo: Uma análise Comparativa da Família GARCH e Modelos com Mudanças de Regime Markoviana – MSIH e SWARCH. **Escola de Economia de São Paulo: CEQEF Working Paper Series**, Texto Para Discussão n. 312, 2012.

OPENCOIN WEBSITE – Disponível em: <<http://opencoin.com>>, visualizado em: 17 de dez. de 2017.

OSLER, C. L. Stop-loss orders and price cascades in currency markets. **Journal of International Money and Finance**, v. 24, n. 1, p. 219-241, 2005.

PATTON, A. J. Volatility Forecast Comparison Using Imperfect Volatility Proxies. **Journal of Econometrics**, v. 160, n. 1, p. 246–256, 2011.

PAYNE, R. Informed trade in spot foreign exchange markets: an empirical investigation. **Journal of International Economics**, v. 61, n. 2, p. 307–329, 2003.

PERICOLI, M.; SBRACIA, M. A primer on financial contagion. **Journal of Economic Surveys**, v. 17, n. 1, p. 571-608, 2003.

PEROBELLI, F. F. C.; VIDAL, T. L.; SECURATO, J. R. Avaliando o Efeito Contágio entre Economias durante Crises Financeiras. **Estudos Econômicos**, v. 43, n. 3, p. 557-594, 2013.

PHILLIP, A.; CHAN, J. S. K.; PEIRIS, S. A new look at Cryptocurrencies. **Economics Letters**, v. 163, n. 1, p. 6-9, 2018.

RIPPLENET WEBSITE. Disponível em: <<https://www.ripple.com>>, visualizado em: 24/05/2018.

RFB – RECEITA FEDERAL DO BRASIL. **Instrução Normativa Nº 1899**, de 03 de maio de 2019. Disponível em:< <http://normas.receita.fazenda.gov.br/sijut2consulta/link.action?visao=anotado&idAto=100592>>. Acesso em: 15/08/2019

RODRIGUEZ, J. C. Measuring financial contagion: A Copula approach. **Journal of Empirical Finance**, v. 14, n. 1, p. 401–423, 2007.

ROGOJANU, A.; BADEA, L. The Issue of Competing Currencies. **Theoretical and Applied Economics**, v. 21, n. 1, p. 103-114, 2014.

SAHALIA, J.; CACHO-DIAZ, R. J.; LAEVEN, R. J. A. Modeling financial contagion using mutually exciting jump processes. **Journal of Financial Economics**, v. 117, n. 3, p. 585–606, 2015.

SALM, C. A.; SCHUPPLI, M. Positive feedback trading in stock index futures: International evidence. **International Review of Financial Analysis**, v. 19, n. 5, p. 313-322, 2010.

- SCHARFSTEIN, D. S.; STEIN, J. C. Herd behavior and investment. **The American Economic Review**, v. 80, n.3, p. 465–479, 1990.
- SCHWARZ, G. Estimating the dimensional of a model. **The Annals of Statistics**, v. 6, n. 2, p. 461-464, 1978.
- SEGNON, M.; BEKIROS, S. Forecasting Volatility in Cryptocurrency Markets. **Center for Quantitative Econmics**, v. 79, n. 1, p. 1-37, 2019.
- SENTANA, E; WADHWANI, S. Feedback Traders and Stock Return Autocorrelations: Evidence from a Century of Daily Data. **The Economic Journal**, v. 102. n. 411, p. 415-425, 1992.
- SHI, J.; CHIANG, T. C.; LIANG, X. Positive-feedback trading activity and momentum profits. **Managerial Finance**, v. 38, n. 5, p. 508–529, 2012.
- SHILLER, R. J. Speculative prices and popular models. **Journal of Economic Perspectives**, v. 4, n. 2, p. 55-65, 1990.
- SIAS, R. W. Institutional herding. **Review of Financial Studies**, v. 17, n. 1, p. 165–206, 2004.
- SILVA, M. F.; PEREIRA, E. J. A. L.; FILHO, A. M. S; CASTRO, A. P. N.; MIRANDA, J. G. V.; ZEBENDE, G. F. Quantifying the contagion effect of the 2008 financial crisis between the G7 countries (by GDP nominal). **Physica A: Statistical Mechanics and its Applications**, v. 453, n. 1, p. 1-8, 2016.
- SIMS, C. A. “Macroeconomics and Reality.” **Econometrica**, v. 48, n. 1, p. 1–48, 1980.
- STAVROYIANNIS, S.; BABALOS, V. Dynamic Properties of the Bitcoin and the US Market. **SSRN Electronic Journal**, 2017. Available at SSRN: <<https://ssrn.com/abstract=2966998>>, Access in: June 22, 2019.
- STELLAR WEBSITE - disponível em <<https://www.stellar.org/>>, visualizado em: 05 de maio de 2019.
- TETHER WEBSITE – disponível em: <[Tether.to](https://tether.to)>, visualizado em: 17 de outubro de 2017.
- THEIL, H.: **Applied Economic Forecasting**. Studies in Mathematical and Managerial Economics, 4. North Holland Publishing, p. 26 – 36, 1966.
- TIWARI, A. K.; KUMAR, S.; PATHAK, R. Modelling the dynamics of Bitcoin and Litecoin: GARCH versus stochastic volatility models. **Applied Economics**, v. 51, n. 37, p. 4073-4082, 2019.
- TRIMBORN, S.; HÄRDLE, W. K. CRIX an index for blockchain based currencies. **SFB 649 Working Paper**, n. 2016-021, Economic Risk, Berlin, 2016.
- TRIMBORN, S.; LI, M; HÄRDLE, W. K. Investing with Cryptocurrencies - A Liquidity Constrained Investment Approach. **SFB 649 Working Paper**, n. 2017-014, Economic Risk, Berlin, 2017.
- TRUEMAN, B. Analyst forecasts and herding behavior. **The Review of Financial Studies**, v. 7, n. 1, p. 97-124, 1994.
- TSAY, R. S. **Analysis of Financial Time Series**. 3^a Ed. New Jersey: John Wiley & Sons, 714 p., 2010.

URQUHART, A., 2017. The Volatility of Bitcoin. **SSRN Electronic Journal**, 2017. Available at SSRN: <<https://ssrn.com/abstract=2921082>>, Access in: June 22, 2019.

VIALE, A. M.; BESSLER, D. A.; KOLARI, J. W. On the Structure of Financial Contagion: Econometric Tests and Mercosur Evidence. **Journal of Applied Economics**, v. 17, n. 2, p. 373-400, 2014.

VIDAL-TOMÁS, D.; IBÁÑEZ, A.M.; FARINÓS, J. E. (2018). Herding in the cryptocurrencies Market: CSSD and CSAD approaches. **Finance Research Letters**. Forthcoming.

VIEIRA, C. R.; SILVA FILHO, O. C. Modelos VaRs e a nova fórmula da exigência de capital da carteira trading. **Pesquisa e Planejamento Econômico**, v. 42, n. 1, p. 137 – 183, 2012.

WERMERS, R. Mutual fund herding and the impact on stock prices. **The Journal of Finance**, v. 54, n. 2, p. 581-622, 1999.

WOOD, R. A.; MCLNISH, T. H.; ORD, J. K. An investigation of transactions data for NYSE stocks. **Journal of Finance**, v. 60, n. 3, p. 723-739, 1985.

YAO, J.; MA, C.; HE, W. P. Investor herding behaviour of Chinese stock market. **International Review of Economics & Finance**, v. 29, n. 1, p. 12-29, 2014.

YERMACK, D. Is Bitcoin a real currency? An Economic Appraisal. In: **Handbook of digital currency**. Academic Press, p. 31-43, 2015.

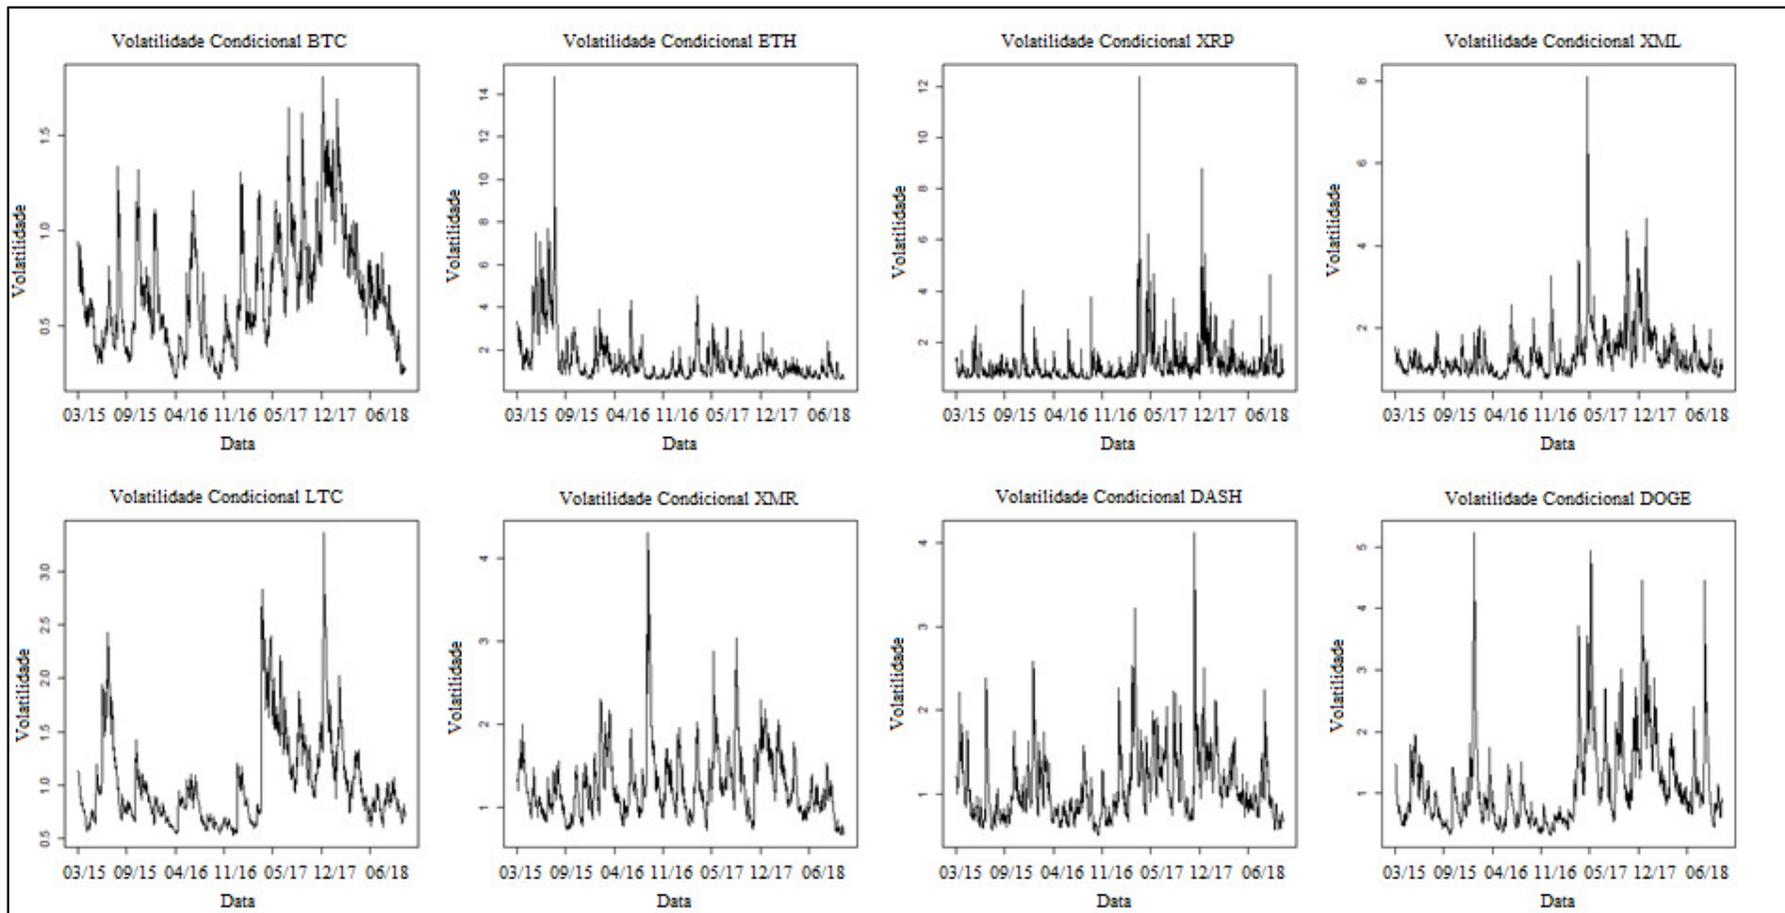
ZAKOIAN, J. M. Threshold heteroscedasticity models. **Journal of Economic Dynamics and Control**, v. 18, n. 5, p. 931–955, 1994.

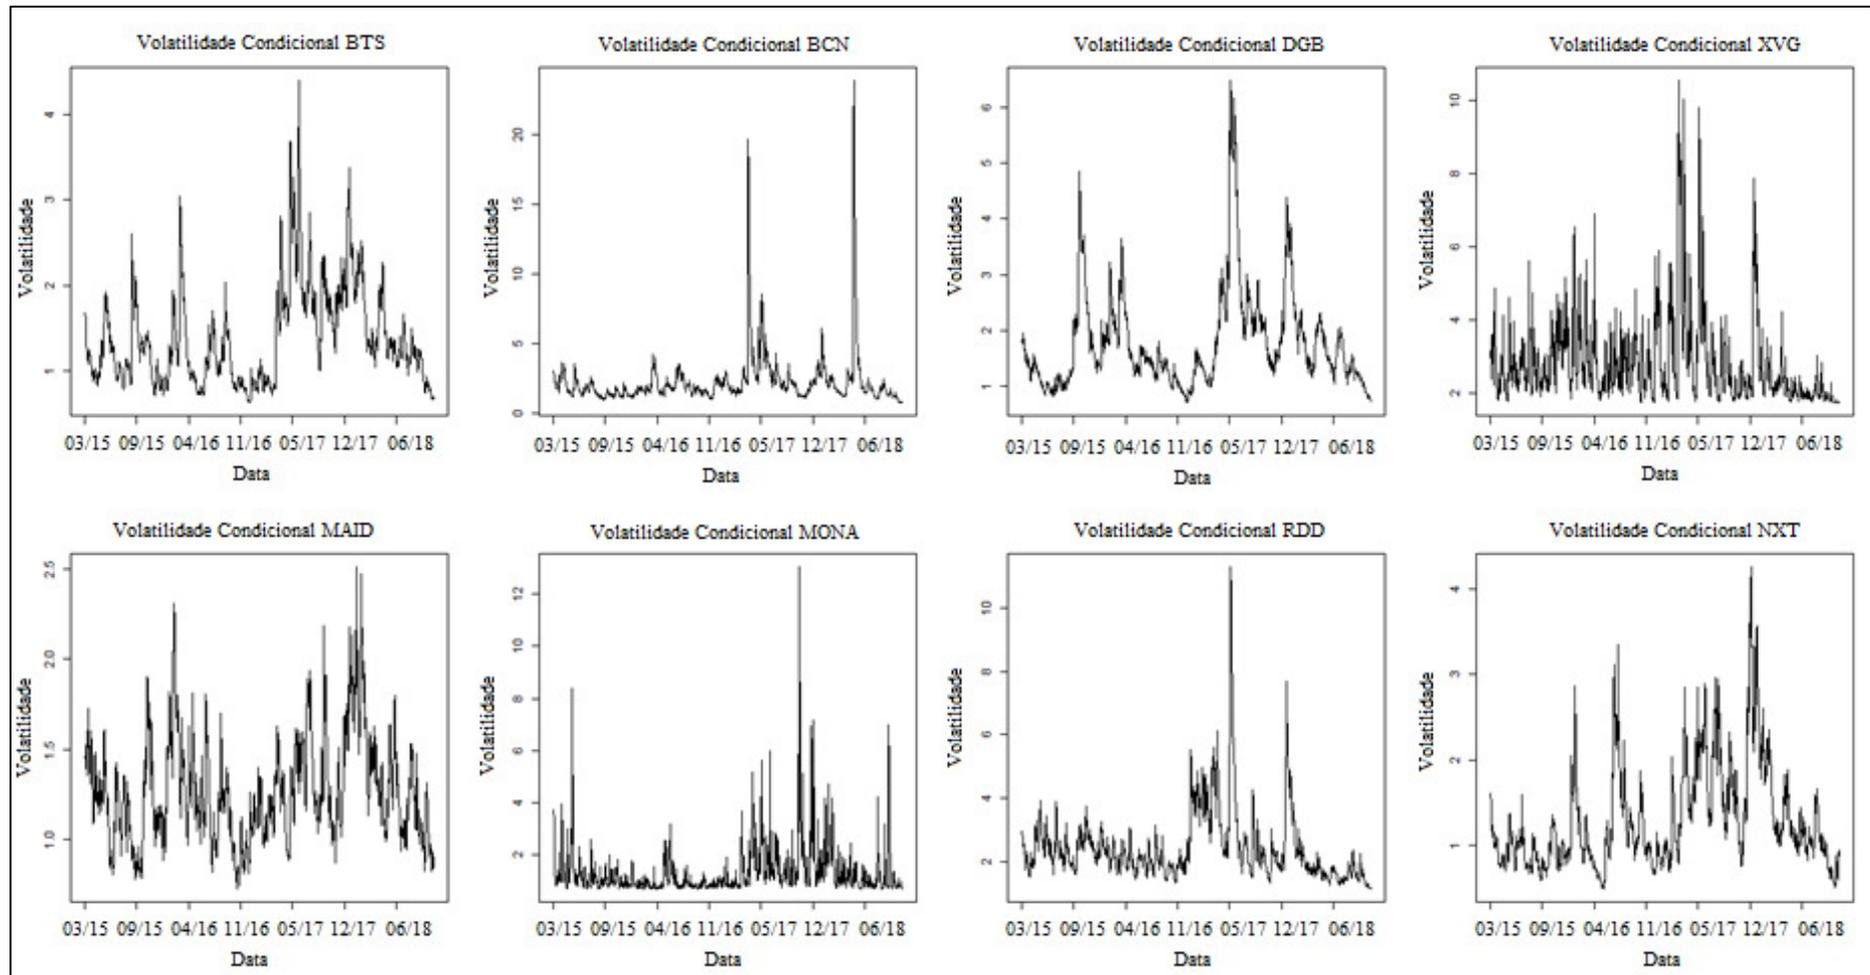
ZIVOT, E.; ANDREWS, D. W. K. Further evidence on the great crash, the oil-price shock, and the unit-root hypothesis. **Journal of Business & Economic Statistics**, v. 20, n. 1, p. 25-44, 2002.

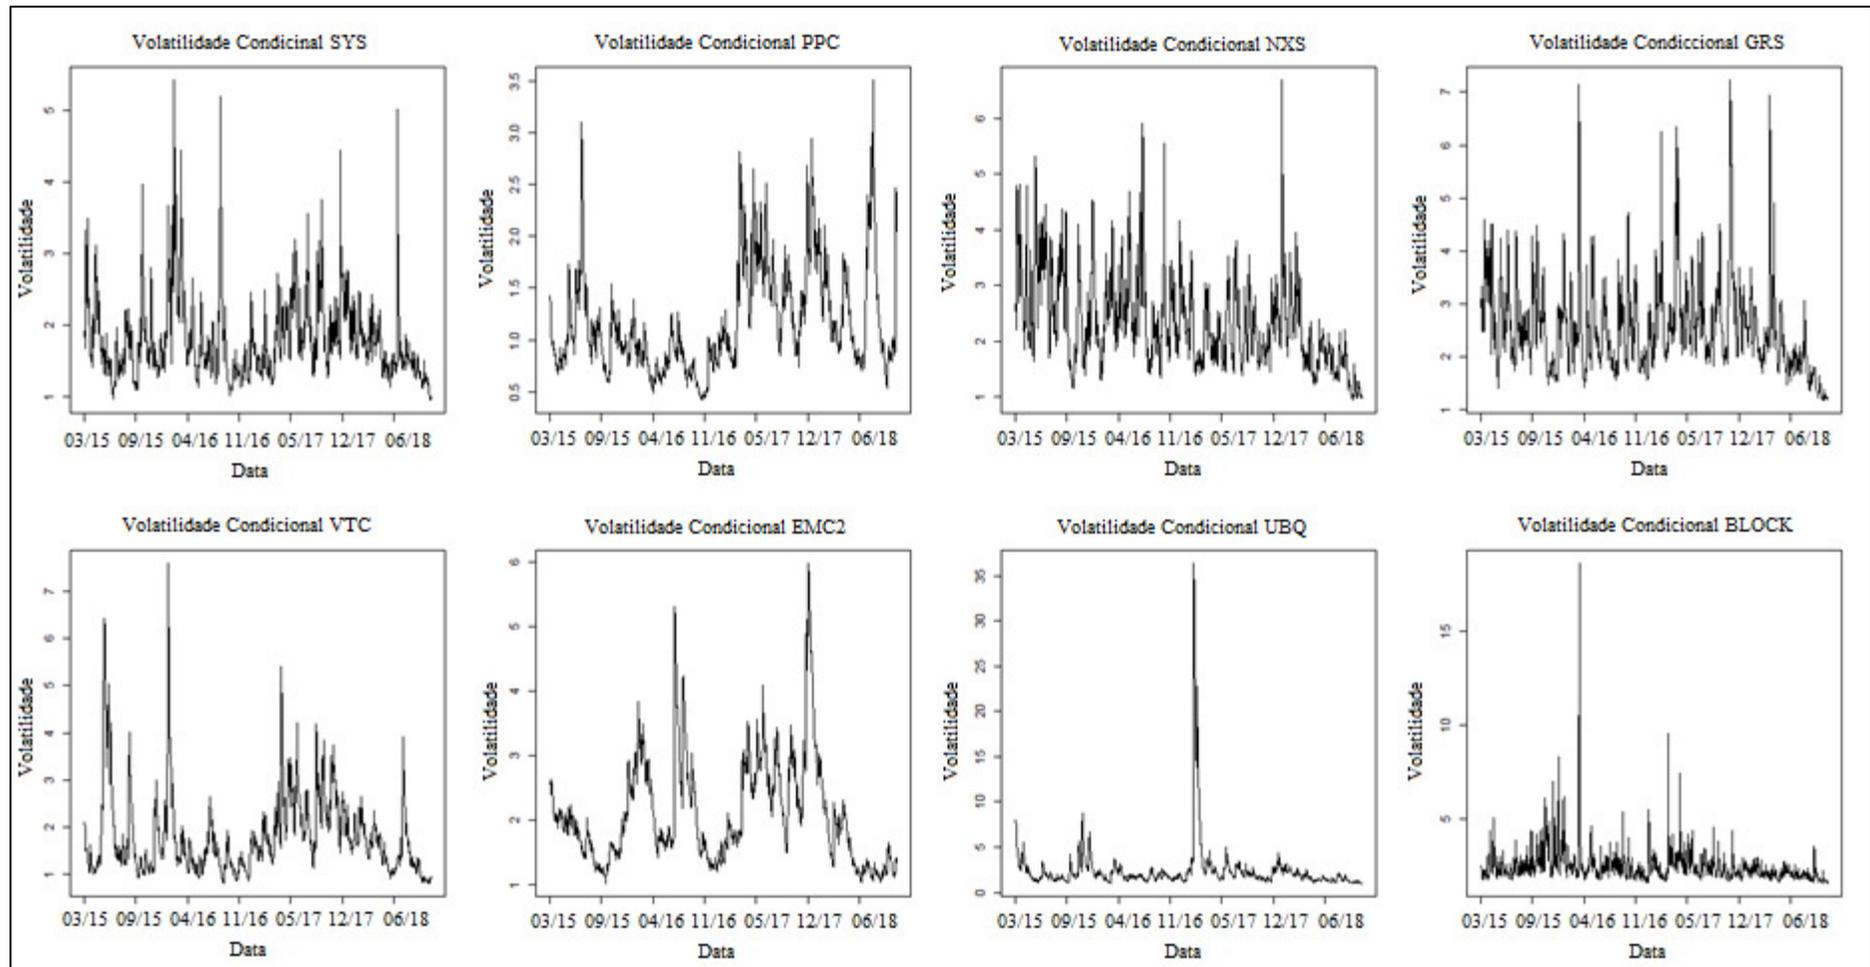
7. ANEXOS

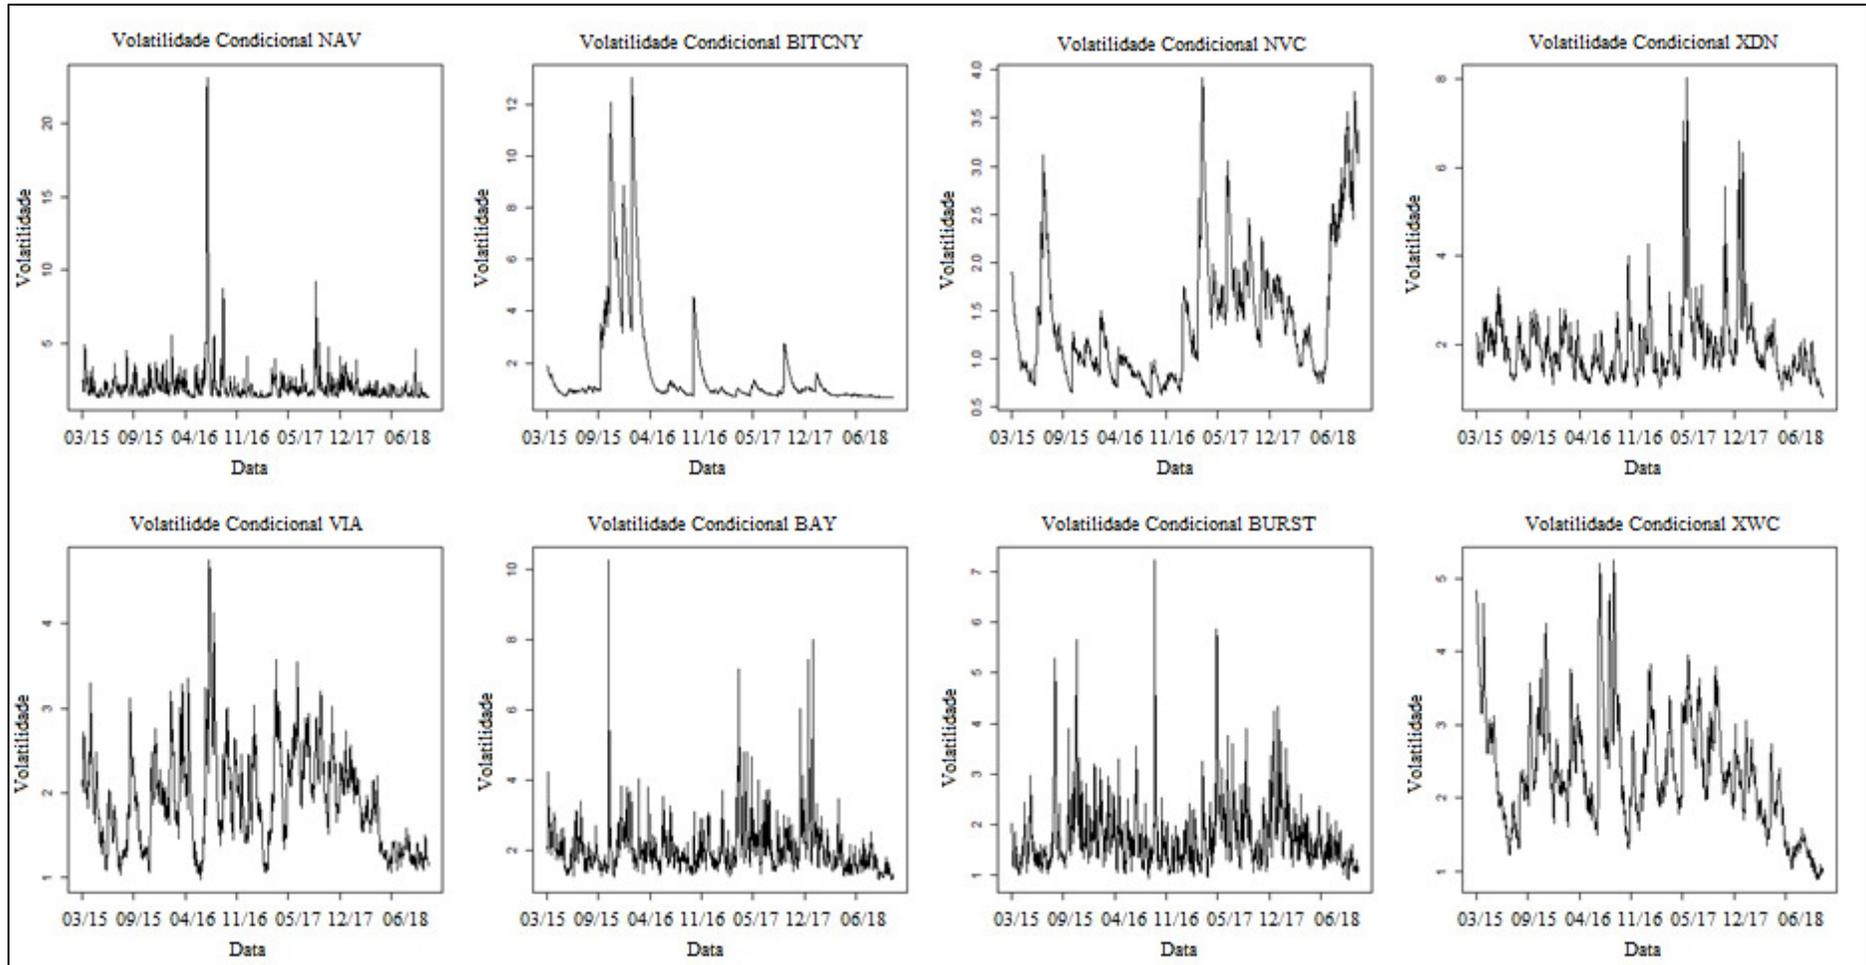
7.1. Anexo 1: Primeiro Ensaio.

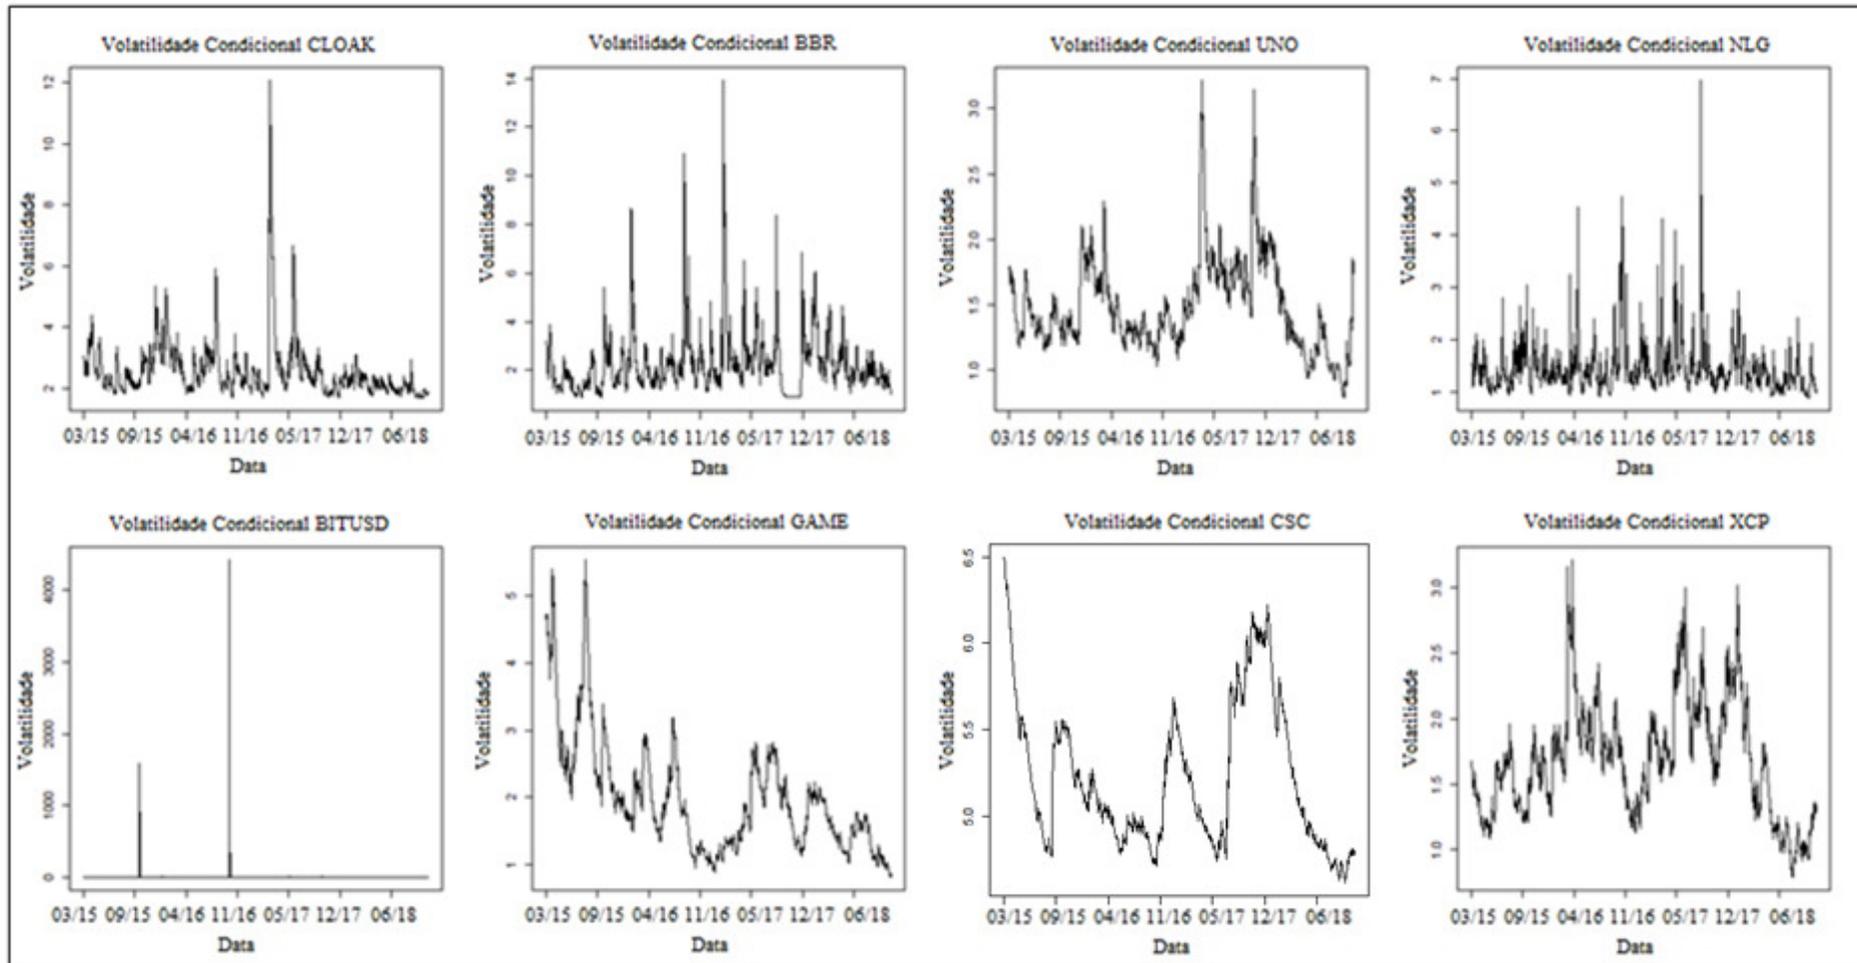
7.1.1. Gráficos de volatilidade condicional para apenas um estado

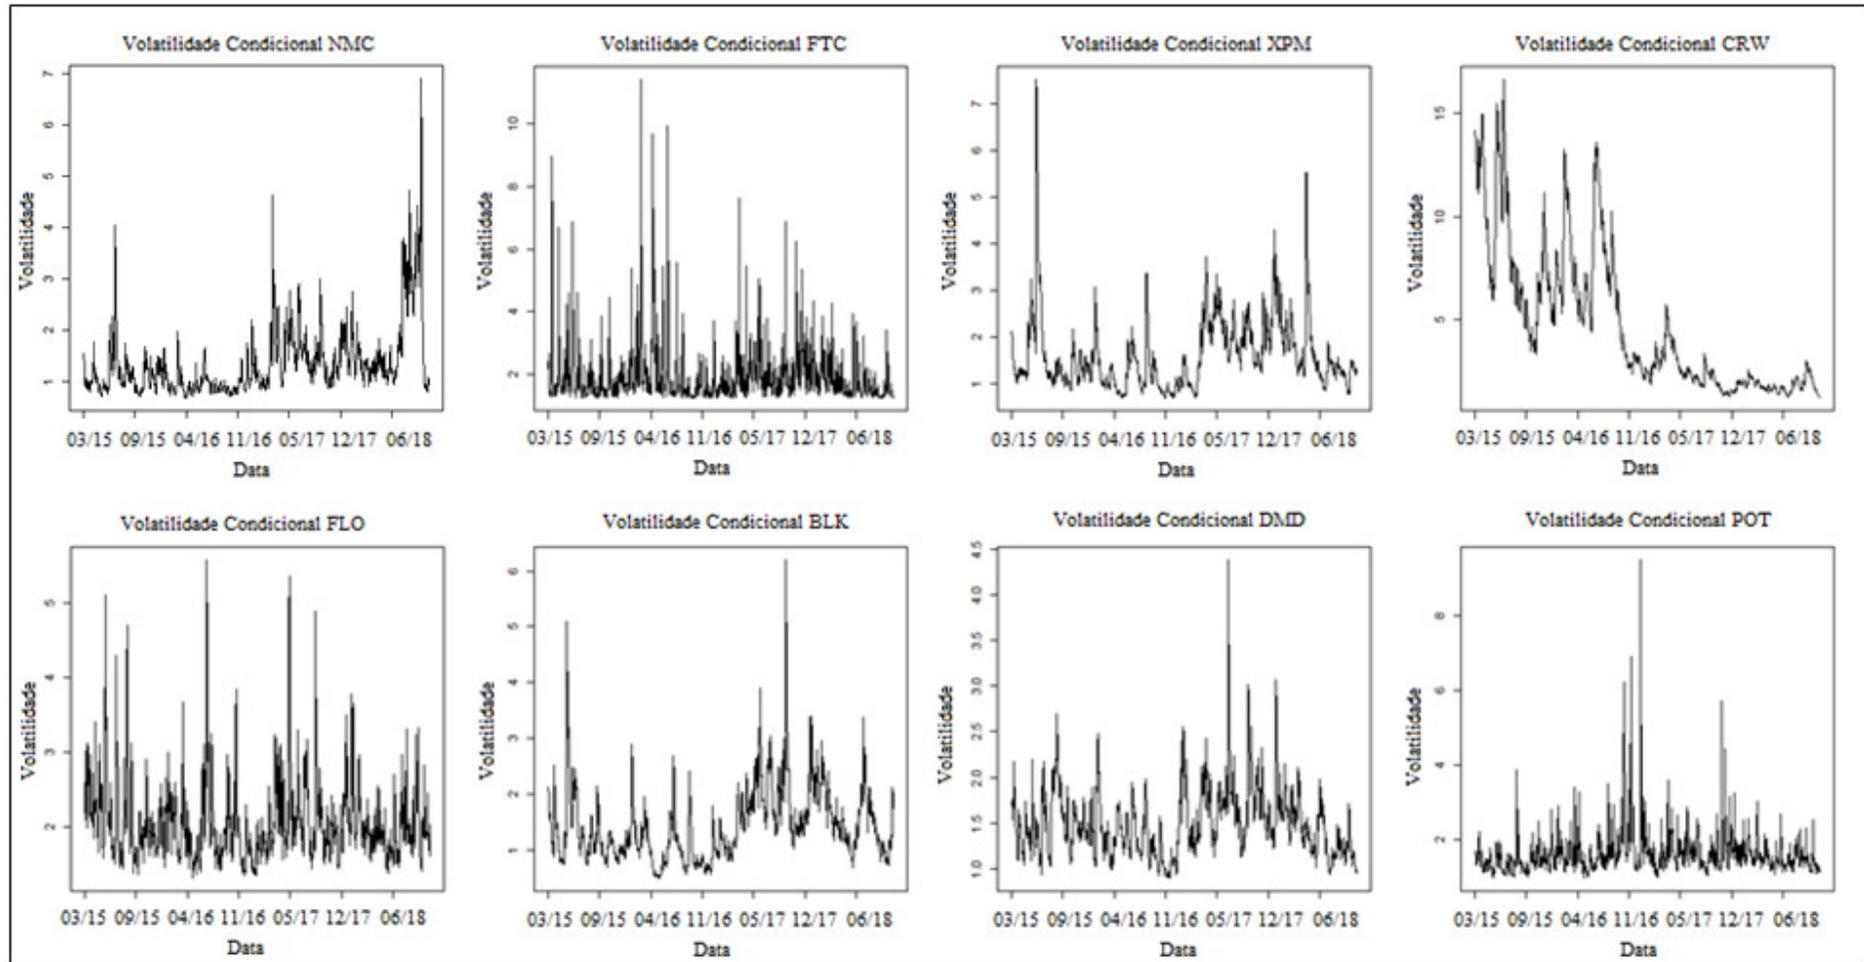




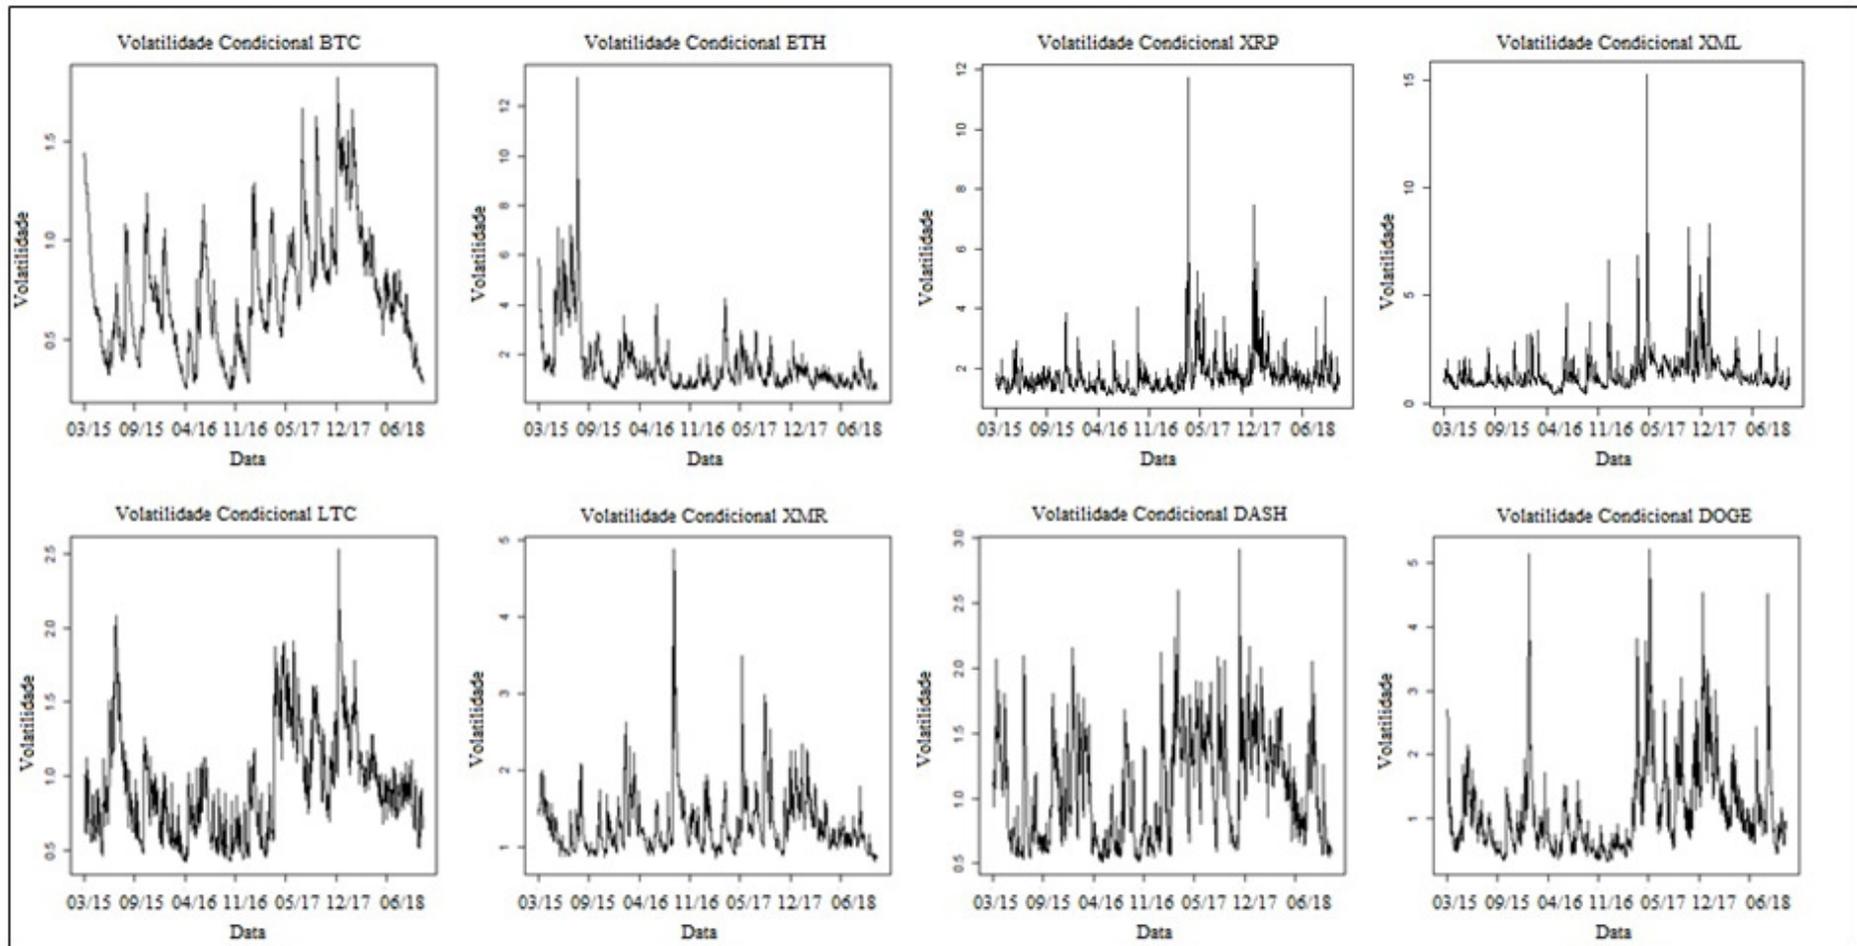


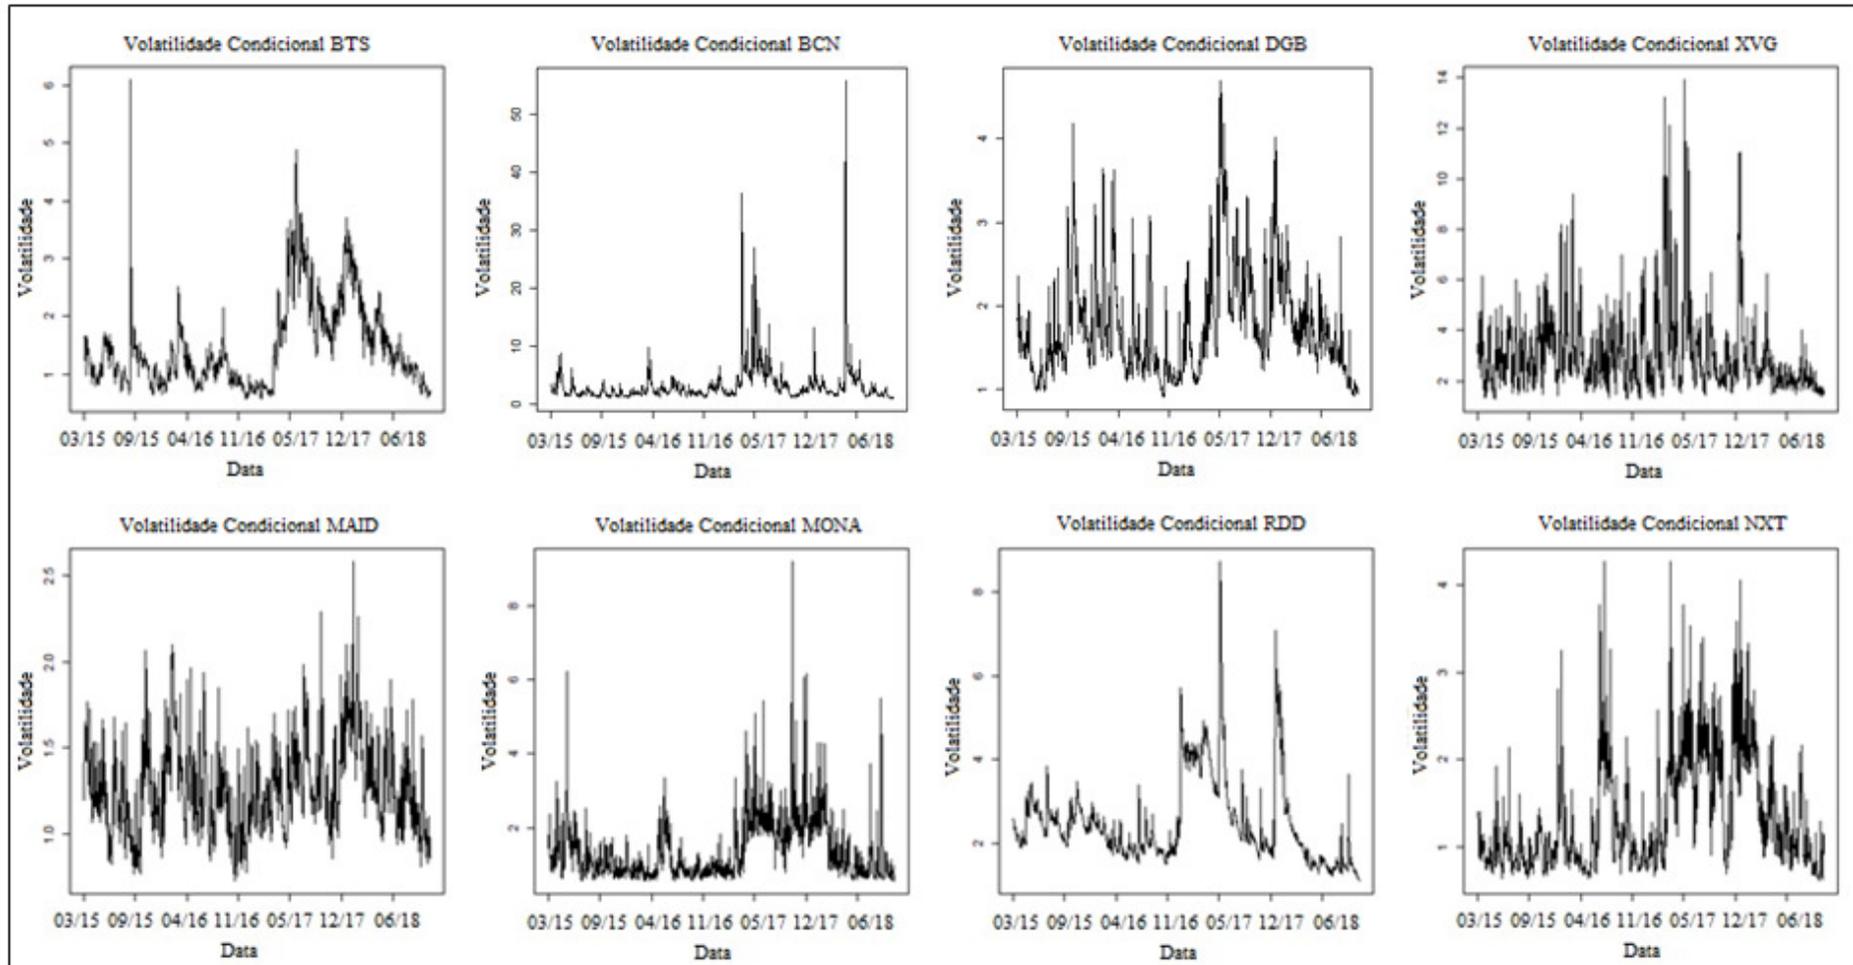


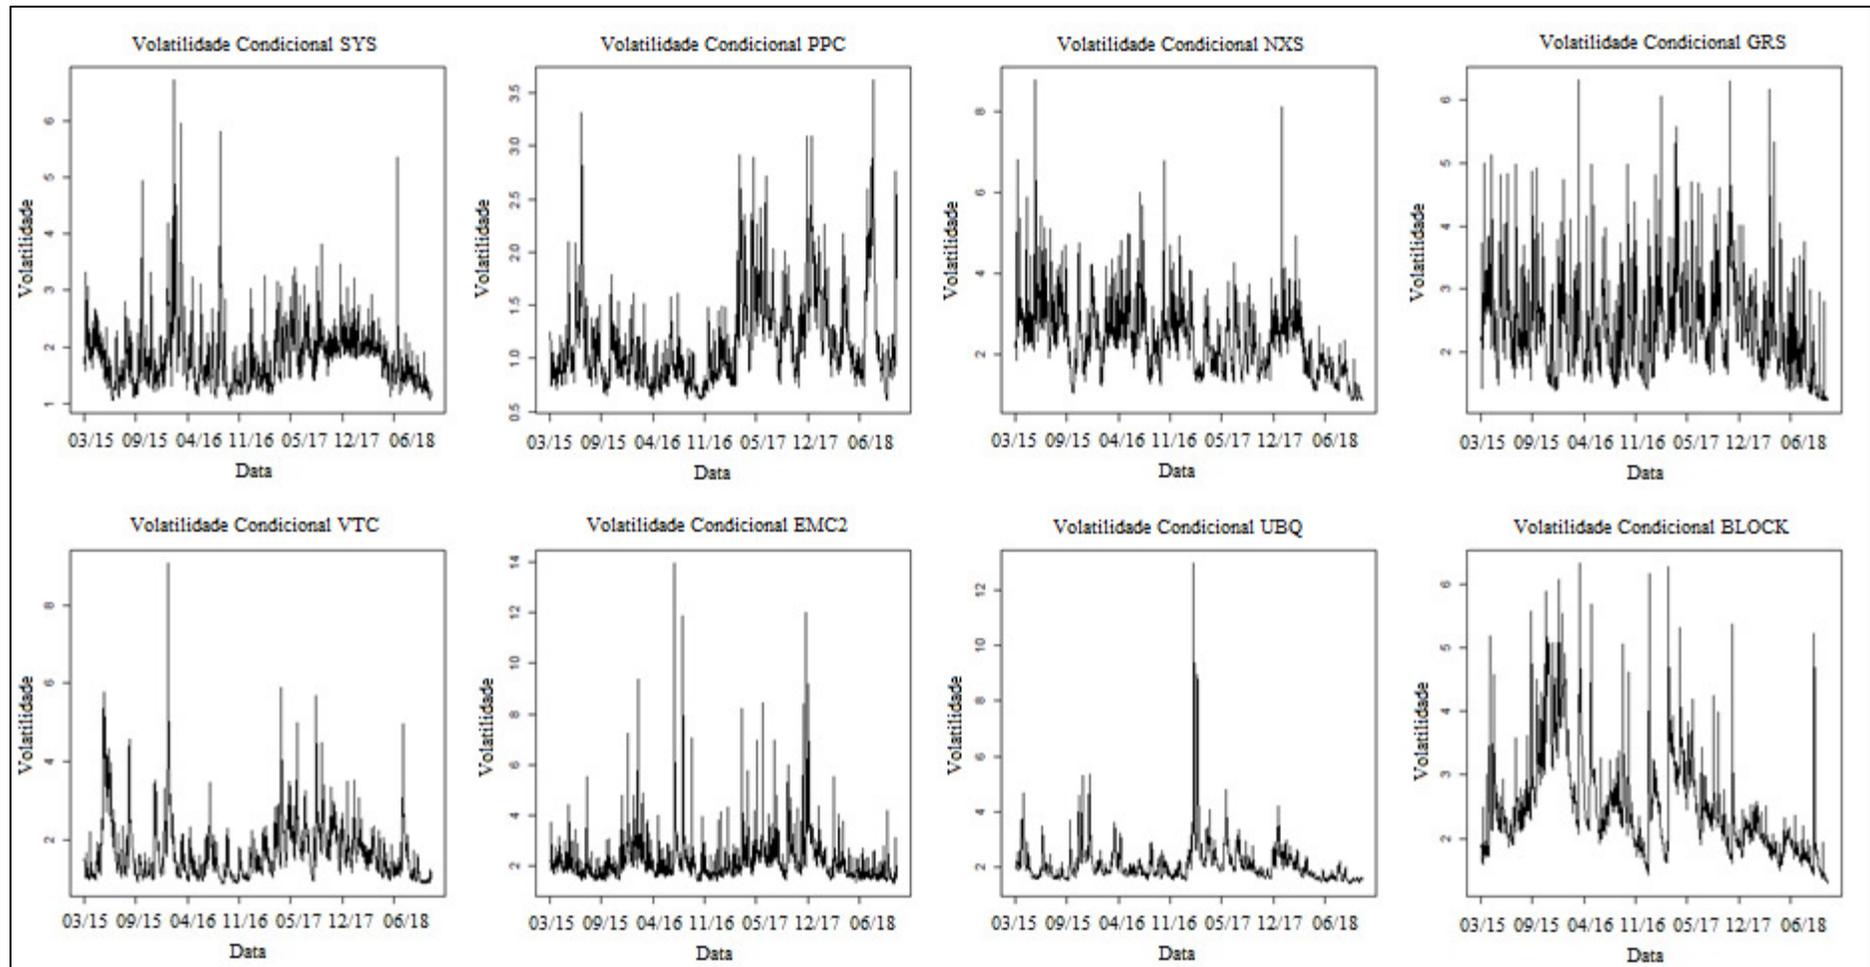


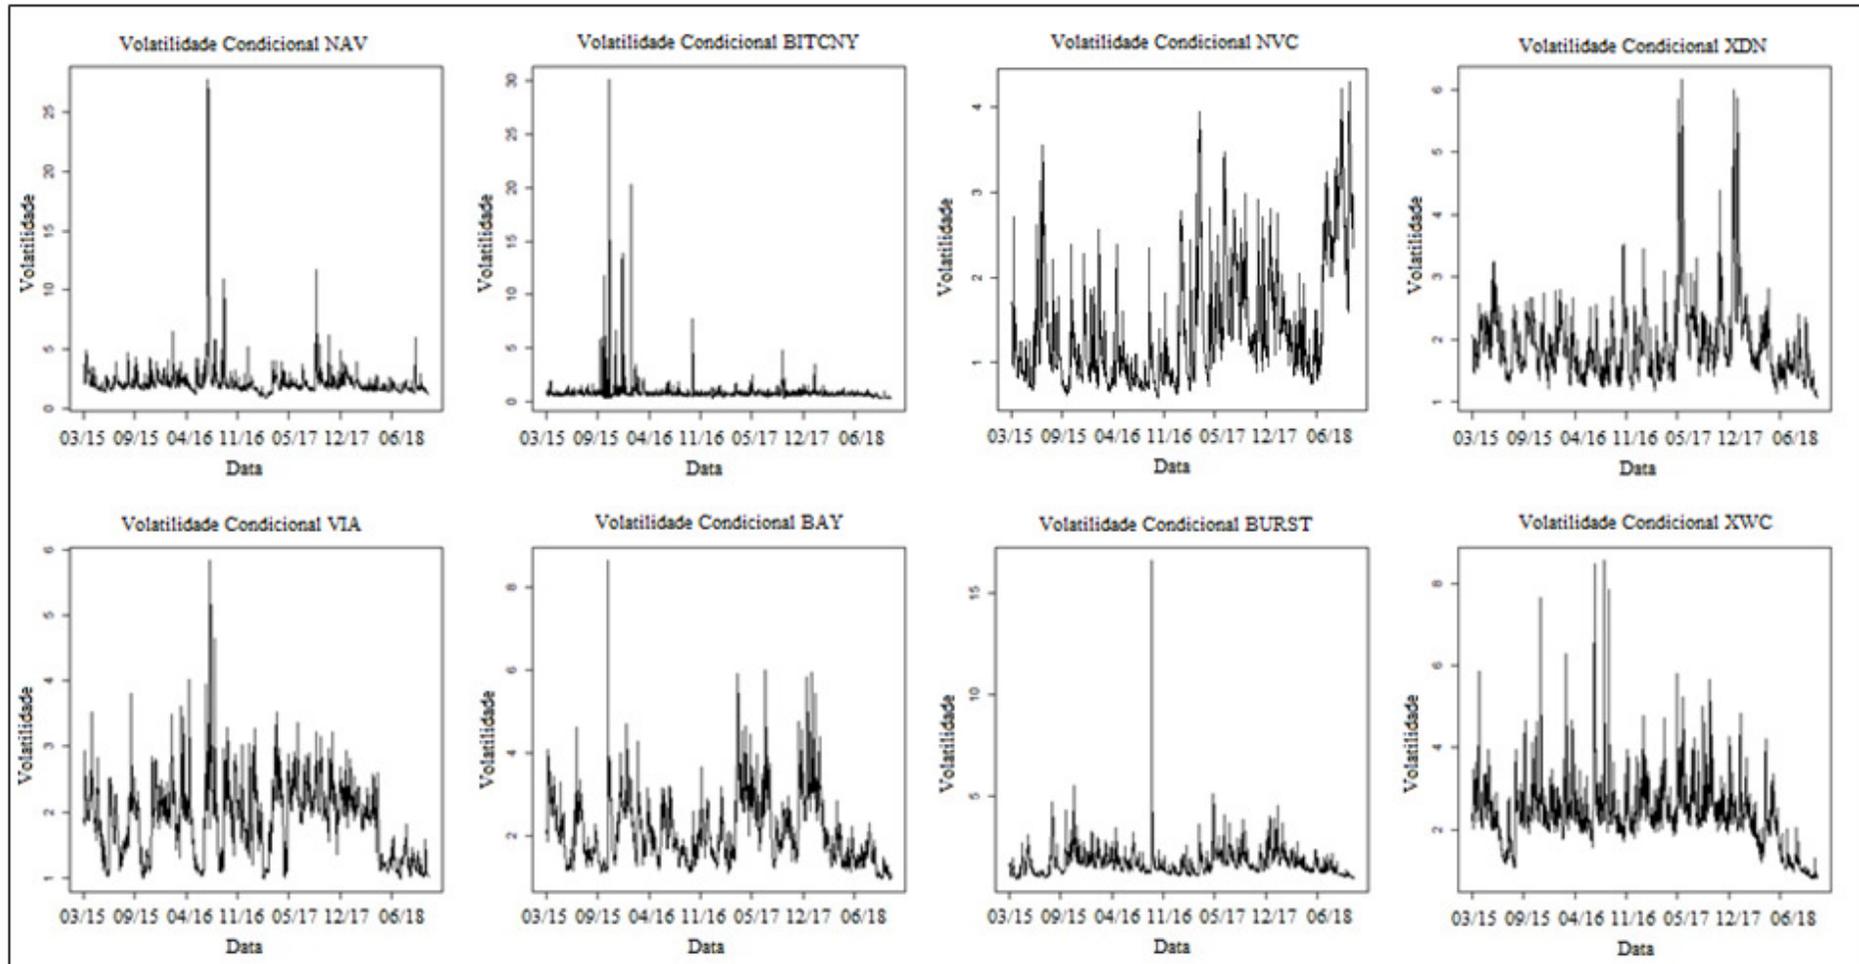


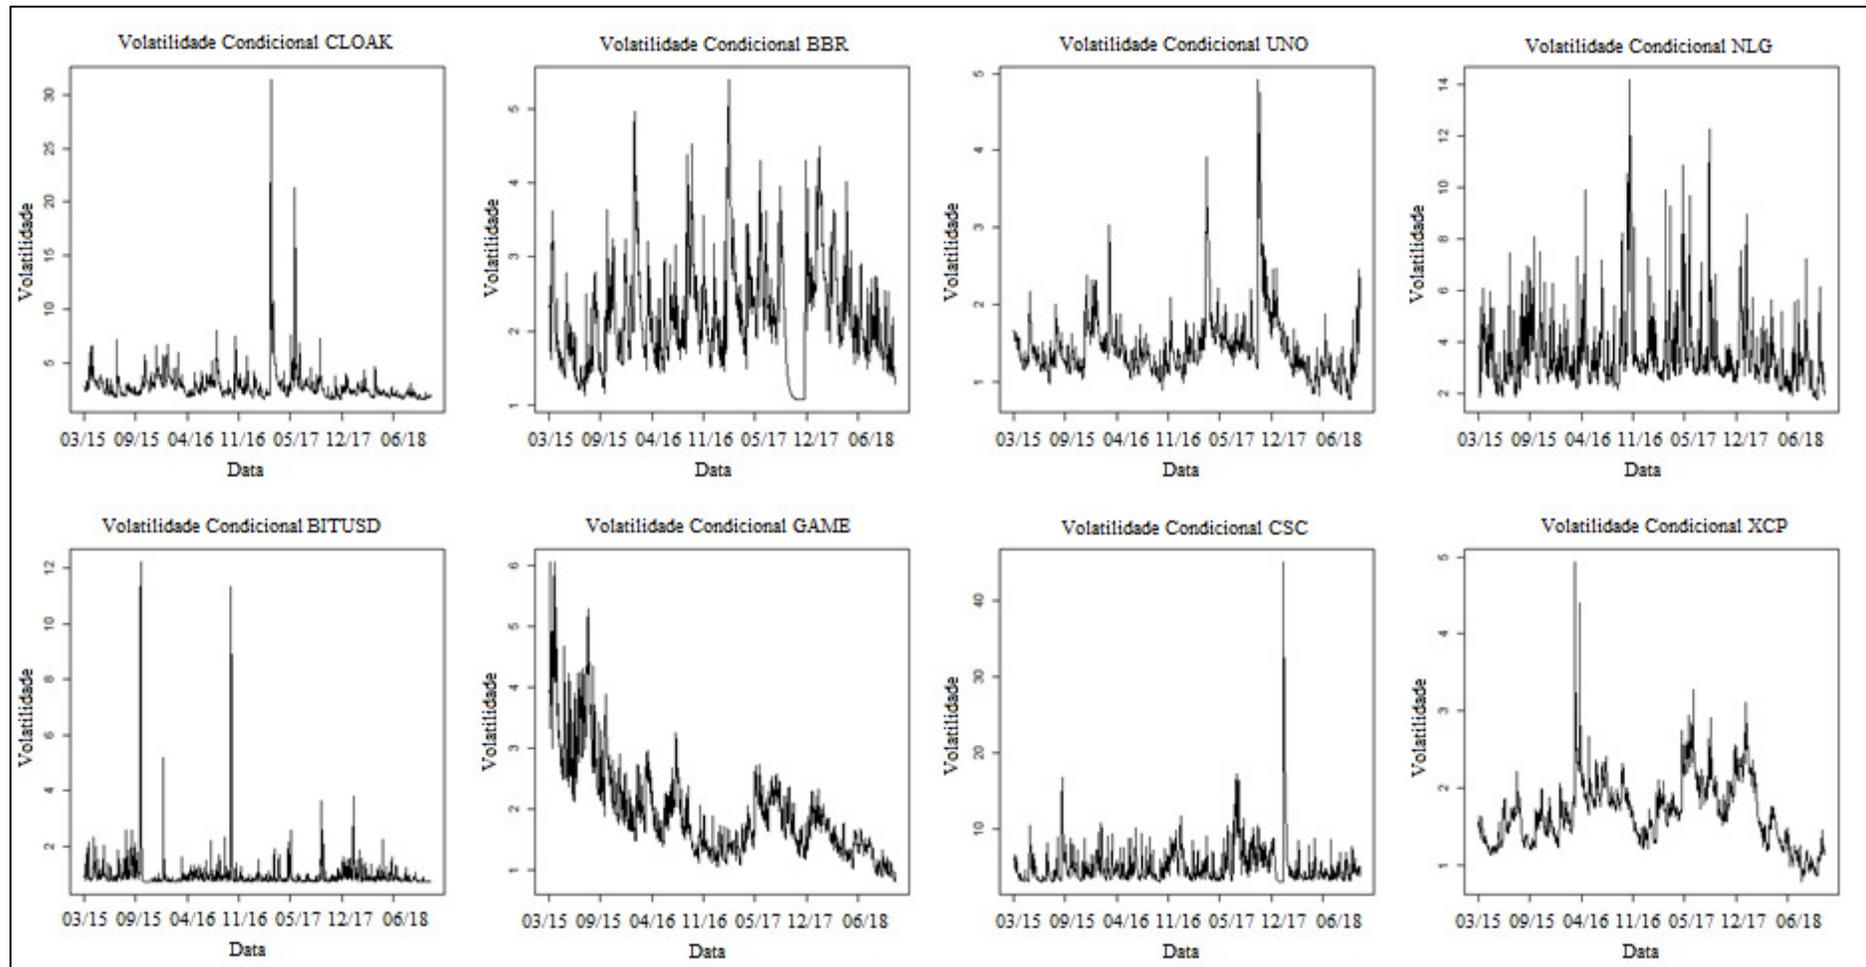
7.1.2. Gráficos de volatilidade condicional para dois estados

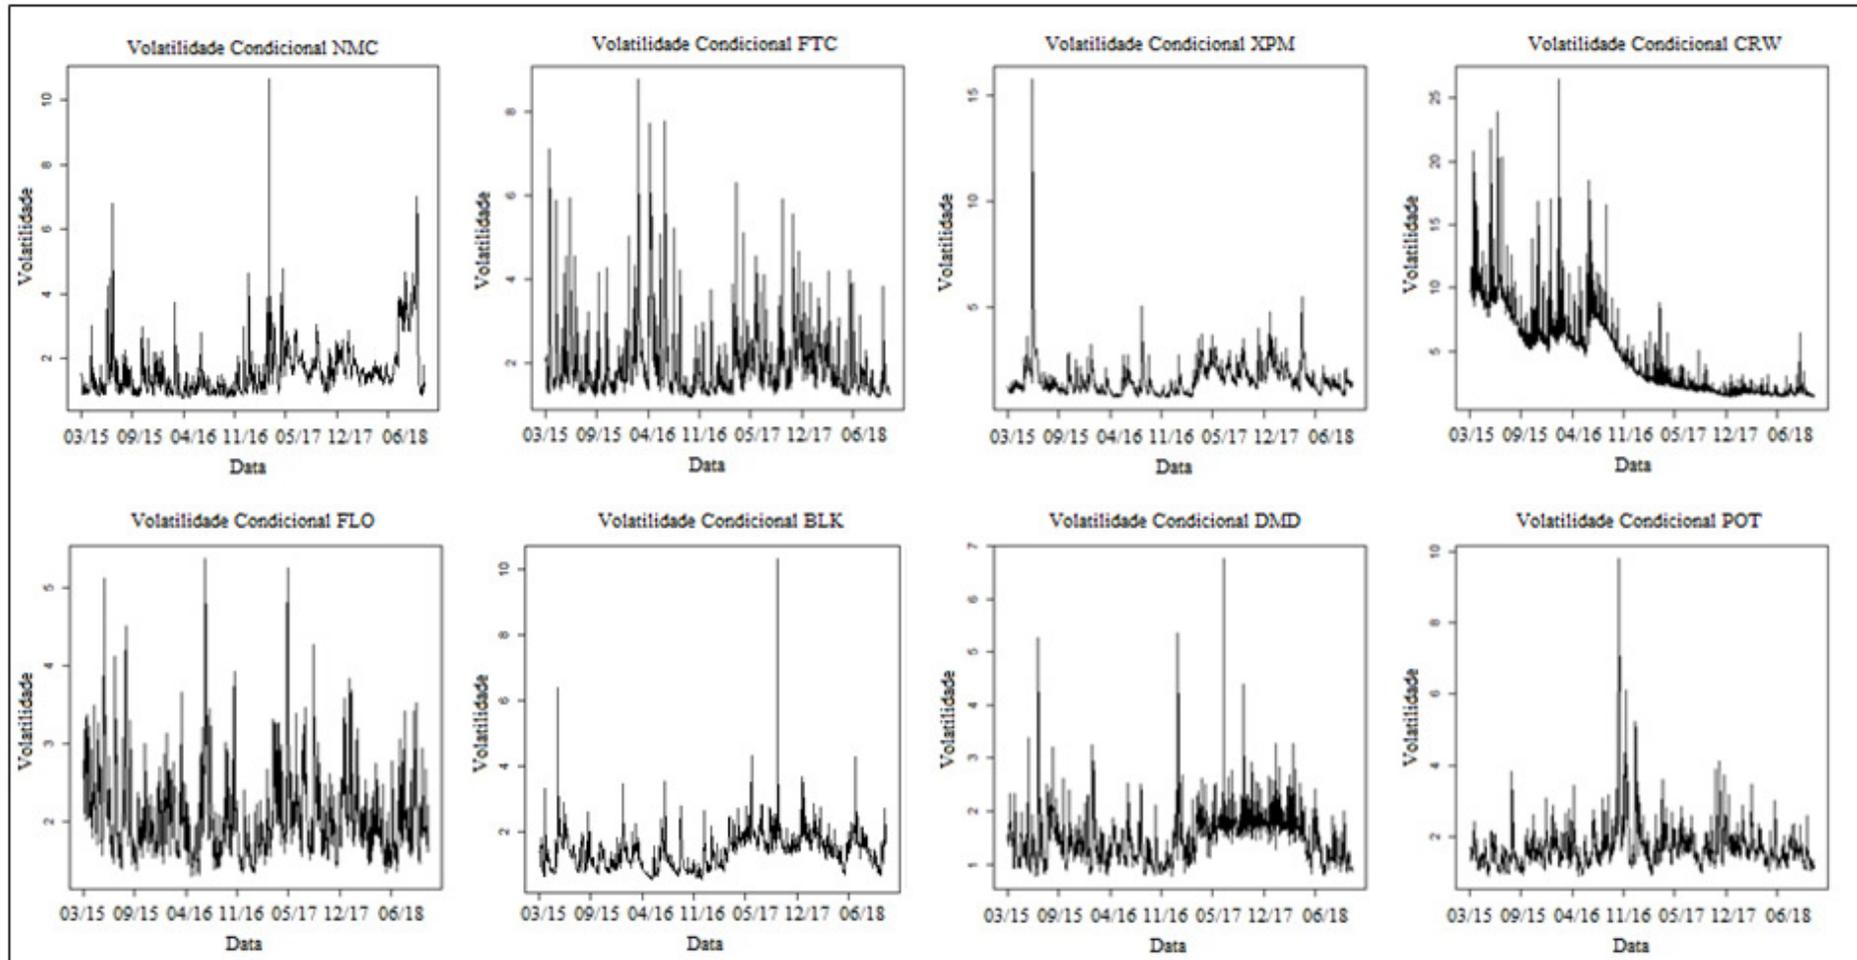




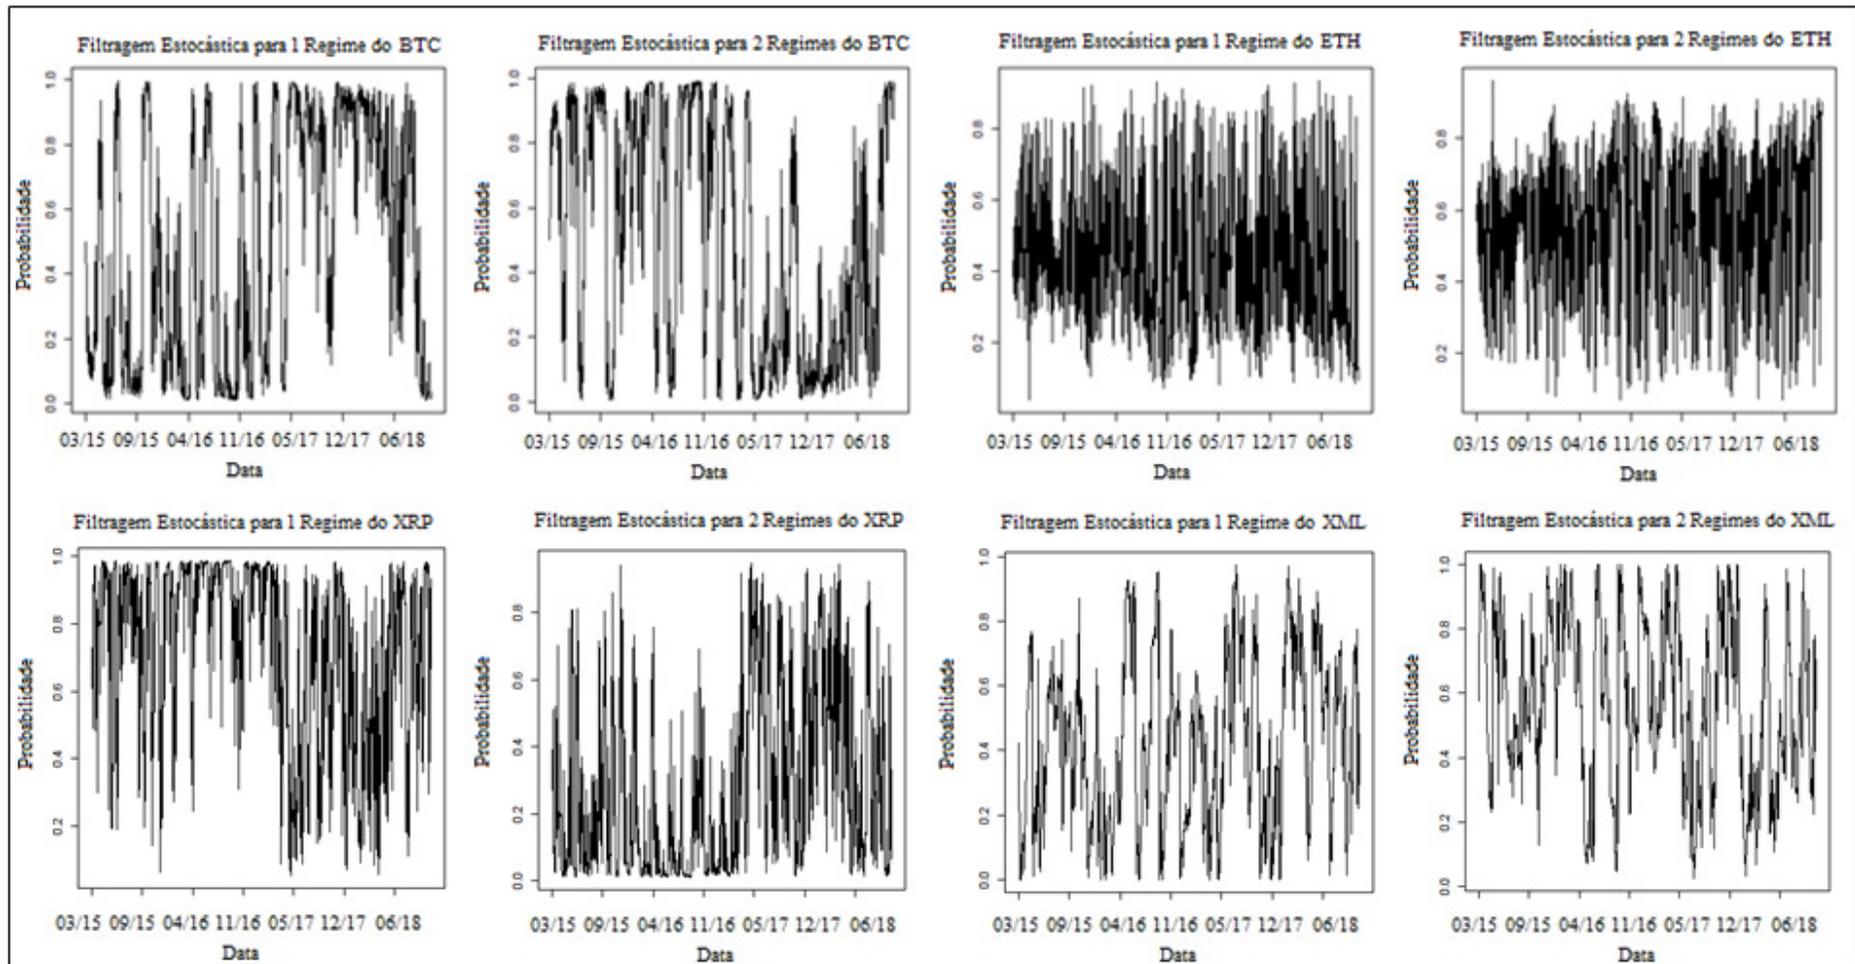


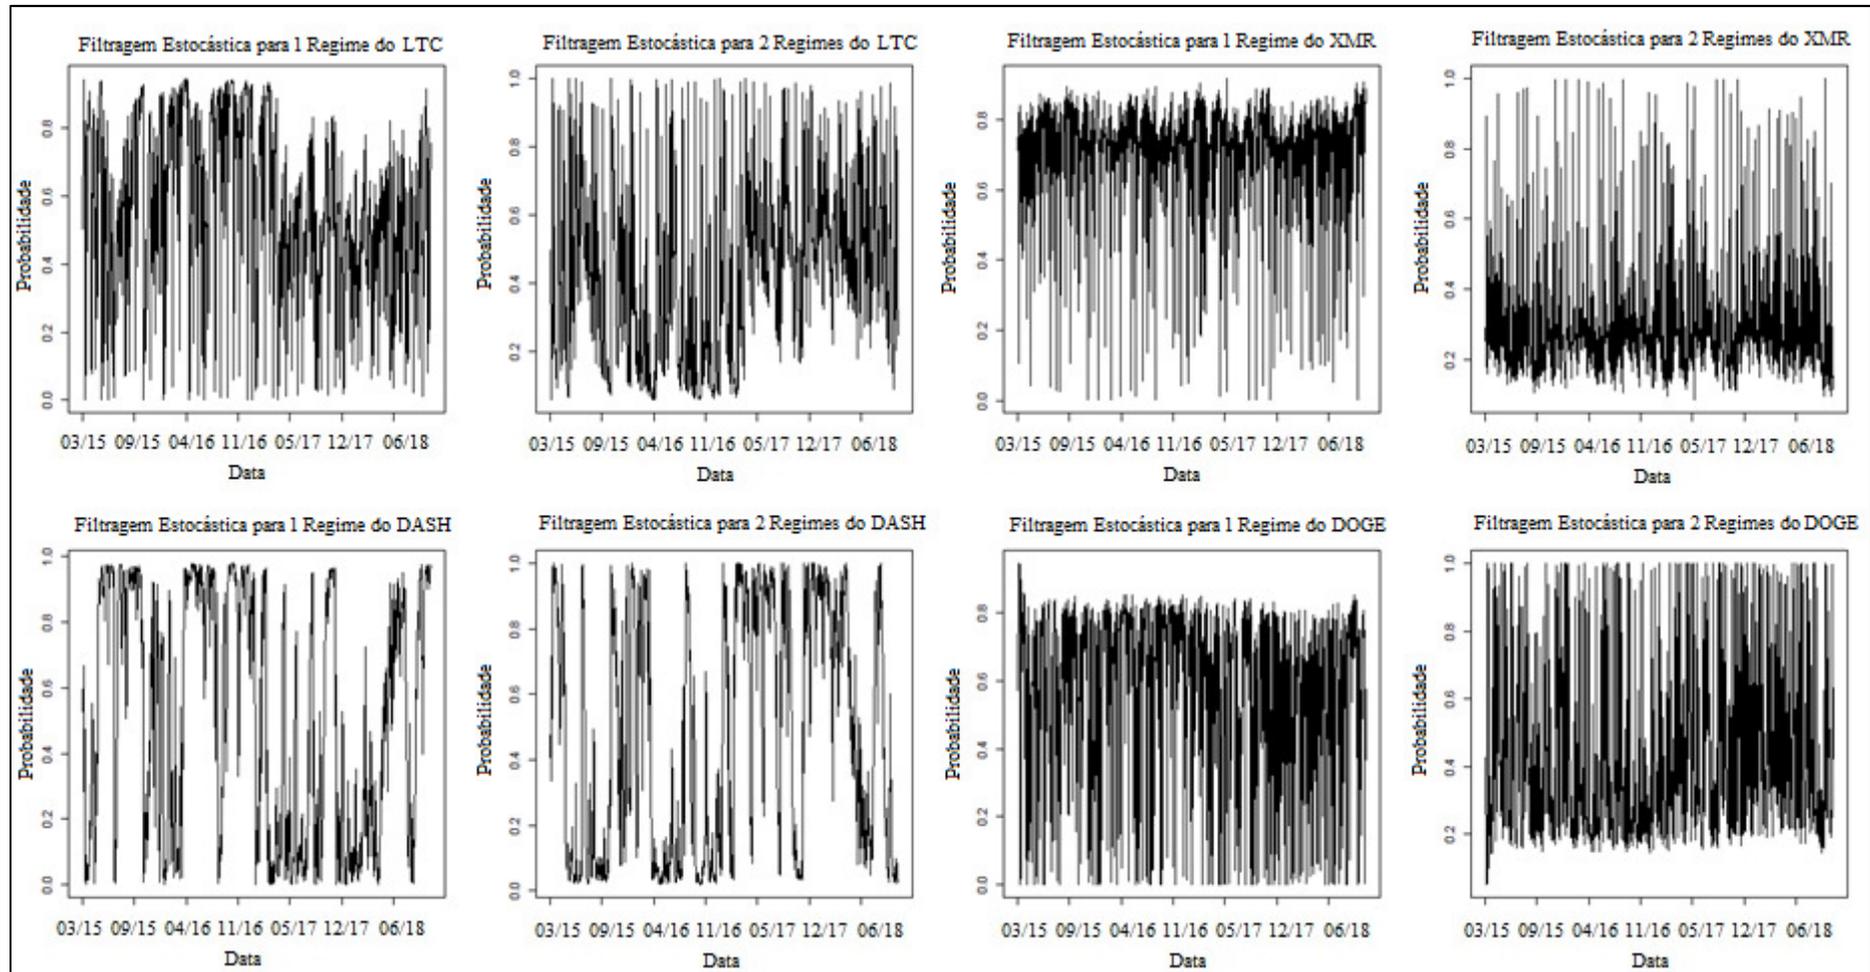


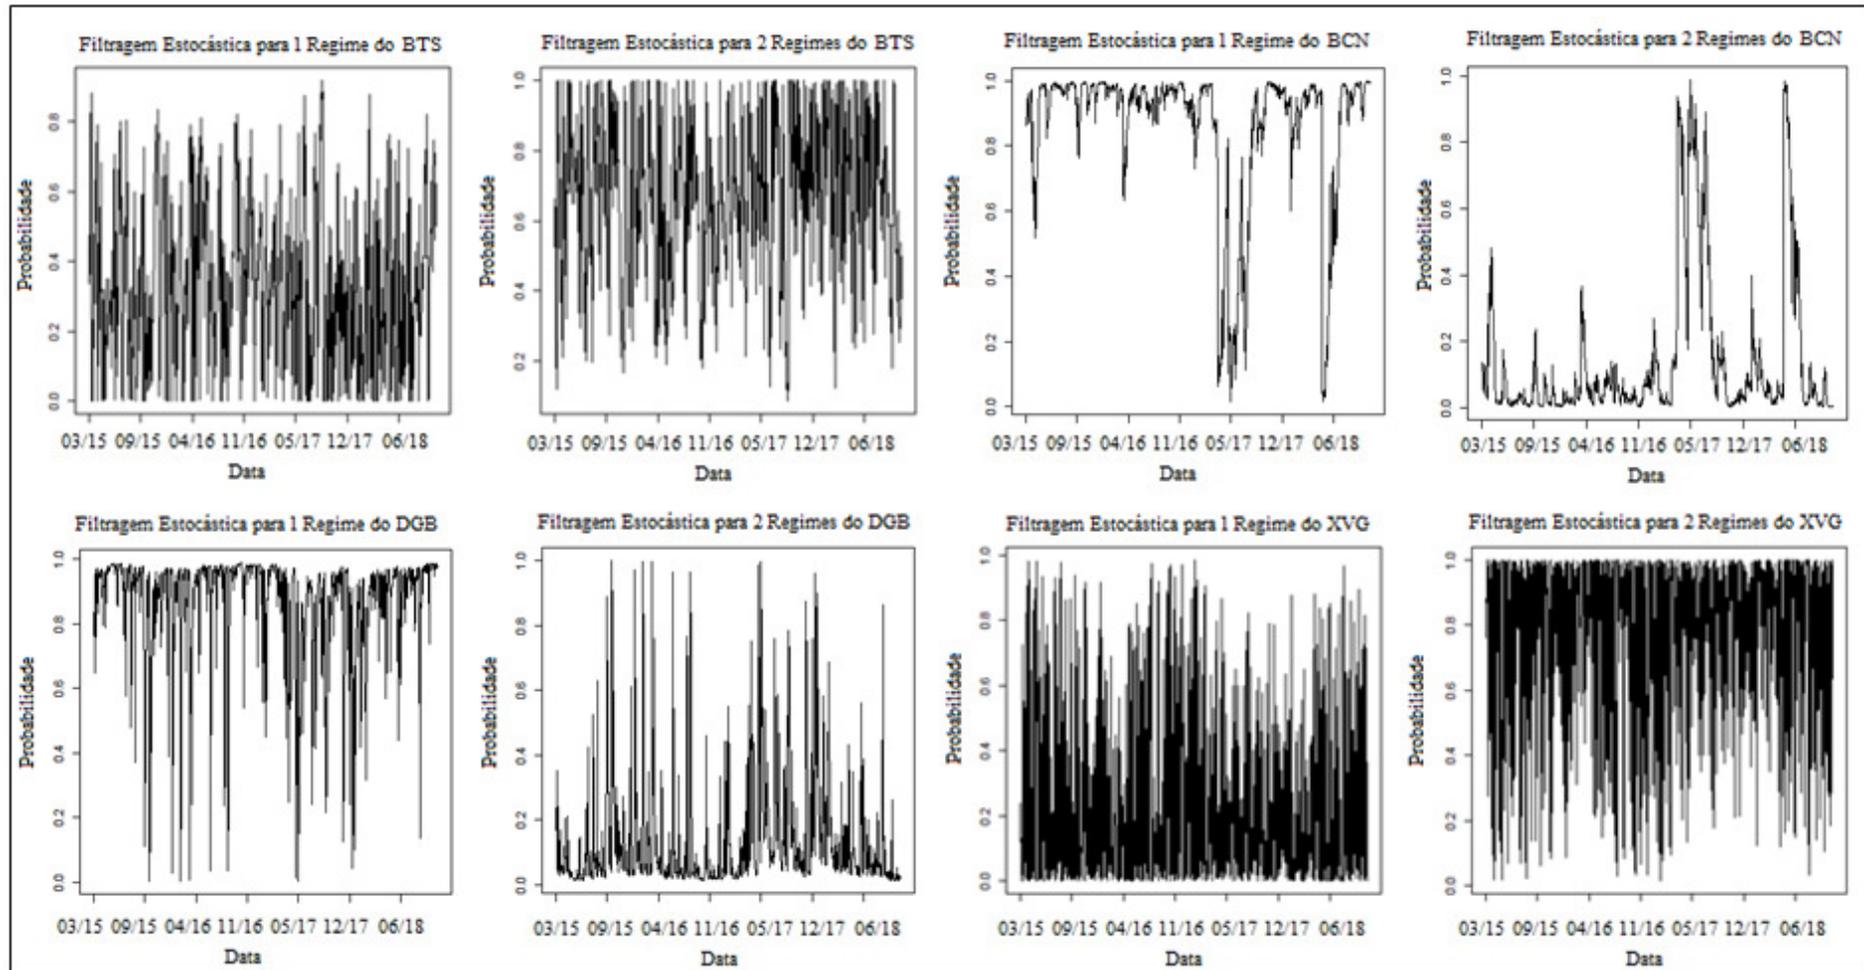


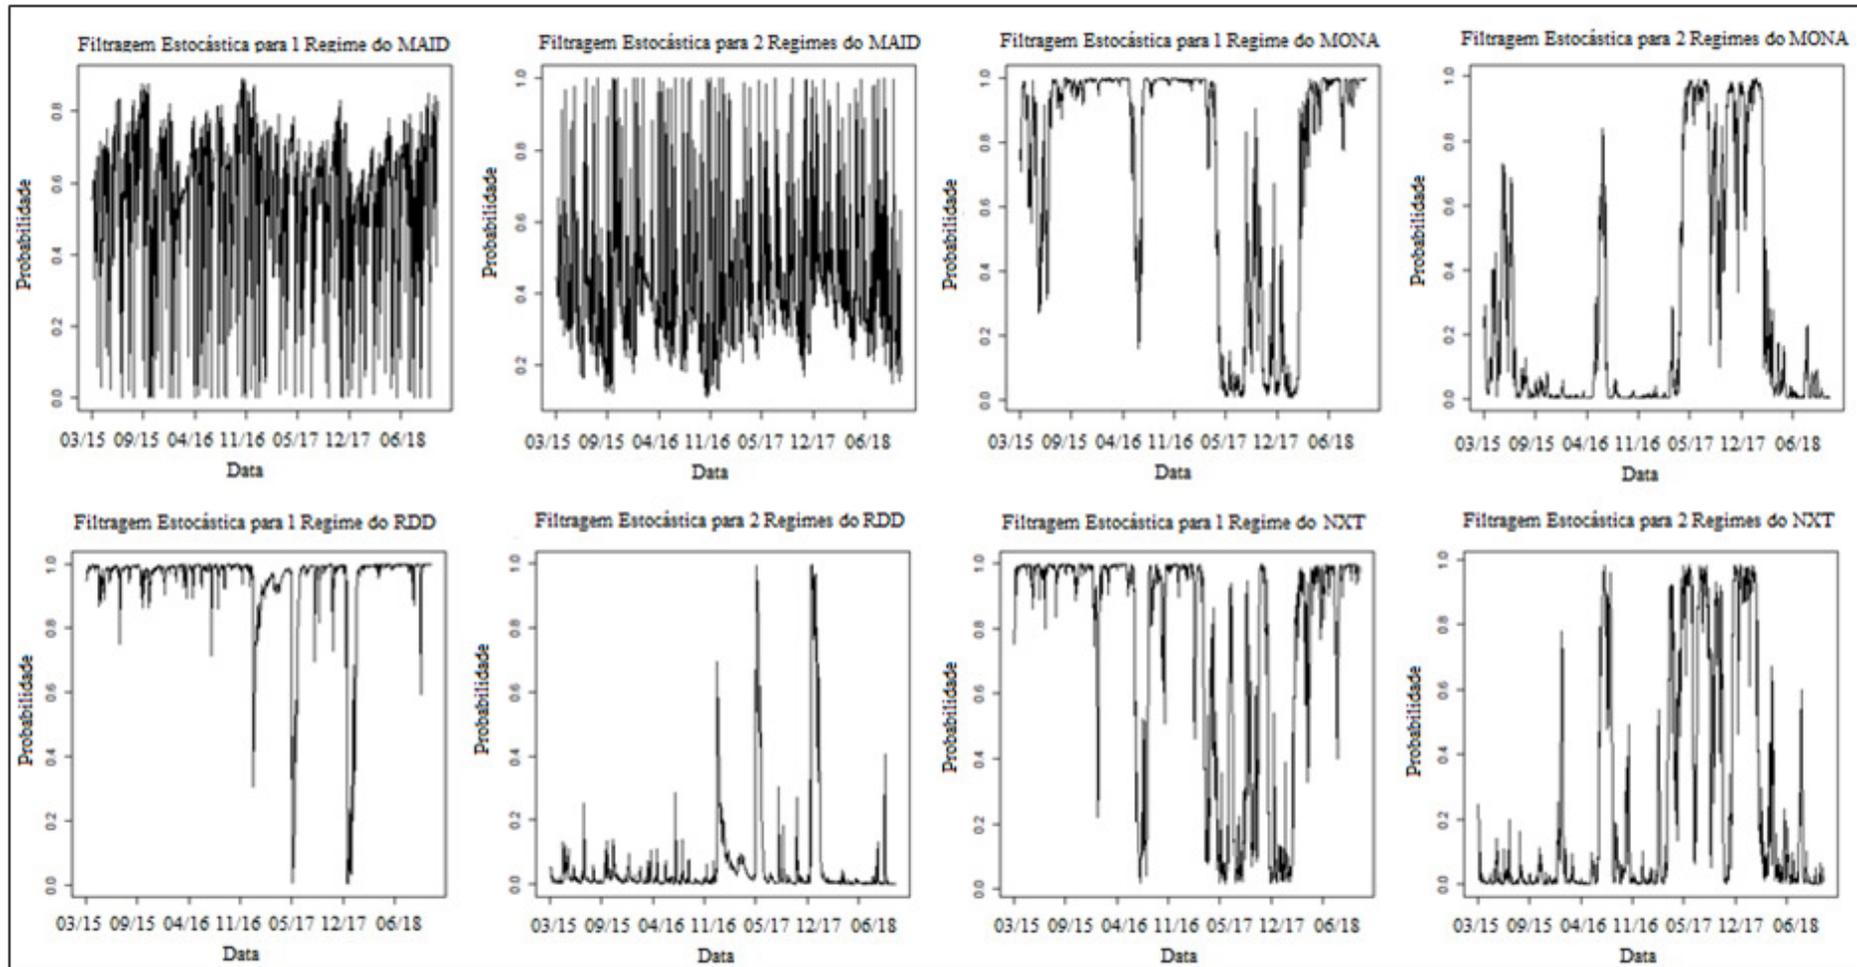


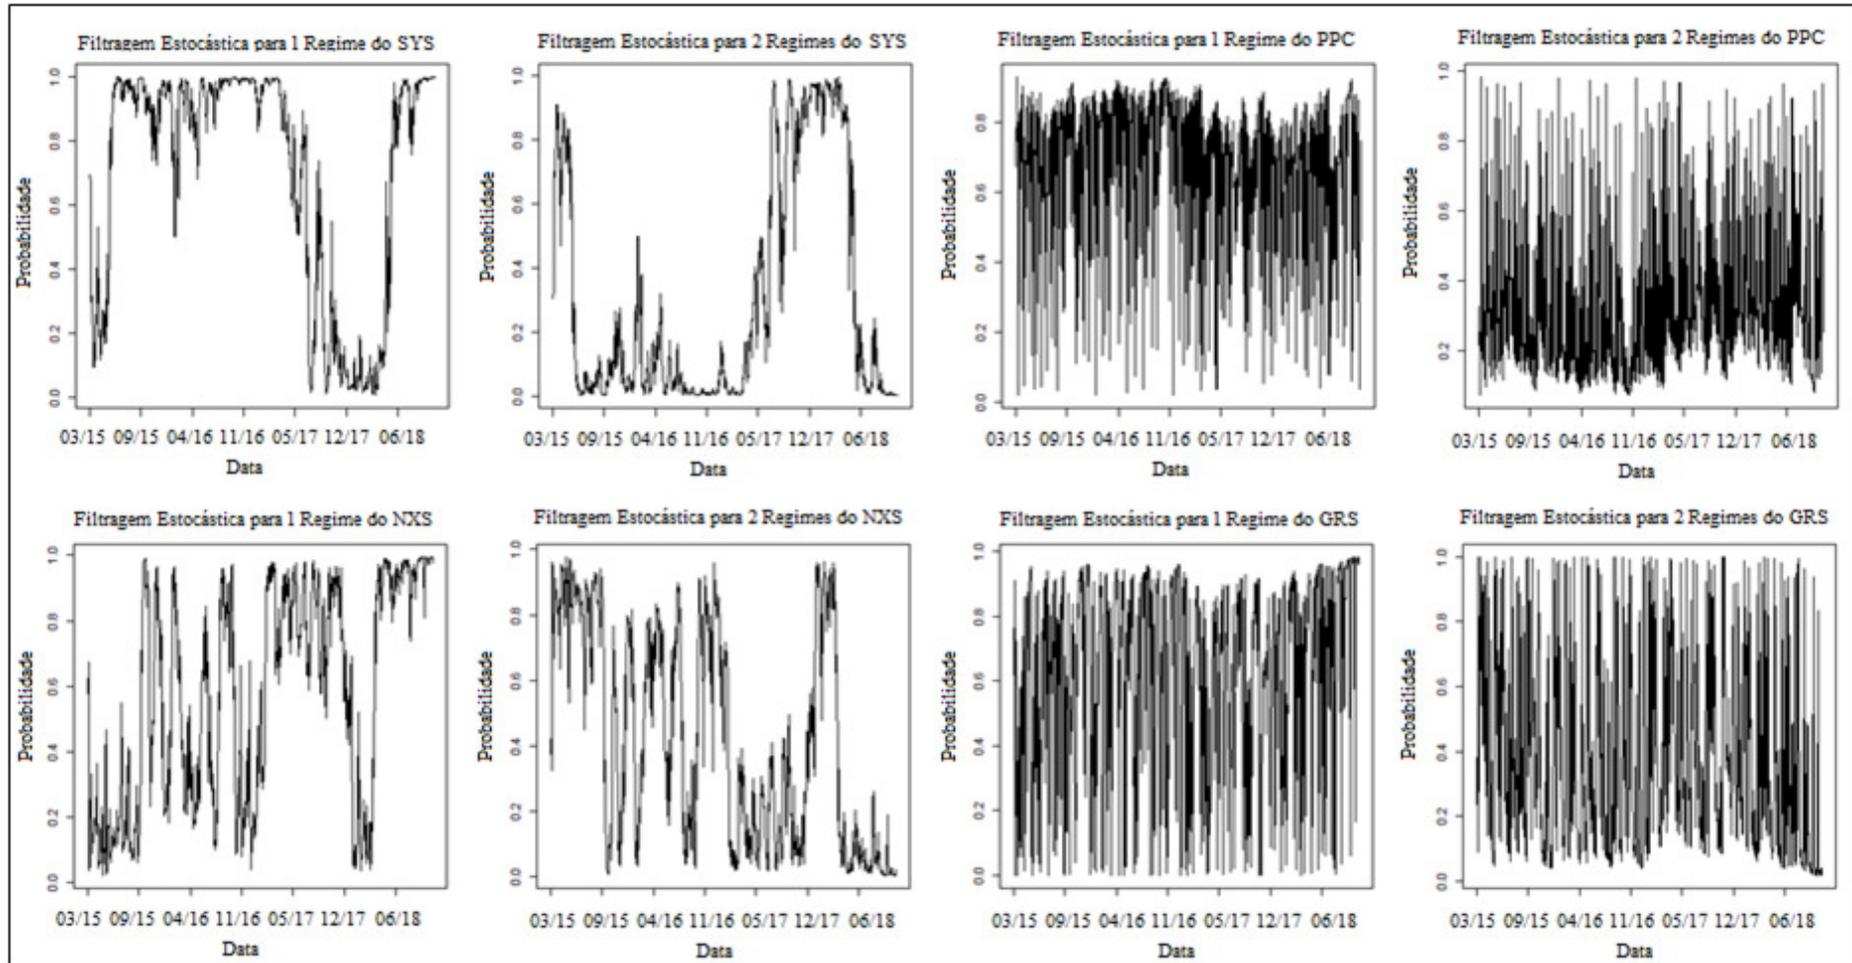
7.1.3. Gráficos probabilidades filtradas para um e dois regimes

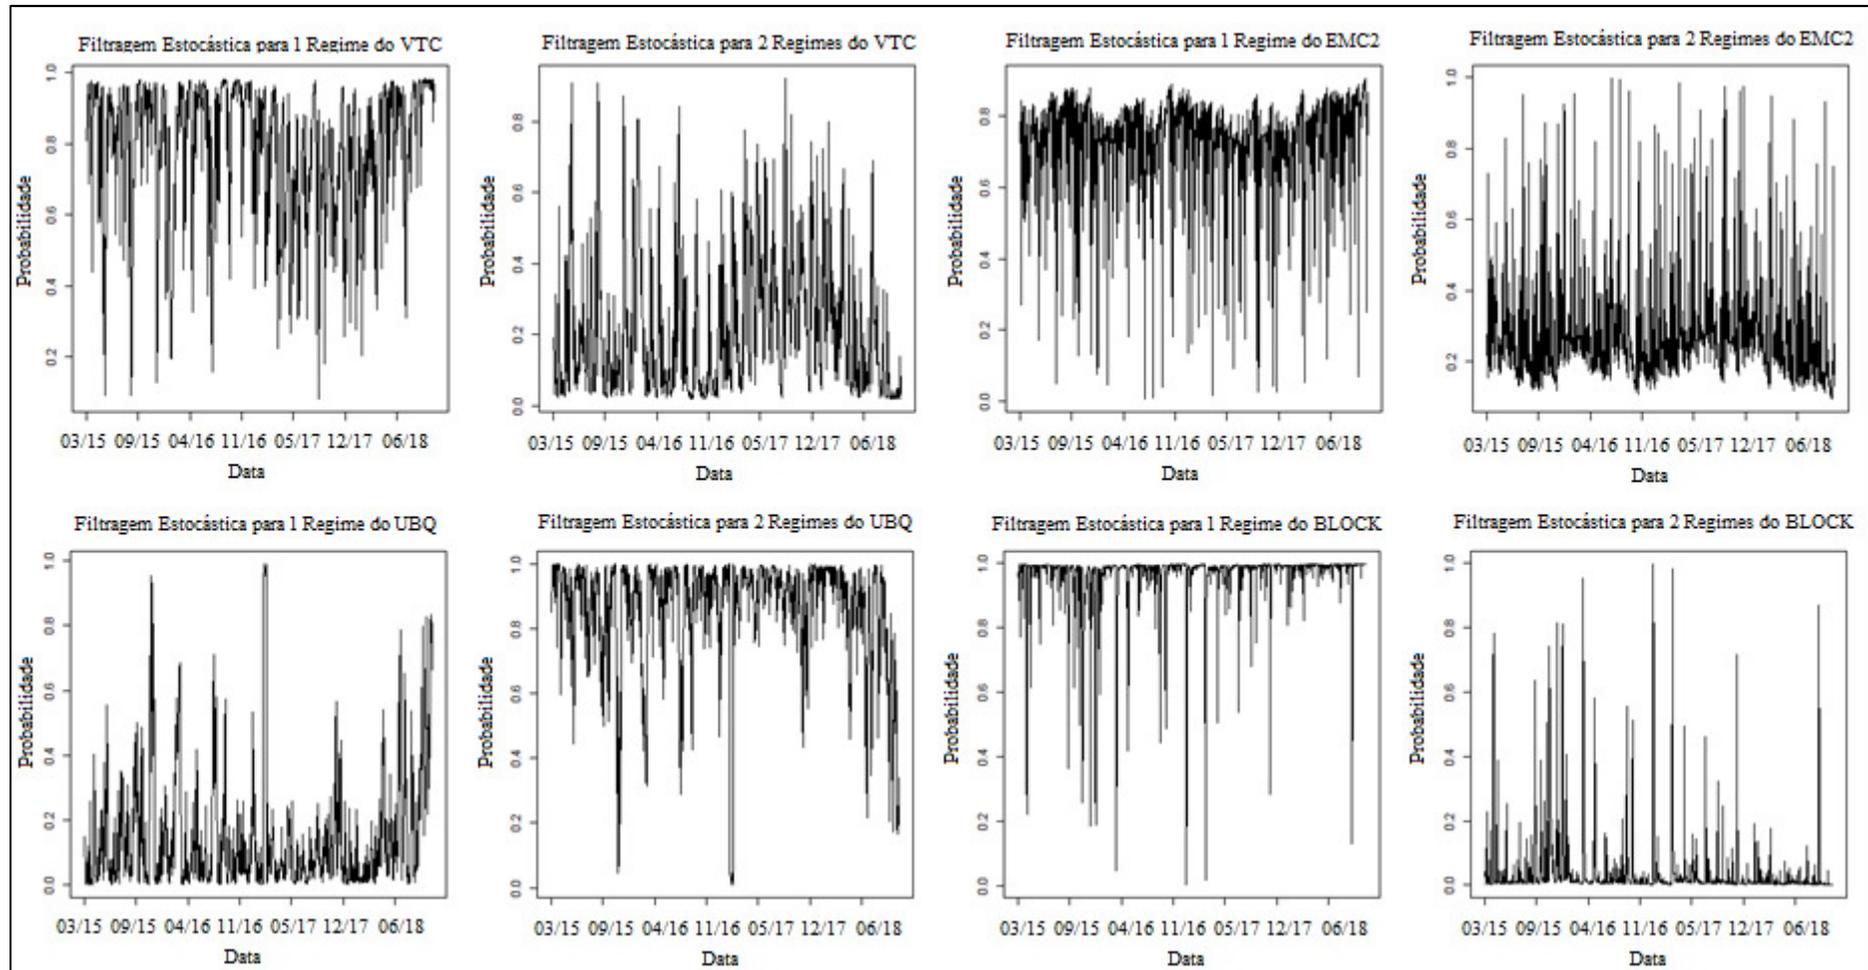


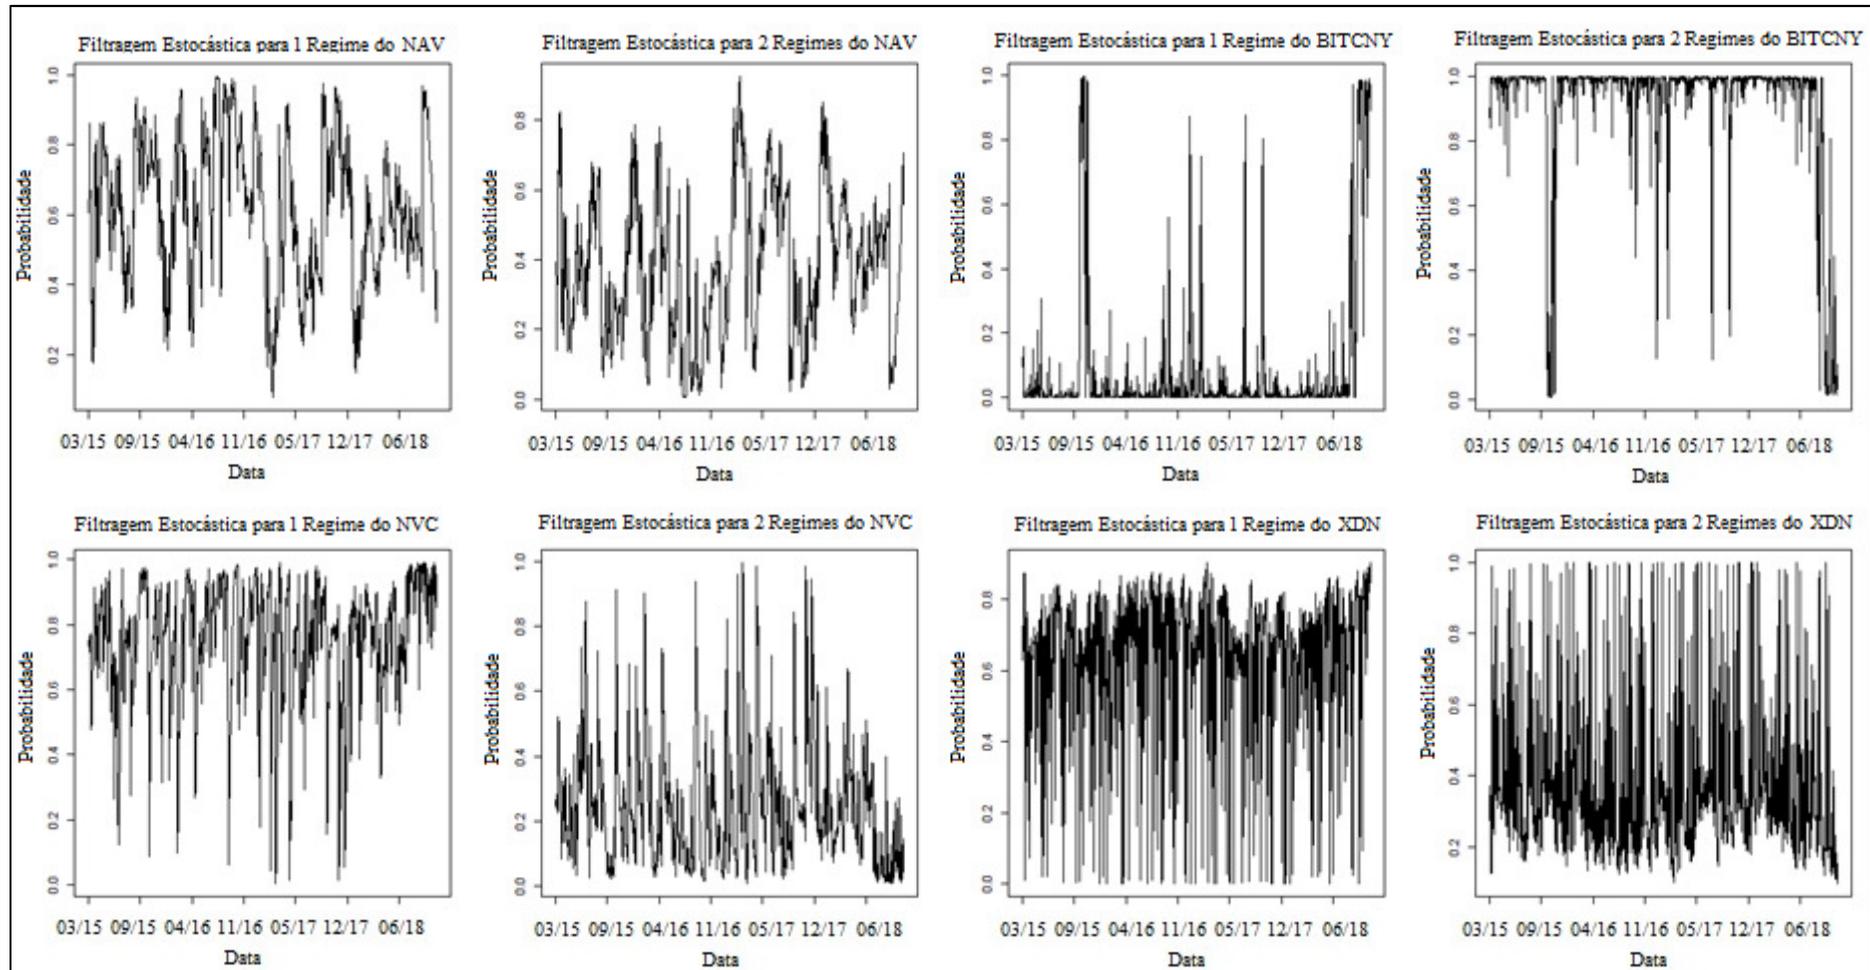


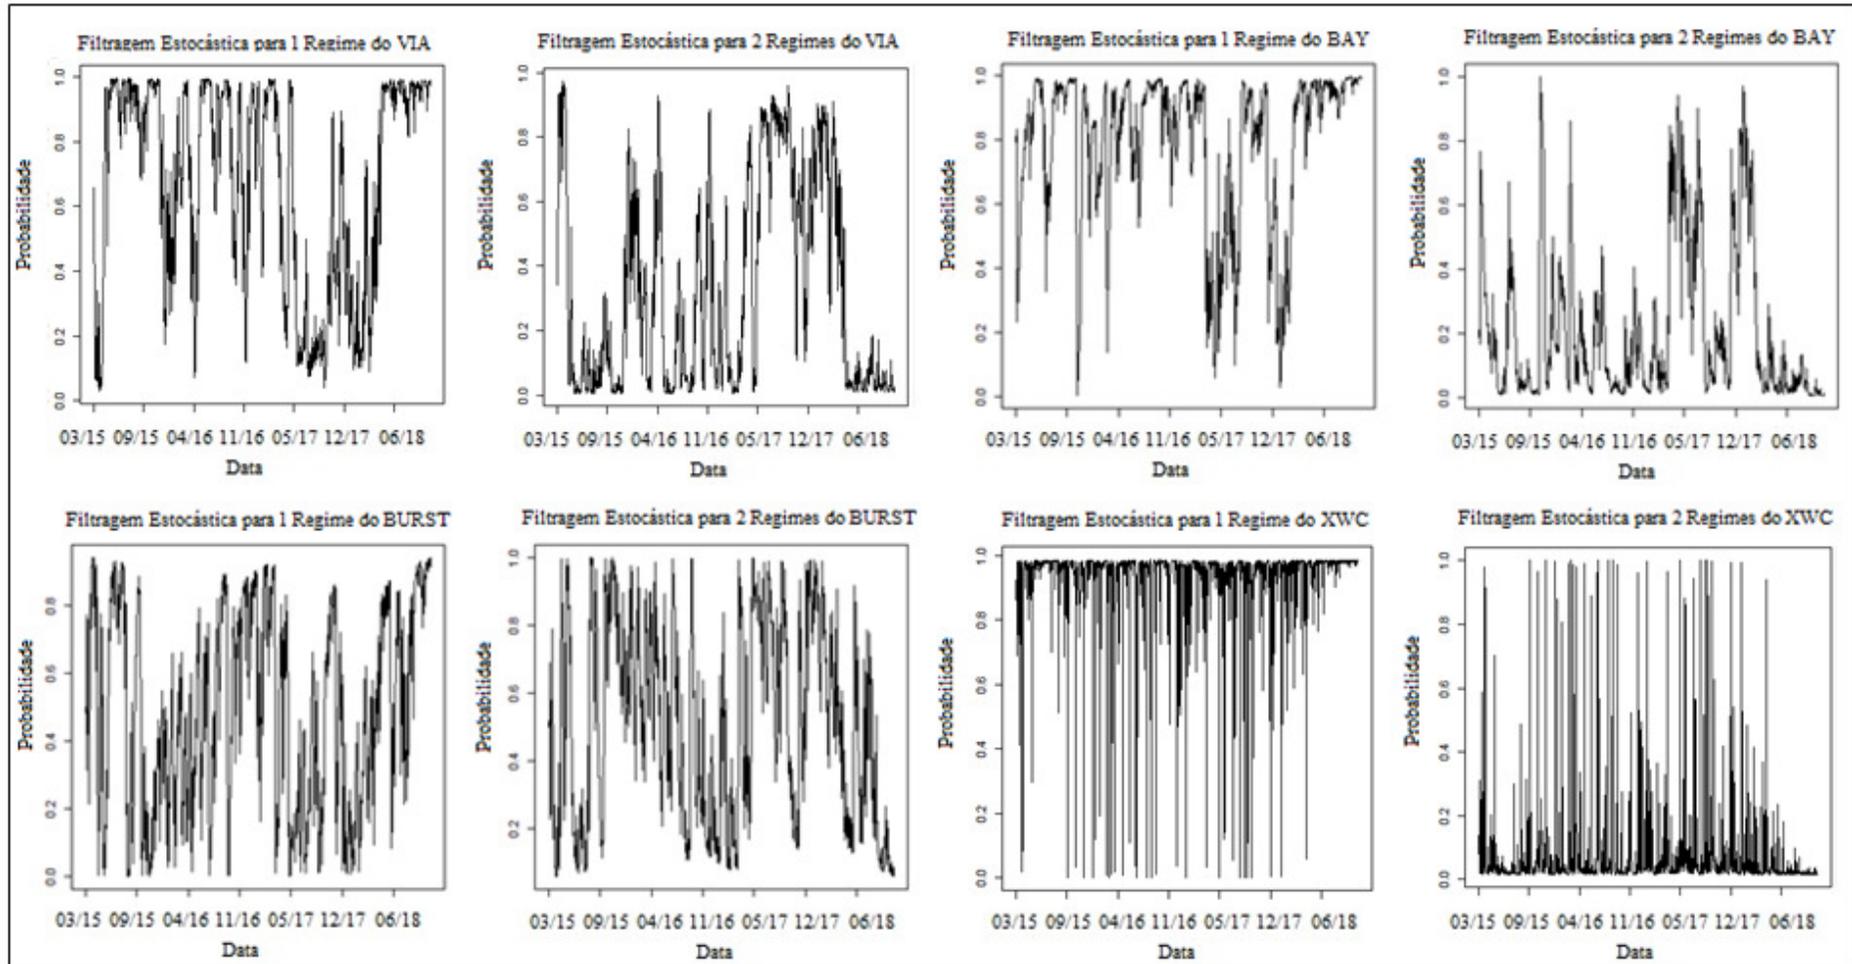


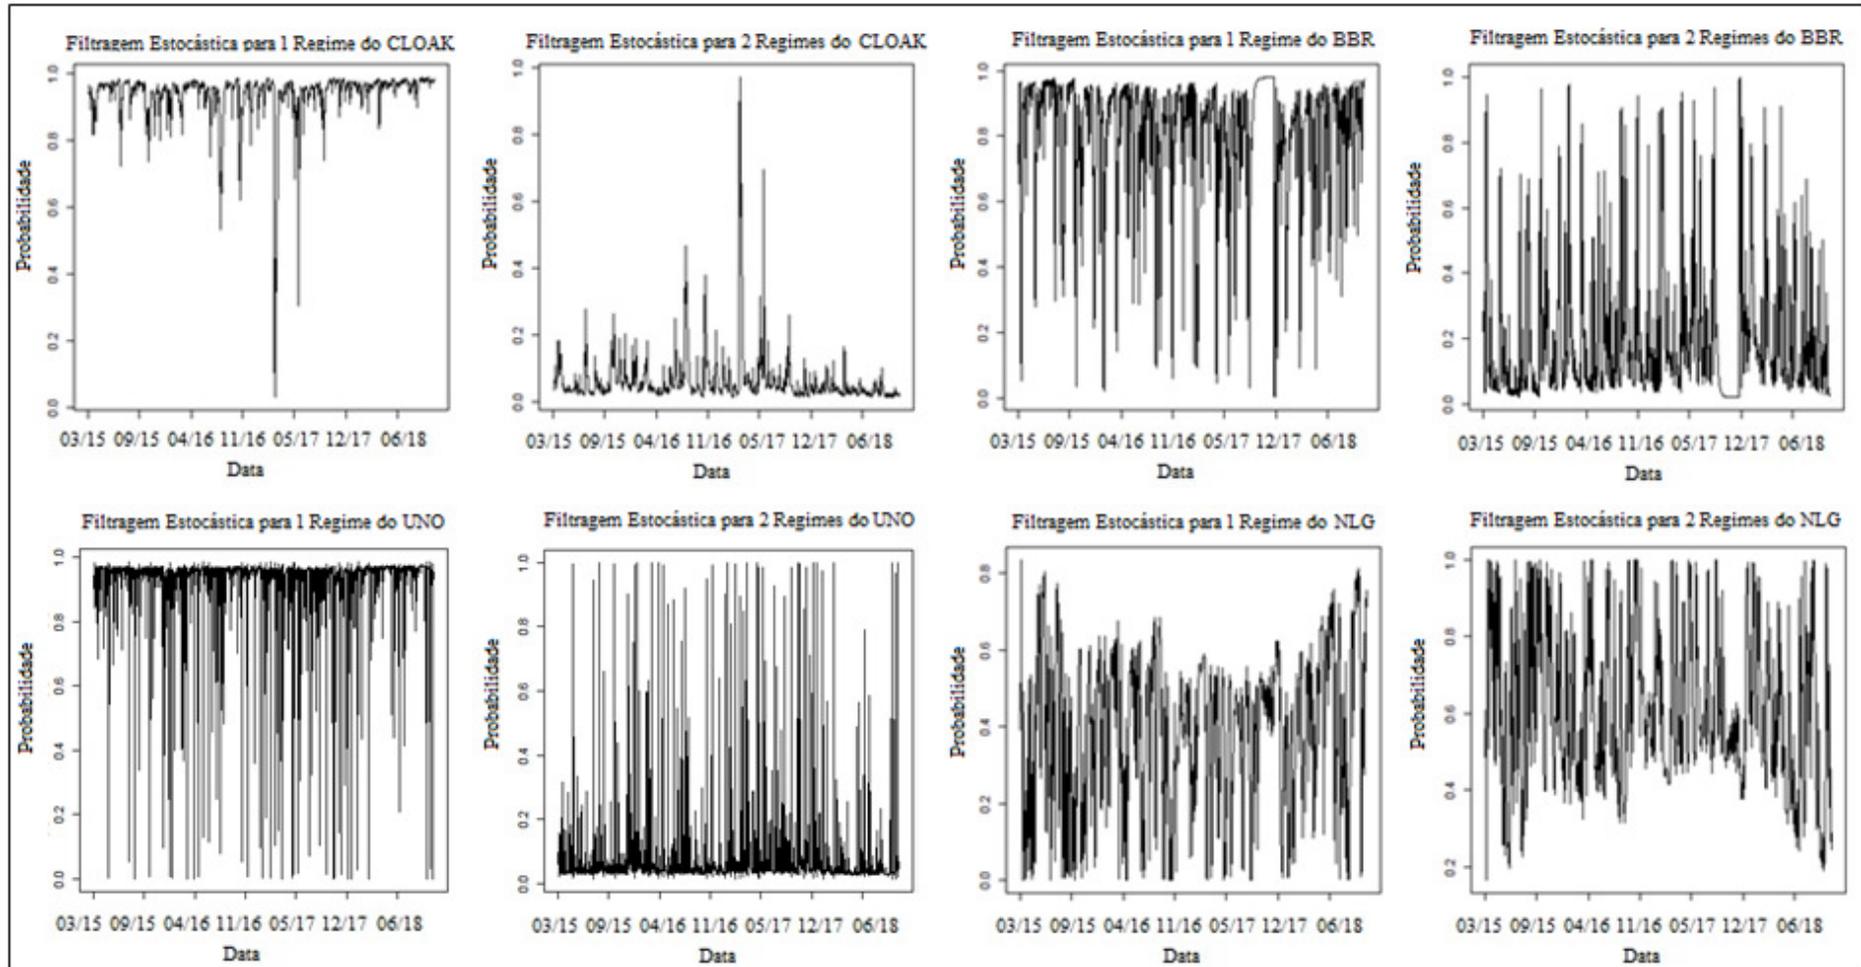


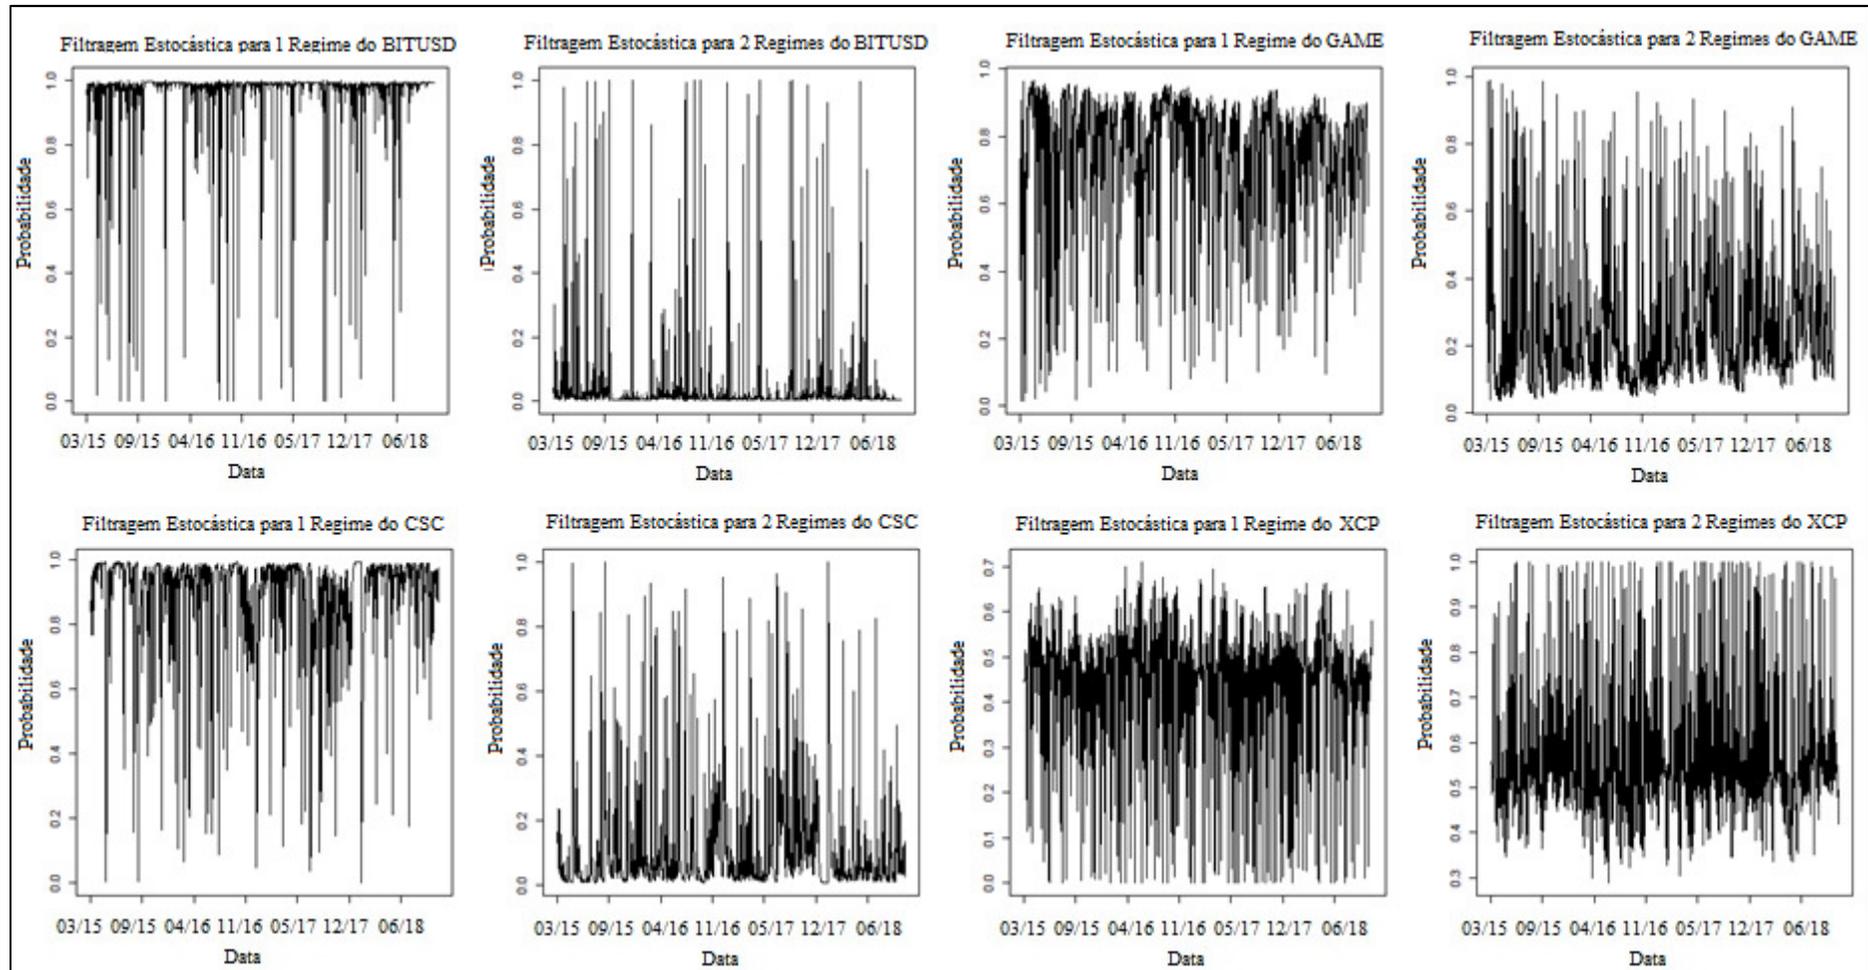


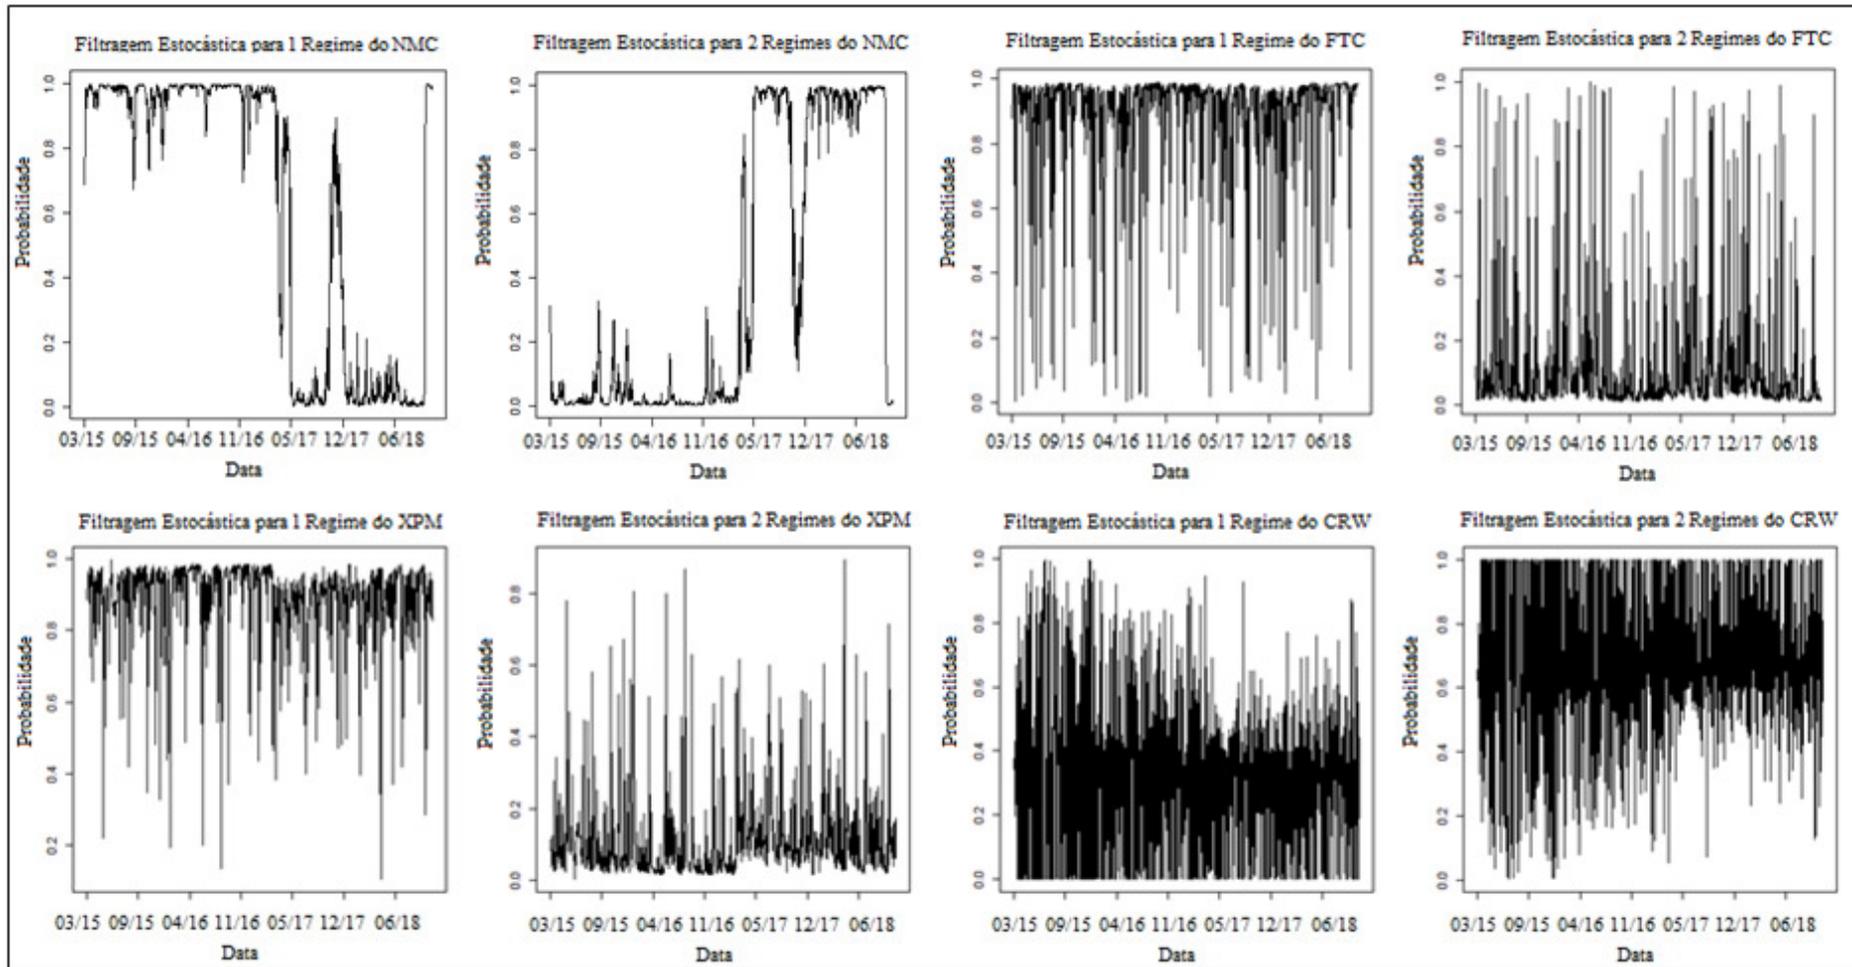


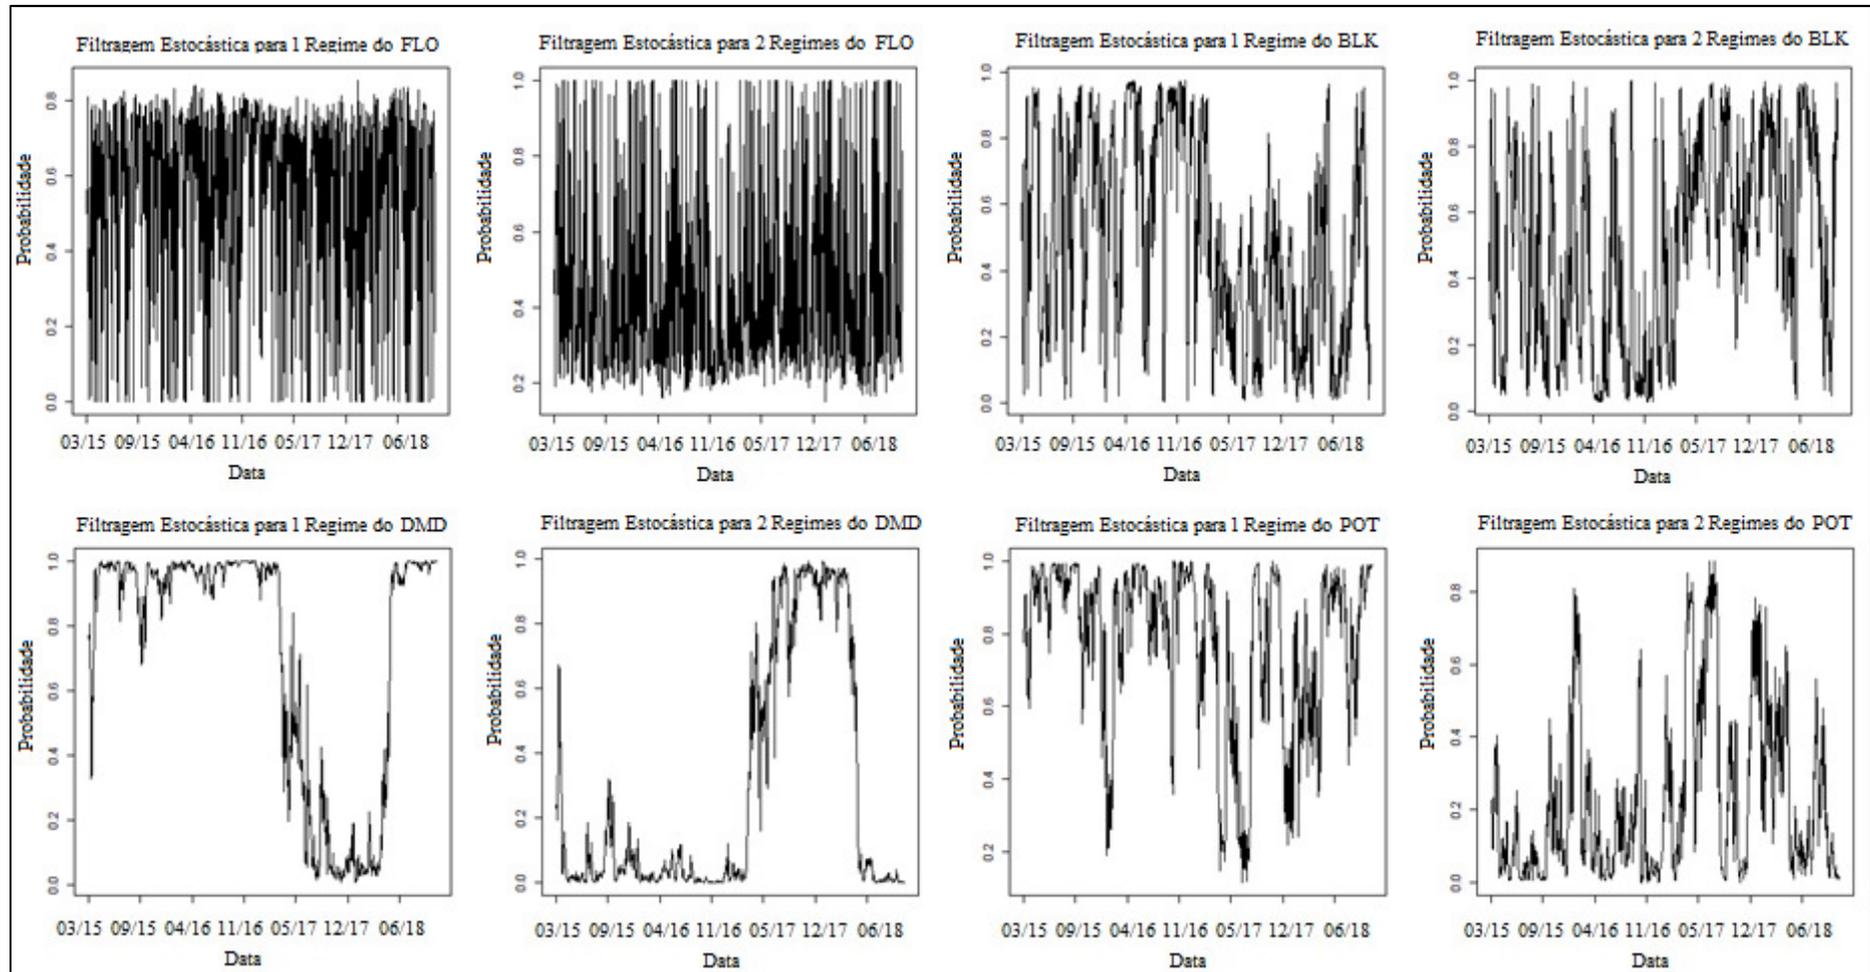












7.2. Anexo 2: Segundo Ensaio.

7.2.1. Testes de cocurtose e covolatilidade

A2.1: Teste de Cocurtose para 2015 – 2018.

Moeda	ETH	XRP	XLM	LTC	XMR	Tether	DASH	DOGE
Teste de Cocurtose	70445***	147759***	27251***	11839***	5876***	18132***	3542***	6602***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	BTS	BCN	DGB	XVG	MAID	MONA	RDD	Nxt
Teste de Cocurtose	5428***	13501***	64058***	4594***	884***	37145***	13907***	2355***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	SYS	PPC	NXS	GRS	VTC	EMC2	UBQ	BLOCK
Teste de Cocurtose	5747***	997***	2838***	8863***	15457***	24343***	14270839***	12349***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	NAV	BITCNY	NVC	XDN	VIA	BAY	Burst	XWC
Teste de Cocurtose	413846***	2009306***	4929***	13539***	5342***	15132***	9726***	24438***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	CLOAK	BBR	UNO	NLG	BITUSD	GAME	CSC	XCP
Teste de Cocurtose	32418***	20647***	34035***	11195***	847552***	24517***	2291***	8031***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	NMC	FTC	XPM	CRW	FLO	BLK	ECC	DMD
Teste de Cocurtose	2195***	43050***	11390***	21097***	4399***	16343***	7739***	8254***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	POT							
Teste de Cocurtose	18126***							
Efeito do Teste	CT							

*p<0,10; **p<0,05 e ***p<0,01

Fonte: Própria.

A2.2: Teste de Covolatilidade para 2015 – 2018.

Moeda	ETH	XRP	XLM	LTC	XMR	Tether	DASH	DOGE
Teste de Covolatilidade	104179***	210136***	35881***	14802***	7233***	21286***	4344***	8161***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	BTS	BCN	DGB	XVG	MAID	MONA	RDD	Nxt
Teste de Covolatilidade	6592***	16896***	86288***	5124***	923***	49827***	17520***	2704***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	SYS	PPC	NXS	GRS	VTC	EMC2	UBQ	BLOCK
Teste de Covolatilidade	6856***	1085***	2993***	10758***	19758***	31627***	20987570***	15428***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	NAV	BITCNY	NVC	XDN	VIA	BAY	Burst	XWC
Teste de Covolatilidade	584188***	2967124***	5889***	17006***	6294***	19106***	12082***	31825***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	CLOAK	BBR	UNO	NLG	BITUSD	GAME	CSC	XCP
Teste de Covolatilidade	43141***	26875***	44837***	14174***	1242224***	32183***	2098***	9881***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	NMC	FTC	XPM	CRW	FLO	BLK	ECC	DMD
Teste de Covolatilidade	2373***	57404***	14261***	27258***	5029***	20837***	9009***	10257***
Efeito do Teste	CT	CT	CT	CT	CT	CT	CT	CT
Moeda	POT							
Teste de Covolatilidade	23431***							
Efeito do Teste	CT							

*p<0,10; **p<0,05 e ***p<0,01

Fonte: Própria.

7.3. Anexo 3: Terceiro Ensaio.

7.3.1. Resultados completos do teste de *feedback trading*.**Dependent Variable: BAY**

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BAY = C(1) + C(2)*VARGJR + C(3)*BAY(-1) + C(4)*VARGJR*BAY(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +
C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.008284	0.005596	-1.480352	0.1388
C(2) = θ	0.859483	0.520514	1.651220	0.0987
C(3) = ϕ_0	-0.157811	0.044460	-3.549524	0.0004
C(4) = ϕ_1	-0.826244	1.334662	-0.619066	0.5359
Variance Equation				
C = ω	0.002137	0.000254	8.407641	0.0000
RESID(-1)^2 = β	0.382629	0.039945	9.578955	0.0000
RESID(-1)^2*(RESID(-1)<0) =	-0.276776	0.042182	-6.561502	0.0000
GARCH(-1) = δ	0.599765	0.040496	14.81041	0.0000
R-squared	0.014183	Mean dependent var		0.003445
Adjusted R-squared	0.011975	S.D. dependent var		0.111649
S.E. of regression	0.110979	Akaike info criterion		-1.733710
Sum squared resid	16.49156	Schwarz criterion		-1.702719
Log likelihood	1172.186	Hannan-Quinn criter.		-1.722101
Durbin-Watson stat	1.931082			

Dependent Variable: BBR

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BBR = C(1) + C(2)*VARGJR + C(3)*BBR(-1) + C(4)*VARGJR*BBR(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +
C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.024158	0.001690	14.29597	0.0000
C(2) = θ	-0.378021	0.165593	-2.282836	0.0224
C(3) = ϕ_0	-0.275116	0.038329	-7.177748	0.0000
C(4) = ϕ_1	1.047722	1.096303	0.955687	0.3392
Variance Equation				
C = ω	1.20E-05	1.34E-06	8.926163	0.0000
RESID(-1)^2 = β	0.494316	0.034940	14.14761	0.0000
RESID(-1)^2*(RESID(-1)<0) =	-0.170899	0.039273	-4.351600	0.0000
GARCH(-1) = δ	0.759267	0.009369	81.04278	0.0000
R-squared	0.016165	Mean dependent var		0.002770
Adjusted R-squared	0.013961	S.D. dependent var		0.121810
S.E. of regression	0.120957	Akaike info criterion		-1.735150
Sum squared resid	19.59031	Schwarz criterion		-1.704159
Log likelihood	1173.153	Hannan-Quinn criter.		-1.723541
Durbin-Watson stat	1.917300			

Dependent Variable: BCN

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BCN= C(1) + C(2)*VARGJR + C(3)*BCN(-1) + C(4)*VARGJR*BCN(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +
C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.006820	0.002899	2.352408	0.0187
C(2) = θ	-0.156581	0.039455	-3.968551	0.0001
C(3) = ϕ_0	-0.336195	0.024804	-13.55385	0.0000
C(4) = ϕ_1	0.072760	0.179305	0.405789	0.6849

Variance Equation

C = ω	0.006083	0.000266	22.88924	0.0000
RESID(-1)^2 = β	1.227660	0.096120	12.77212	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.347841	0.147563	-2.357243	0.0184
GARCH(-1) = δ	0.029654	0.023394	1.267581	0.2049

R-squared	0.012162	Mean dependent var	0.003462
Adjusted R-squared	0.009949	S.D. dependent var	0.150400
S.E. of regression	0.149650	Akaike info criterion	-1.614404
Sum squared resid	29.98692	Schwarz criterion	-1.583412
Log likelihood	1092.072	Hannan-Quinn criter.	-1.602795
Durbin-Watson stat	1.851908		

Dependent Variable: BITCNY

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BITCNY= C(1) + C(2)*VARGJR + C(3)*BITCNY(-1) + C(4)*VARGJR*BITCNY(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +
C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.00430	0.00022	-19.0417	0.0000
C(2) = θ	-0.53845	0.01780	-30.2345	0.0000
C(3) = ϕ_0	-0.67443	0.01825	-36.9471	0.0000
C(4) = ϕ_1	0.03800	0.08064	0.47131	0.6374

Variance Equation

C = ω	0.00020	2.43E-0	8.35783	0.0000
RESID(-1)^2 = β	6.55818	0.11968	54.7942	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-6.18609	0.16932	-36.5332	0.0000
GARCH(-1) = δ	0.35298	0.00599	58.9277	0.0000

R-squared	-6.49810	Mean dependent var	-9.16E-05
Adjusted R-squared	-6.51490	S.D. dependent var	0.135587
S.E. of regression	0.37168	Akaike info criterion	-2.322815
Sum squared resid	184.9857	Schwarz criterion	-2.291823
Log likelihood	1567.770	Hannan-Quinn criter.	-2.311205
Durbin-Watson stat	0.448622		

Dependent Variable: BITUSD

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BITUSD= C(1) + C(2)*VARGJR + C(3)*BITUSD(-1) + C(4)*VARGJR*BITUSD(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +
C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.004822	0.004188	-1.151318	0.2496
C(2) = θ	1.026055	0.754297	1.360281	0.1737
C(3) = ϕ_0	-0.553365	0.035033	-15.79534	0.0000
C(4) = ϕ_1	2.077271	4.232269	0.490817	0.6236

Variance Equation

C = ω	0.000148	1.14E-05	12.99641	0.0000
RESID(-1)^2 = β	2.105054	0.088230	23.85864	0.0000
RESID(-1)^2*(RESID(-1)<0) =	-1.185181	0.135252	-8.762763	0.0000
GARCH(-1) = δ	0.331718	0.017752	18.68609	0.0000

R-squared	0.173721	Mean dependent var	2.52E-18
Adjusted R-squared	0.171869	S.D. dependent var	0.056766
S.E. of regression	0.051658	Akaike info criterion	-3.713826
Sum squared resid	3.573180	Schwarz criterion	-3.682834
Log likelihood	2501.834	Hannan-Quinn criter.	-3.702216
Durbin-Watson stat	2.259935		

Dependent Variable: BLK

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BLK = C(1) + C(2)*VARGJR + C(3)*BLK(-1) + C(4)*VARGJR*BLK(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +
C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.001448	0.002466	0.587337	0.5570
C(2) = θ	-0.184302	0.554000	-0.332675	0.7394
C(3) = ϕ_0	-0.038307	0.045722	-0.837823	0.4021
C(4) = ϕ_1	-0.701695	4.037494	-0.173795	0.8620

Variance Equation

C = ω	0.000171	1.96E-05	8.698785	0.0000
RESID(-1)^2 = β	0.203157	0.012166	16.69930	0.0000
RESID(-1)^2*(RESID(-1)<0) =	-0.059183	0.018202	-3.251498	0.0011
GARCH(-1) = δ	0.826962	0.008698	95.07701	0.0000

R-squared	0.008703	Mean dependent var	0.001091
Adjusted R-squared	0.006482	S.D. dependent var	0.079112
S.E. of regression	0.078855	Akaike info criterion	-2.498003
Sum squared resid	8.326041	Schwarz criterion	-2.467011
Log likelihood	1685.409	Hannan-Quinn criter.	-2.486393
Durbin-Watson stat	2.021703		

Dependent Variable: BLOCK

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BLOCK = C(1) + C(2)*VARGJR + C(3)*BLOCK(-1) + C(4)*VARGJR*BLOCK(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +

C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.008097	0.007708	1.050482	0.2935
C(2) = θ	-0.317850	0.475641	-0.668257	0.5040
C(3) = ϕ_0	-0.130368	0.048024	-2.714658	0.0066
C(4) = ϕ_1	0.110521	1.250304	0.088395	0.9296

Variance Equation

C = ω	0.003391	0.000358	9.471788	0.0000
RESID(-1)^2 = β	0.269413	0.036764	7.328193	0.0000
RESID(-1)^2*(RESID(-1)<0) =	-0.196668	0.033833	-5.812894	0.0000
GARCH(-1) = δ	0.643123	0.039237	16.39065	0.0000

R-squared	0.030054	Mean dependent var	0.003234
Adjusted R-squared	0.027881	S.D. dependent var	0.136535
S.E. of regression	0.134618	Akaike info criterion	-1.308035
Sum squared resid	24.26527	Schwarz criterion	-1.277044
Log likelihood	886.3457	Hannan-Quinn criter.	-1.296426
Durbin-Watson stat	2.056713		

Dependent Variable: BTC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BTC = C(1) + C(2)*VARGJR + C(3)*BTC(-1) + C(4)*VARGJR*BTC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +

C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.000722	0.001029	0.701224	0.4832
C(2) = θ	1.618567	0.957982	1.689560	0.0911
C(3) = ϕ_0	0.155204	0.046877	3.310868	0.0009
C(4) = ϕ_1	-50.82260	17.50605	-2.903146	0.0037

Variance Equation

C = ω	1.24E-05	2.30E-06	5.395366	0.0000
RESID(-1)^2 = β	0.146307	0.012805	11.42541	0.0000
RESID(-1)^2*(RESID(-1)<0) =	-0.066272	0.012699	-5.218577	0.0000
GARCH(-1) = δ	0.894695	0.006992	127.9623	0.0000

R-squared	0.003453	Mean dependent var	0.002283
Adjusted R-squared	0.001220	S.D. dependent var	0.037961
S.E. of regression	0.037938	Akaike info criterion	-4.017891
Sum squared resid	1.927181	Schwarz criterion	-3.986900
Log likelihood	2706.014	Hannan-Quinn criter.	-4.006282
Durbin-Watson stat	1.897161		

Dependent Variable: BTS

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BTS = C(1) + C(2)*VARGJR + C(3)*BTS(-1) + C(4)*VARGJR*BTS(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.002878	0.002795	-1.029444	0.3033
C(2) = θ	0.426385	0.586026	0.727588	0.4669
C(3) = ϕ_0	0.023583	0.043420	0.543135	0.5870
C(4) = ϕ_1	0.620223	3.385339	0.183208	0.8546

Variance Equation

C = ω	0.000115	1.62E-05	7.091096	0.0000
RESID(-1)^2 = β	0.121386	0.011629	10.43852	0.0000
RESID(-1)^2*(RESID(-1)<0) =	-0.057732	0.013761	-4.195431	0.0000
GARCH(-1) = δ	0.893018	0.009273	96.30229	0.0000

R-squared	0.004206	Mean dependent var	0.001699
Adjusted R-squared	0.001975	S.D. dependent var	0.077977
S.E. of regression	0.077900	Akaike info criterion	-2.536556
Sum squared resid	8.125668	Schwarz criterion	-2.505565
Log likelihood	1711.298	Hannan-Quinn criter.	-2.524947
Durbin-Watson stat	1.990500		

Dependent Variable: BURST

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

BURST = C(1) + C(2)*VARGJR + C(3)*BURST(-1) + C(4)*VARGJR*BURST(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.002726	0.003949	-0.690234	0.4900
C(2) = θ	0.391727	0.523939	0.747658	0.4547
C(3) = ϕ_0	-0.078478	0.052122	-1.505675	0.1322
C(4) = ϕ_1	-0.586650	2.934856	-0.199890	0.8416

Variance Equation

C = ω	0.001857	0.000213	8.725883	0.0000
RESID(-1)^2 = β	0.479300	0.036428	13.15757	0.0000
RESID(-1)^2*(RESID(-1)<0) =	-0.208044	0.045592	-4.563135	0.0000
GARCH(-1) = δ	0.476314	0.041063	11.59950	0.0000

R-squared	0.001192	Mean dependent var	0.002174
Adjusted R-squared	-0.001045	S.D. dependent var	0.095550
S.E. of regression	0.095600	Akaike info criterion	-2.038670
Sum squared resid	12.23758	Schwarz criterion	-2.007679
Log likelihood	1376.967	Hannan-Quinn criter.	-2.027061
Durbin-Watson stat	1.948830		

Dependent Variable: CLOAK

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

$$\text{CLOAK} = C(1) + C(2)*\text{VARGJR} + C(3)*\text{CLOAK}(-1) + C(4)*\text{VARGJR}*\text{CLOAK}(-1)$$

$$\text{GARCH} = C(5) + C(6)*\text{RESID}(-1)^2 + C(7)*\text{RESID}(-1)^2*(\text{RESID}(-1)<0) + C(8)*\text{GARCH}(-1)$$

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.000483	0.006759	0.071522	0.9430
C(2) = θ	0.192842	0.370598	0.520352	0.6028
C(3) = ϕ_0	-0.193587	0.037135	-5.213111	0.0000
C(4) = ϕ_1	0.565190	0.595952	0.948381	0.3429

Variance Equation

C = ω	0.001067	0.000142	7.529223	0.0000
RESID(-1)^2 = β	0.087538	0.016242	5.389744	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	0.069520	0.023138	3.004597	0.0027
GARCH(-1) = δ	0.833669	0.014610	57.06010	0.0000

R-squared	0.027669	Mean dependent var	0.004045
Adjusted R-squared	0.025490	S.D. dependent var	0.143384
S.E. of regression	0.141545	Akaike info criterion	-1.264765
Sum squared resid	26.82673	Schwarz criterion	-1.233774
Log likelihood	857.2899	Hannan-Quinn criter.	-1.253156
Durbin-Watson stat	2.068833		

Dependent Variable: CRW

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

$$\text{CRW} = C(1) + C(2)*\text{VARGJR} + C(3)*\text{CRW}(-1) + C(4)*\text{VARGJR}*\text{CRW}(-1)$$

$$\text{GARCH} = C(5) + C(6)*\text{RESID}(-1)^2 + C(7)*\text{RESID}(-1)^2*(\text{RESID}(-1)<0) + C(8)*\text{GARCH}(-1)$$

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.002950	0.003754	-0.785707	0.4320
C(2) = θ	0.053993	0.088419	0.610647	0.5414
C(3) = ϕ_0	-0.166270	0.033753	-4.926148	0.0000
C(4) = ϕ_1	-0.299485	0.199733	-1.499424	0.1338

Variance Equation

C = ω	6.78E-05	3.48E-05	1.945857	0.0517
RESID(-1)^2 = β	0.062240	0.006610	9.415772	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	0.031859	0.013927	2.287597	0.0222
GARCH(-1) = δ	0.927461	0.004460	207.9471	0.0000

R-squared	0.070843	Mean dependent var	0.003526
Adjusted R-squared	0.068762	S.D. dependent var	0.299314
S.E. of regression	0.288840	Akaike info criterion	-0.446025
Sum squared resid	111.7110	Schwarz criterion	-0.415034
Log likelihood	307.5059	Hannan-Quinn criter.	-0.434416
Durbin-Watson stat	2.120635		

Dependent Variable: CSC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

CSC = C(1) + C(2)*VARGJR + C(3)*CSC(-1) + C(4)*VARGJR*CSC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.026021	0.044971	0.578605	0.5629
C(2) = θ	-0.256589	0.498368	-0.514859	0.6067
C(3) = ϕ_0	0.000349	0.099073	0.003522	0.9972
C(4) = ϕ_1	-1.744198	0.712720	-2.447241	0.0144
Variance Equation				
C = ω	0.029061	0.003721	7.810712	0.0000
RESID(-1)^2 = β	0.070409	0.017879	3.938167	0.0001
RESID(-1)^2*(RESID(-1)<0) = λ	-0.071847	0.018393	-3.906112	0.0001
GARCH(-1) = δ	0.624514	0.047262	13.21395	0.0000
R-squared	0.018058	Mean dependent var		-0.000625
Adjusted R-squared	0.015858	S.D. dependent var		0.291450
S.E. of regression	0.289130	Akaike info criterion		0.331102
Sum squared resid	111.9354	Schwarz criterion		0.362093
Log likelihood	-214.3347	Hannan-Quinn criter.		0.342711
Durbin-Watson stat	2.014112			

Dependent Variable: DASH

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

DASH = C(1) + C(2)*VARGJR + C(3)*DASH(-1) + C(4)*VARGJR*DASH(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.002222	0.002290	-0.969977	0.3321
C(2) = θ	1.245639	0.768209	1.621484	0.1049
C(3) = ϕ_0	-0.001616	0.045057	-0.035866	0.9714
C(4) = ϕ_1	-7.752862	7.559179	-1.025622	0.3051
Variance Equation				
C = ω	0.000183	2.25E-05	8.164510	0.0000
RESID(-1)^2 = β	0.252608	0.019999	12.63135	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.113004	0.024267	-4.656756	0.0000
GARCH(-1) = δ	0.776038	0.014344	54.10079	0.0000
R-squared	0.006971	Mean dependent var		0.002935
Adjusted R-squared	0.004746	S.D. dependent var		0.058596
S.E. of regression	0.058456	Akaike info criterion		-3.018626
Sum squared resid	4.575563	Schwarz criterion		-2.987635
Log likelihood	2035.008	Hannan-Quinn criter.		-3.007017
Durbin-Watson stat	1.946786			

Dependent Variable: DGB

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

DGB = C(1) + C(2)*VARGJR + C(3)*DGB(-1) + C(4)*VARGJR*DGB(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.004215	0.002743	-1.536448	0.1244
C(2) = θ	0.502782	0.369694	1.359995	0.1738
C(3) = ϕ_0	-0.172043	0.035897	-4.792714	0.0000
C(4) = ϕ_1	2.712599	1.856383	1.461228	0.1440
Variance Equation				
C = ω	4.57E-05	1.41E-05	3.230339	0.0012
RESID(-1)^2 = β	0.096338	0.005877	16.39179	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.092278	0.007969	-11.58000	0.0000
GARCH(-1) = δ	0.946300	0.003275	288.9218	0.0000
R-squared	-0.000507	Mean dependent var		0.003409
Adjusted R-squared	-0.002749	S.D. dependent var		0.100628
S.E. of regression	0.100766	Akaike info criterion		-2.047304
Sum squared resid	13.59592	Schwarz criterion		-2.016313
Log likelihood	1382.765	Hannan-Quinn criter.		-2.035695
Durbin-Watson stat	1.948340			

Dependent Variable: DMD

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

DMD = C(1) + C(2)*VARGJR + C(3)*DMD(-1) + C(4)*VARGJR*DMD(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-8.17E-05	0.004397	-0.018587	0.9852
C(2) = θ	0.183065	0.742213	0.246648	0.8052
C(3) = ϕ_0	-0.194347	0.035116	-5.534356	0.0000
C(4) = ϕ_1	0.549920	2.506516	0.219396	0.8263
Variance Equation				
C = ω	0.000275	5.49E-05	5.014237	0.0000
RESID(-1)^2 = β	0.088071	0.013297	6.623177	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	0.008343	0.016210	0.514661	0.6068
GARCH(-1) = δ	0.870159	0.016567	52.52419	0.0000
R-squared	0.035600	Mean dependent var		0.002016
Adjusted R-squared	0.033440	S.D. dependent var		0.080154
S.E. of regression	0.078802	Akaike info criterion		-2.326822
Sum squared resid	8.314914	Schwarz criterion		-2.295831
Log likelihood	1570.461	Hannan-Quinn criter.		-2.315213
Durbin-Watson stat	2.036539			

Dependent Variable: DOGE

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

DOGE = C(1) + C(2)*VARGJR + C(3)*DOGE(-1) + C(4)*VARGJR*DOGE(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.001819	0.001377	-1.321535	0.1863
C(2) = θ	0.447980	0.509493	0.879267	0.3793
C(3) = ϕ_0	-0.050044	0.040756	-1.227886	0.2195
C(4) = ϕ_1	2.329746	3.839376	0.606803	0.5440
Variance Equation				
C = ω	6.45E-05	8.75E-06	7.372541	0.0000
RESID(-1)^2 = β	0.300298	0.019910	15.08295	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.164843	0.021901	-7.526692	0.0000
GARCH(-1) = δ	0.806825	0.010886	74.11559	0.0000
R-squared	-0.001013	Mean dependent var		0.002242
Adjusted R-squared	-0.003255	S.D. dependent var		0.066904
S.E. of regression	0.067013	Akaike info criterion		-3.119321
Sum squared resid	6.013053	Schwarz criterion		-3.088330
Log likelihood	2102.624	Hannan-Quinn criter.		-3.107712
Durbin-Watson stat	1.905670			

Dependent Variable: ECC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

ECC = C(1) + C(2)*VARGJR + C(3)*ECC(-1) + C(4)*VARGJR*ECC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.010826	0.006094	-1.776584	0.0756
C(2) = θ	-0.001836	0.064342	-0.028539	0.9772
C(3) = ϕ_0	-0.254951	0.034900	-7.305128	0.0000
C(4) = ϕ_1	-0.291525	0.132433	-2.201310	0.0277
Variance Equation				
C = ω	2.02E-07	7.55E-05	0.002680	0.9979
RESID(-1)^2 = β	0.008722	0.005714	1.526402	0.1269
RESID(-1)^2*(RESID(-1)<0) = λ	0.089211	0.013979	6.381824	0.0000
GARCH(-1) = δ	0.954003	0.003112	306.5783	0.0000
R-squared	0.143439	Mean dependent var		-0.000257
Adjusted R-squared	0.141520	S.D. dependent var		0.405708
S.E. of regression	0.375906	Akaike info criterion		0.442284
Sum squared resid	189.2076	Schwarz criterion		0.473276
Log likelihood	-288.9939	Hannan-Quinn criter.		0.453894
Durbin-Watson stat	2.183483			

Dependent Variable: EMC2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

$$EMC2 = C(1) + C(2)*VARGJR + C(3)*EMC2(-1) + C(4)*VARGJR*EMC2(-1)$$

$$GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)$$

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.005100	0.004760	-1.071502	0.2839
C(2) = θ	0.343962	0.459155	0.749120	0.4538
C(3) = ϕ_0	-0.088977	0.028463	-3.126059	0.0018
C(4) = ϕ_1	-0.355598	0.910352	-0.390616	0.6961

Variance Equation

C = ω	0.005707	0.000389	14.68057	0.0000
RESID(-1)^2 = β	1.010791	0.079040	12.78832	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.907604	0.084162	-10.78397	0.0000
GARCH(-1) = δ	0.187556	0.035257	5.319748	0.0000

R-squared	-0.010681	Mean dependent var	0.004681
Adjusted R-squared	-0.012946	S.D. dependent var	0.116922
S.E. of regression	0.117676	Akaike info criterion	-1.640209
Sum squared resid	18.54208	Schwarz criterion	-1.609218
Log likelihood	1109.400	Hannan-Quinn criter.	-1.628600
Durbin-Watson stat	1.859938		

Dependent Variable: ETH

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

$$ETH = C(1) + C(2)*VARGJR + C(3)*ETH(-1) + C(4)*VARGJR*ETH(-1)$$

$$GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)$$

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.000475	0.001831	0.259157	0.7955
C(2) = θ	0.277211	0.243376	1.139023	0.2547
C(3) = ϕ_0	0.071233	0.034797	2.047091	0.0406
C(4) = ϕ_1	-1.201644	0.577297	-2.081502	0.0374

Variance Equation

C = ω	0.000293	3.33E-05	8.807913	0.0000
RESID(-1)^2 = β	0.320658	0.027262	11.76223	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.065008	0.036663	-1.773116	0.0762
GARCH(-1) = δ	0.694036	0.021523	32.24623	0.0000

R-squared	-0.051937	Mean dependent var	0.004387
Adjusted R-squared	-0.054293	S.D. dependent var	0.098823
S.E. of regression	0.101470	Akaike info criterion	-2.589066
Sum squared resid	13.78667	Schwarz criterion	-2.558075
Log likelihood	1746.558	Hannan-Quinn criter.	-2.577457
Durbin-Watson stat	2.165309		

Dependent Variable: FLO

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

FLO = C(1) + C(2)*VARGJR + C(3)*FLO(-1) + C(4)*VARGJR*FLO(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.006247	0.006837	0.913733	0.3609
C(2) = θ	-0.178377	0.574340	-0.310578	0.7561
C(3) = ϕ_0	-0.063378	0.051869	-1.221899	0.2217
C(4) = ϕ_1	-0.657202	2.210391	-0.297324	0.7662
Variance Equation				
C = ω	0.002365	0.000318	7.426726	0.0000
RESID(-1)^2 = β	0.191326	0.032324	5.919008	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.039827	0.038175	-1.043266	0.2968
GARCH(-1) = δ	0.638948	0.038112	16.76509	0.0000
R-squared	0.013168	Mean dependent var		0.002836
Adjusted R-squared	0.010957	S.D. dependent var		0.111002
S.E. of regression	0.110392	Akaike info criterion		-1.659219
Sum squared resid	16.31769	Schwarz criterion		-1.628228
Log likelihood	1122.166	Hannan-Quinn criter.		-1.647610
Durbin-Watson stat	2.063480			

Dependent Variable: FTC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

FTC = C(1) + C(2)*VARGJR + C(3)*FTC(-1) + C(4)*VARGJR*FTC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.002694	0.004653	0.578929	0.5626
C(2) = θ	-0.358278	0.483433	-0.741111	0.4586
C(3) = ϕ_0	0.028390	0.035824	0.792469	0.4281
C(4) = ϕ_1	-0.410481	1.211569	-0.338801	0.7348
Variance Equation				
C = ω	0.004263	0.000254	16.78262	0.0000
RESID(-1)^2 = β	0.809814	0.068942	11.74639	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.697812	0.074691	-9.342642	0.0000
GARCH(-1) = δ	0.247297	0.036350	6.803142	0.0000
R-squared	0.002850	Mean dependent var		0.001825
Adjusted R-squared	0.000616	S.D. dependent var		0.114293
S.E. of regression	0.114257	Akaike info criterion		-1.859681
Sum squared resid	17.48030	Schwarz criterion		-1.828690
Log likelihood	1256.776	Hannan-Quinn criter.		-1.848072
Durbin-Watson stat	1.842578			

Dependent Variable: GAME

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

GAME= C(1) + C(2)*VARGJR + C(3)*GAME(-1) + C(4)*VARGJR*GAME(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +

C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.002493	0.004015	-0.621000	0.5346
C(2) = θ	0.636818	0.435349	1.462777	0.1435
C(3) = ϕ_0	-0.034085	0.035676	-0.955405	0.3394
C(4) = ϕ_1	-2.020483	1.266490	-1.595341	0.1106

Variance Equation

C = ω	9.12E-05	1.48E-05	6.148461	0.0000
RESID(-1)^2 = β	0.061207	0.004915	12.45344	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.022729	0.009454	-2.404184	0.0162
GARCH(-1) = δ	0.939973	0.003357	279.9756	0.0000

R-squared	0.016570	Mean dependent var	0.004109
Adjusted R-squared	0.014367	S.D. dependent var	0.111034
S.E. of regression	0.110234	Akaike info criterion	-1.852639
Sum squared resid	16.27090	Schwarz criterion	-1.821647
Log likelihood	1252.047	Hannan-Quinn criter.	-1.841030
Durbin-Watson stat	2.041102		

Dependent Variable: GRS

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

GRS= C(1) + C(2)*VARGJR + C(3)*GRS(-1) + C(4)*VARGJR*GRS(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) +

C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.002574	0.008105	0.317592	0.7508
C(2) = θ	0.030410	0.506787	0.060006	0.9522
C(3) = ϕ_0	-0.108729	0.050586	-2.149408	0.0316
C(4) = ϕ_1	-0.335348	1.287351	-0.260495	0.7945

Variance Equation

C = ω	0.003306	0.000343	9.627707	0.0000
RESID(-1)^2 = β	0.207251	0.026660	7.773774	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.005408	0.037132	-0.145632	0.8842
GARCH(-1) = δ	0.643112	0.026973	23.84289	0.0000

R-squared	0.016397	Mean dependent var	0.005193
Adjusted R-squared	0.014193	S.D. dependent var	0.136647
S.E. of regression	0.135674	Akaike info criterion	-1.264418
Sum squared resid	24.64759	Schwarz criterion	-1.233427
Log likelihood	857.0566	Hannan-Quinn criter.	-1.252809
Durbin-Watson stat	2.006573		

Dependent Variable: LTC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

LTC= C(1) + C(2)*VARGJR + C(3)*LTC(-1) + C(4)*VARGJR*LTC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.000470	0.001713	-0.274152	0.7840
C(2) = θ	0.596469	0.604904	0.986055	0.3241
C(3) = ϕ_0	-0.085085	0.034686	-2.453022	0.0142
C(4) = ϕ_1	8.335506	5.636058	1.478960	0.1392
Variance Equation				
C = ω	5.00E-05	5.68E-06	8.809975	0.0000
RESID(-1)^2 = β	0.066940	0.005688	11.76756	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.084984	0.006348	-13.38821	0.0000
GARCH(-1) = δ	0.956578	0.004289	223.0246	0.0000
R-squared	0.000391	Mean dependent var		0.002381
Adjusted R-squared	-0.001849	S.D. dependent var		0.059378
S.E. of regression	0.059433	Akaike info criterion		-3.110622
Sum squared resid	4.729707	Schwarz criterion		-3.079630
Log likelihood	2096.782	Hannan-Quinn criter.		-3.099012
Durbin-Watson stat	1.993031			

Dependent Variable: MAID

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

MAID= C(1) + C(2)*VARGJR + C(3)*MAID(-1) + C(4)*VARGJR*MAID(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.001451	0.004544	-0.319334	0.7495
C(2) = θ	0.749559	1.076416	0.696346	0.4862
C(3) = ϕ_0	-0.035012	0.057426	-0.609692	0.5421
C(4) = ϕ_1	-9.225871	9.080164	-1.016047	0.3096
Variance Equation				
C = ω	0.000206	4.48E-05	4.600299	0.0000
RESID(-1)^2 = β	0.070058	0.014246	4.917646	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	0.012297	0.016263	0.756114	0.4496
GARCH(-1) = δ	0.879613	0.017517	50.21442	0.0000
R-squared	0.010551	Mean dependent var		0.001610
Adjusted R-squared	0.008334	S.D. dependent var		0.067434
S.E. of regression	0.067152	Akaike info criterion		-2.627565
Sum squared resid	6.038150	Schwarz criterion		-2.596574
Log likelihood	1772.410	Hannan-Quinn criter.		-2.615956
Durbin-Watson stat	1.980078			

Dependent Variable: MONA

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

MONA= C(1) + C(2)*VARGJR + C(3)*MONA(-1) + C(4)*VARGJR*MONA(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.003709	0.001653	-2.244063	0.0248
C(2) = θ	0.704450	0.410192	1.717366	0.0859
C(3) = ϕ_0	0.017121	0.031091	0.550685	0.5818
C(4) = ϕ_1	-0.866897	0.950478	-0.912065	0.3617

Variance Equation

C = ω	0.000598	4.46E-05	13.41142	0.0000
RESID(-1)^2 = β	0.614028	0.055192	11.12521	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.112052	0.067786	-1.653008	0.0983
GARCH(-1) = δ	0.489991	0.022989	21.31404	0.0000

R-squared	0.005885	Mean dependent var	0.001721
Adjusted R-squared	0.003658	S.D. dependent var	0.080105
S.E. of regression	0.079958	Akaike info criterion	-2.721645
Sum squared resid	8.560643	Schwarz criterion	-2.690654
Log likelihood	1835.585	Hannan-Quinn criter.	-2.710036
Durbin-Watson stat	1.960138		

Dependent Variable: NAV

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

NAV= C(1) + C(2)*VARGJR + C(3)*NAV(-1) + C(4)*VARGJR*NAV(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.002568	0.003850	0.667072	0.5047
C(2) = θ	-0.192982	0.334728	-0.576535	0.5643
C(3) = ϕ_0	-0.115697	0.037993	-3.045225	0.0023
C(4) = ϕ_1	-0.228072	0.421850	-0.540646	0.5888

Variance Equation

C = ω	0.001874	0.000185	10.12948	0.0000
RESID(-1)^2 = β	0.309234	0.034316	9.011310	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.068274	0.044396	-1.537832	0.1241
GARCH(-1) = δ	0.608690	0.031728	19.18480	0.0000

R-squared	0.076551	Mean dependent var	0.002588
Adjusted R-squared	0.074482	S.D. dependent var	0.130152
S.E. of regression	0.125212	Akaike info criterion	-1.702607
Sum squared resid	20.99279	Schwarz criterion	-1.671615
Log likelihood	1151.300	Hannan-Quinn criter.	-1.690997
Durbin-Watson stat	2.018880		

Dependent Variable: NLG

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

NLG= C(1) + C(2)*VARGJR + C(3)*NLG(-1) + C(4)*VARGJR*NLG(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.002871	0.004125	0.696074	0.4864
C(2) = θ	-0.224869	0.759733	-0.295984	0.7672
C(3) = ϕ_0	-0.060071	0.042933	-1.399182	0.1618
C(4) = ϕ_1	-2.447892	3.127113	-0.782796	0.4337

Variance Equation

C = ω	0.001666	0.000141	11.83235	0.0000
RESID(-1)^2 = β	0.318929	0.042491	7.505743	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.172132	0.050317	-3.420994	0.0006
GARCH(-1) = δ	0.508601	0.034160	14.88890	0.0000

R-squared	0.033392	Mean dependent var	0.002308
Adjusted R-squared	0.031226	S.D. dependent var	0.082918
S.E. of regression	0.081613	Akaike info criterion	-2.365230
Sum squared resid	8.918585	Schwarz criterion	-2.334239
Log likelihood	1596.252	Hannan-Quinn criter.	-2.353621
Durbin-Watson stat	2.035198		

Dependent Variable: NMC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

NMC= C(1) + C(2)*VARGJR + C(3)*NMC(-1) + C(4)*VARGJR*NMC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.000413	0.001755	0.235406	0.8139
C(2) = θ	-0.062040	0.334485	-0.185480	0.8529
C(3) = ϕ_0	-0.054375	0.034352	-1.582866	0.1135
C(4) = ϕ_1	-1.121181	1.766413	-0.634722	0.5256

Variance Equation

C = ω	0.000101	9.95E-06	10.15203	0.0000
RESID(-1)^2 = β	0.183452	0.011046	16.60837	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.130441	0.012383	-10.53376	0.0000
GARCH(-1) = δ	0.877950	0.005156	170.2771	0.0000

R-squared	0.017842	Mean dependent var	7.98E-05
Adjusted R-squared	0.015642	S.D. dependent var	0.093198
S.E. of regression	0.092467	Akaike info criterion	-2.545620
Sum squared resid	11.44855	Schwarz criterion	-2.514629
Log likelihood	1717.384	Hannan-Quinn criter.	-2.534011
Durbin-Watson stat	2.072496		

Dependent Variable: NVC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

NVC= C(1) + C(2)*VARGJR + C(3)*NVC(-1) + C(4)*VARGJR*NVC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.001616	0.002335	-0.692030	0.4889
C(2) = θ	0.498161	0.394161	1.263851	0.2063
C(3) = ϕ_0	-0.025310	0.039564	-0.639709	0.5224
C(4) = ϕ_1	-3.912070	3.128323	-1.250533	0.2111

Variance Equation

C = ω	3.64E-05	3.43E-06	10.59655	0.0000
RESID(-1)^2 = β	0.069951	0.004445	15.73853	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.045342	0.007970	-5.689365	0.0000
GARCH(-1) = δ	0.950942	0.001839	517.0764	0.0000

R-squared	0.023907	Mean dependent var	0.001817
Adjusted R-squared	0.021720	S.D. dependent var	0.083984
S.E. of regression	0.083067	Akaike info criterion	-2.546016
Sum squared resid	9.239166	Schwarz criterion	-2.515024
Log likelihood	1717.649	Hannan-Quinn criter.	-2.534406
Durbin-Watson stat	2.084642		

Dependent Variable: NXS

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

NXS= C(1) + C(2)*VARGJR + C(3)*NXS(-1) + C(4)*VARGJR*NXS(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.002716	0.005242	0.518100	0.6044
C(2) = θ	0.123604	0.388521	0.318139	0.7504
C(3) = ϕ_0	-0.160831	0.049045	-3.279237	0.0010
C(4) = ϕ_1	-0.994661	1.681362	-0.591580	0.5541

Variance Equation

C = ω	0.001051	0.000145	7.251371	0.0000
RESID(-1)^2 = β	0.206434	0.018649	11.06955	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.052086	0.029136	-1.787680	0.0738
GARCH(-1) = δ	0.766717	0.017602	43.55744	0.0000

R-squared	0.037757	Mean dependent var	0.004418
Adjusted R-squared	0.035601	S.D. dependent var	0.125965
S.E. of regression	0.123702	Akaike info criterion	-1.478393
Sum squared resid	20.48971	Schwarz criterion	-1.447402
Log likelihood	1000.741	Hannan-Quinn criter.	-1.466784
Durbin-Watson stat	2.016021		

Dependent Variable: NXT

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

NXT= C(1) + C(2)*VARGJR + C(3)*NXT(-1) + C(4)*VARGJR*NXT(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.002323	0.002291	-1.014236	0.3105
C(2) = θ	0.309040	0.570170	0.542014	0.5878
C(3) = ϕ_0	-0.035806	0.039524	-0.905943	0.3650
C(4) = ϕ_1	1.585613	4.009491	0.395465	0.6925
Variance Equation				
C = ω	0.000120	1.63E-05	7.397049	0.0000
RESID(-1)^2 = β	0.154419	0.014987	10.30386	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.034852	0.019858	-1.755005	0.0793
GARCH(-1) = δ	0.848915	0.012135	69.95605	0.0000
R-squared	0.001995	Mean dependent var		0.001100
Adjusted R-squared	-0.000241	S.D. dependent var		0.076199
S.E. of regression	0.076208	Akaike info criterion		-2.681139
Sum squared resid	7.776493	Schwarz criterion		-2.650148
Log likelihood	1808.385	Hannan-Quinn criter.		-2.669530
Durbin-Watson stat	1.931959			

Dependent Variable: POT

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

POT= C(1) + C(2)*VARGJR + C(3)*POT(-1) + C(4)*VARGJR*POT(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.001220	0.005056	0.241350	0.8093
C(2) = θ	0.084695	0.762150	0.111126	0.9115
C(3) = ϕ_0	-0.018530	0.041506	-0.446448	0.6553
C(4) = ϕ_1	-1.745766	2.172990	-0.803393	0.4217
Variance Equation				
C = ω	0.003156	0.000268	11.79308	0.0000
RESID(-1)^2 = β	0.479382	0.050760	9.444136	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.326068	0.053383	-6.108078	0.0000
GARCH(-1) = δ	0.295997	0.049988	5.921335	0.0000
R-squared	0.020121	Mean dependent var		0.001860
Adjusted R-squared	0.017926	S.D. dependent var		0.091931
S.E. of regression	0.091103	Akaike info criterion		-2.154752
Sum squared resid	11.11349	Schwarz criterion		-2.123761
Log likelihood	1454.916	Hannan-Quinn criter.		-2.143143
Durbin-Watson stat	1.986785			

Dependent Variable: PPC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

PPC= C(1) + C(2)*VARGJR + C(3)*PPC(-1) + C(4)*VARGJR*PPC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.000644	0.001846	-0.348775	0.7273
C(2) = θ	0.107085	0.549866	0.194747	0.8456
C(3) = ϕ_0	-0.034115	0.037327	-0.913970	0.3607
C(4) = ϕ_1	-2.201608	4.037745	-0.545257	0.5856

Variance Equation

C = ω	8.66E-05	9.40E-06	9.210451	0.0000
RESID(-1)^2 = β	0.160543	0.011751	13.66210	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.132783	0.013122	-10.11947	0.0000
GARCH(-1) = δ	0.890670	0.005652	157.5988	0.0000

R-squared	0.003263	Mean dependent var	0.000950
Adjusted R-squared	0.001030	S.D. dependent var	0.068960
S.E. of regression	0.068924	Akaike info criterion	-2.862608
Sum squared resid	6.361002	Schwarz criterion	-2.831617
Log likelihood	1930.241	Hannan-Quinn criter.	-2.850999
Durbin-Watson stat	1.970361		

Dependent Variable: RDD

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

RDD= C(1) + C(2)*VARGJR + C(3)*RDD(-1) + C(4)*VARGJR*RDD(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.012325	0.004674	-2.636939	0.0084
C(2) = θ	0.787405	0.306523	2.568828	0.0102
C(3) = ϕ_0	-0.321393	0.039378	-8.161854	0.0000
C(4) = ϕ_1	0.796379	1.197685	0.664932	0.5061

Variance Equation

C = ω	0.000394	9.86E-05	3.989954	0.0001
RESID(-1)^2 = β	0.146343	0.012385	11.81579	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.047067	0.015966	-2.947990	0.0032
GARCH(-1) = δ	0.860203	0.013447	63.97150	0.0000

R-squared	0.079364	Mean dependent var	0.003536
Adjusted R-squared	0.077302	S.D. dependent var	0.135941
S.E. of regression	0.130581	Akaike info criterion	-1.488462
Sum squared resid	22.83192	Schwarz criterion	-1.457470
Log likelihood	1007.502	Hannan-Quinn criter.	-1.476852
Durbin-Watson stat	2.042854		

Dependent Variable: SYS

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

SYS= C(1) + C(2)*VARGJR + C(3)*SYS(-1) + C(4)*VARGJR*SYS(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.002726	0.005236	0.520615	0.6026
C(2) = θ	0.154025	0.612530	0.251458	0.8015
C(3) = ϕ_0	-0.039365	0.045338	-0.868262	0.3853
C(4) = ϕ_1	-3.100183	2.543668	-1.218784	0.2229

Variance Equation

C = ω	0.000868	0.000107	8.083925	0.0000
RESID(-1)^2 = β	0.186379	0.023593	7.899782	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.140881	0.024942	-5.648285	0.0000
GARCH(-1) = δ	0.788632	0.021114	37.35150	0.0000

R-squared	0.022675	Mean dependent var	0.004236
Adjusted R-squared	0.020486	S.D. dependent var	0.098217
S.E. of regression	0.097206	Akaike info criterion	-1.955322
Sum squared resid	12.65216	Schwarz criterion	-1.924330
Log likelihood	1320.998	Hannan-Quinn criter.	-1.943712
Durbin-Watson stat	1.978807		

Dependent Variable: UBQ

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

UBQ= C(1) + C(2)*VARGJR + C(3)*UBQ(-1) + C(4)*VARGJR*UBQ(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.001978	0.002477	0.798559	0.4245
C(2) = θ	-0.314135	0.081841	-3.838378	0.0001
C(3) = ϕ_0	-0.222249	0.028697	-7.744678	0.0000
C(4) = ϕ_1	0.088514	0.080915	1.093909	0.2740

Variance Equation

C = ω	0.000234	4.54E-05	5.156562	0.0000
RESID(-1)^2 = β	0.458433	0.034038	13.46808	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.343443	0.036874	-9.313961	0.0000
GARCH(-1) = δ	0.800599	0.007707	103.8791	0.0000

R-squared	-0.125911	Mean dependent var	0.002706
Adjusted R-squared	-0.128434	S.D. dependent var	0.175614
S.E. of regression	0.186551	Akaike info criterion	-1.549878
Sum squared resid	46.59898	Schwarz criterion	-1.518887
Log likelihood	1048.743	Hannan-Quinn criter.	-1.538269
Durbin-Watson stat	1.912695		

Dependent Variable: UNO

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

UNO= C(1) + C(2)*VARGJR + C(3)*UNO(-1) + C(4)*VARGJR*UNO(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.004550	0.003956	-1.150229	0.2500
C(2) = θ	0.808825	0.740088	1.092876	0.2744
C(3) = ϕ_0	-0.212680	0.049420	-4.303547	0.0000
C(4) = ϕ_1	4.782852	5.724077	0.835567	0.4034
Variance Equation				
C = ω	6.83E-05	1.27E-05	5.377708	0.0000
RESID(-1)^2 = β	0.054940	0.005838	9.410513	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.037408	0.006749	-5.542380	0.0000
GARCH(-1) = δ	0.955369	0.004063	235.1440	0.0000
R-squared	0.020753	Mean dependent var		0.002111
Adjusted R-squared	0.018559	S.D. dependent var		0.080362
S.E. of regression	0.079613	Akaike info criterion		-2.340517
Sum squared resid	8.486821	Schwarz criterion		-2.309526
Log likelihood	1579.657	Hannan-Quinn criter.		-2.328908
Durbin-Watson stat	1.984863			

Dependent Variable: VIA

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

VIA= C(1) + C(2)*VARGJR + C(3)*VIA(-1) + C(4)*VARGJR*VIA(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.004592	0.004816	0.953530	0.3403
C(2) = θ	-0.170304	0.530457	-0.321051	0.7482
C(3) = ϕ_0	0.010698	0.053686	0.199272	0.8421
C(4) = ϕ_1	-5.365328	3.980786	-1.347806	0.1777
Variance Equation				
C = ω	0.000303	4.64E-05	6.515988	0.0000
RESID(-1)^2 = β	0.122733	0.014394	8.526514	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.071085	0.016752	-4.243293	0.0000
GARCH(-1) = δ	0.883834	0.010036	88.06291	0.0000
R-squared	0.018824	Mean dependent var		0.002954
Adjusted R-squared	0.016625	S.D. dependent var		0.102328
S.E. of regression	0.101474	Akaike info criterion		-1.856210
Sum squared resid	13.78769	Schwarz criterion		-1.825219
Log likelihood	1254.445	Hannan-Quinn criter.		-1.844601
Durbin-Watson stat	1.983620			

Dependent Variable: VTC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

VTC= C(1) + C(2)*VARGJR + C(3)*VTC(-1) + C(4)*VARGJR*VTC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.003174	0.003331	-0.952897	0.3406
C(2) = θ	0.389612	0.435532	0.894566	0.3710
C(3) = ϕ_0	-0.049310	0.033517	-1.471175	0.1412
C(4) = ϕ_1	1.020416	1.042247	0.979054	0.3276

Variance Equation

C = ω	0.000319	3.21E-05	9.946581	0.0000
RESID(-1)^2 = β	0.202309	0.017709	11.42380	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.138643	0.020315	-6.824552	0.0000
GARCH(-1) = δ	0.844359	0.007795	108.3273	0.0000

R-squared	-0.016364	Mean dependent var	0.002901
Adjusted R-squared	-0.018641	S.D. dependent var	0.104557
S.E. of regression	0.105527	Akaike info criterion	-2.023942
Sum squared resid	14.91106	Schwarz criterion	-1.992950
Log likelihood	1367.077	Hannan-Quinn criter.	-2.012333
Durbin-Watson stat	1.980976		

Dependent Variable: XCP

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

XCP= C(1) + C(2)*VARGJR + C(3)*XCP(-1) + C(4)*VARGJR*XCP(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.001412	0.004286	-0.329431	0.7418
C(2) = θ	0.090955	0.572231	0.158948	0.8737
C(3) = ϕ_0	-0.133664	0.045347	-2.947604	0.0032
C(4) = ϕ_1	-0.594518	3.786105	-0.157026	0.8752

Variance Equation

C = ω	9.72E-05	2.19E-05	4.435792	0.0000
RESID(-1)^2 = β	0.049739	0.005777	8.610220	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.070854	0.006850	-10.34394	0.0000
GARCH(-1) = δ	0.968467	0.004885	198.2339	0.0000

R-squared	0.019503	Mean dependent var	0.000676
Adjusted R-squared	0.017306	S.D. dependent var	0.092192
S.E. of regression	0.091391	Akaike info criterion	-2.079469
Sum squared resid	11.18379	Schwarz criterion	-2.048478
Log likelihood	1404.364	Hannan-Quinn criter.	-2.067860
Durbin-Watson stat	2.005174		

Dependent Variable: XDN

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

XDN= C(1) + C(2)*VARGJR + C(3)*XDN(-1) + C(4)*VARGJR*XDN(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.000516	0.006997	-0.073702	0.9412
C(2) = θ	0.092779	0.348367	0.266327	0.7900
C(3) = ϕ_0	-0.256843	0.060366	-4.254758	0.0000
C(4) = ϕ_1	2.264614	1.680973	1.347205	0.1779

Variance Equation

C = ω	0.006765	0.001250	5.410489	0.0000
RESID(-1)^2 = β	0.141346	0.023161	6.102637	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.199754	0.029389	-6.796933	0.0000
GARCH(-1) = δ	0.585678	0.069631	8.411152	0.0000

R-squared	-0.004307	Mean dependent var	0.001898
Adjusted R-squared	-0.006557	S.D. dependent var	0.109228
S.E. of regression	0.109586	Akaike info criterion	-1.596079
Sum squared resid	16.08005	Schwarz criterion	-1.565088
Log likelihood	1079.767	Hannan-Quinn criter.	-1.584470
Durbin-Watson stat	1.836036		

Dependent Variable: XLM

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

XLM= C(1) + C(2)*VARGJR + C(3)*XLM(-1) + C(4)*VARGJR*XLM(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	7.82E-05	0.002820	0.027718	0.9779
C(2) = θ	0.150625	0.592440	0.254245	0.7993
C(3) = ϕ_0	-0.068772	0.038145	-1.802894	0.0714
C(4) = ϕ_1	1.703232	1.852353	0.919496	0.3578

Variance Equation

C = ω	0.000311	1.95E-05	15.94651	0.0000
RESID(-1)^2 = β	0.197307	0.017109	11.53262	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.098683	0.020205	-4.884174	0.0000
GARCH(-1) = δ	0.807207	0.010762	75.00666	0.0000

R-squared	0.010059	Mean dependent var	0.003334
Adjusted R-squared	0.007841	S.D. dependent var	0.080716
S.E. of regression	0.080399	Akaike info criterion	-2.567648
Sum squared resid	8.655326	Schwarz criterion	-2.536657
Log likelihood	1732.176	Hannan-Quinn criter.	-2.556039
Durbin-Watson stat	1.870380		

Dependent Variable: XMR

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

XMR= C(1) + C(2)*VARGJR + C(3)*XMR(-1) + C(4)*VARGJR*XMR(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.001147	0.003291	-0.348542	0.7274
C(2) = θ	0.860062	0.817185	1.052469	0.2926
C(3) = ϕ_0	-0.072688	0.044709	-1.625798	0.1040
C(4) = ϕ_1	-0.271469	6.085465	-0.044609	0.9644

Variance Equation

C = ω	0.000206	2.72E-05	7.564524	0.0000
RESID(-1)^2 = β	0.161134	0.014788	10.89603	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.129869	0.015420	-8.422377	0.0000
GARCH(-1) = δ	0.862229	0.011089	77.75445	0.0000

R-squared	0.002733	Mean dependent var	0.003715
Adjusted R-squared	0.000499	S.D. dependent var	0.069558
S.E. of regression	0.069540	Akaike info criterion	-2.648978
Sum squared resid	6.475201	Schwarz criterion	-2.617986
Log likelihood	1786.789	Hannan-Quinn criter.	-2.637368
Durbin-Watson stat	1.965246		

Dependent Variable: XPM

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

XPM= C(1) + C(2)*VARGJR + C(3)*XPM(-1) + C(4)*VARGJR*XPM(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.003999	0.002954	-1.353617	0.1759
C(2) = θ	0.460541	0.486629	0.946390	0.3439
C(3) = ϕ_0	-0.128834	0.041410	-3.111161	0.0019
C(4) = ϕ_1	1.242560	2.966731	0.418831	0.6753

Variance Equation

C = ω	0.000147	1.43E-05	10.27084	0.0000
RESID(-1)^2 = β	0.156949	0.012710	12.34885	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.105127	0.014359	-7.321481	0.0000
GARCH(-1) = δ	0.887671	0.005940	149.4372	0.0000

R-squared	0.005632	Mean dependent var	0.001622
Adjusted R-squared	0.003404	S.D. dependent var	0.089275
S.E. of regression	0.089123	Akaike info criterion	-2.274836
Sum squared resid	10.63549	Schwarz criterion	-2.243844
Log likelihood	1535.552	Hannan-Quinn criter.	-2.263226
Durbin-Watson stat	1.957783		

Dependent Variable: XRP

$$\text{XRP} = C(1) + C(2)*\text{VARGJR} + C(3)*\text{XRP}(-1) + C(4)*\text{VARGJR}*\text{XRP}(-1)$$

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

$$\text{GARCH} = C(5) + C(6)*\text{RESID}(-1)^2 + C(7)*\text{RESID}(-1)^2*(\text{RESID}(-1)<0) + C(8)*\text{GARCH}(-1)$$

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.001961	0.001755	-1.117321	0.2639
C(2) = θ	0.220878	0.510755	0.432453	0.6654
C(3) = ϕ_0	0.080762	0.038903	2.075969	0.0379
C(4) = ϕ_1	-1.117515	1.528018	-0.731349	0.4646

Variance Equation

C = ω	0.000463	2.21E-05	20.97793	0.0000
RESID(-1)^2 = β	0.585901	0.043276	13.53869	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.341662	0.045890	-7.445248	0.0000
GARCH(-1) = δ	0.554197	0.017557	31.56570	0.0000

R-squared	0.060083	Mean dependent var	0.002848
Adjusted R-squared	0.057978	S.D. dependent var	0.073261
S.E. of regression	0.071105	Akaike info criterion	-3.044932
Sum squared resid	6.769895	Schwarz criterion	-3.013940
Log likelihood	2052.672	Hannan-Quinn criter.	-3.033322
Durbin-Watson stat	1.858553		

Dependent Variable: XVG

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

$$\text{XVG} = C(1) + C(2)*\text{VARGJR} + C(3)*\text{XVG}(-1) + C(4)*\text{VARGJR}*\text{XVG}(-1)$$

$$\text{GARCH} = C(5) + C(6)*\text{RESID}(-1)^2 + C(7)*\text{RESID}(-1)^2*(\text{RESID}(-1)<0) + C(8)*\text{GARCH}(-1)$$

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	-0.009044	0.005022	-1.800908	0.0717
C(2) = θ	0.431019	0.214111	2.013062	0.0441
C(3) = ϕ_0	-0.250509	0.039387	-6.360254	0.0000
C(4) = ϕ_1	-0.404793	0.549469	-0.736698	0.4613

Variance Equation

C = ω	0.002400	0.000293	8.201087	0.0000
RESID(-1)^2 = β	0.252706	0.031486	8.026078	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	-0.118919	0.032353	-3.675712	0.0002
GARCH(-1) = δ	0.703610	0.027688	25.41255	0.0000

R-squared	0.074709	Mean dependent var	0.005051
Adjusted R-squared	0.072636	S.D. dependent var	0.160891
S.E. of regression	0.154937	Akaike info criterion	-1.131443
Sum squared resid	32.14346	Schwarz criterion	-1.100452
Log likelihood	767.7639	Hannan-Quinn criter.	-1.119834
Durbin-Watson stat	1.990537		

Dependent Variable: XWC

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

XWC= C(1) + C(2)*VARGJR + C(3)*XWC(-1) + C(4)*VARGJR*XWC(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.005163	0.005770	0.894908	0.3708
C(2) = θ	-0.471086	0.362759	-1.298620	0.1941
C(3) = ϕ_0	-0.235003	0.031454	-7.471297	0.0000
C(4) = ϕ_1	0.487664	0.452727	1.077172	0.2814
Variance Equation				
C = ω	-2.41E-05	1.38E-05	-1.748044	0.0805
RESID(-1)^2 = β	0.028082	0.003462	8.110458	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	0.056793	0.006514	8.718177	0.0000
GARCH(-1) = δ	0.957186	0.003102	308.5484	0.0000
R-squared	0.039690	Mean dependent var		0.003763
Adjusted R-squared	0.037538	S.D. dependent var		0.127698
S.E. of regression	0.125278	Akaike info criterion		-1.485537
Sum squared resid	21.01503	Schwarz criterion		-1.454546
Log likelihood	1005.538	Hannan-Quinn criter.		-1.473928
Durbin-Watson stat	1.983338			

Dependent Variable: TETHER

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

TETHER = C(1) + C(2)*VARGJRTETHER + C(3)*TETHER(-1) + C(4)

*VARGJRTETHER*TETHER(-1)

GARCH = C(5) + C(6)*RESID(-1)^2 + C(7)*RESID(-1)^2*(RESID(-1)<0) + C(8)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	7.06E-05	3.33E-06	21.20089	0.0000
C(2) = θ	-46.41964	3.106459	-14.94295	0.0000
C(3) = ϕ_0	-2.059121	0.080840	-25.47149	0.0000
C(4) = ϕ_1	27.18399	200.3596	13.56760	0.0000
Variance Equation				
C = ω	-1.41E-09	1.93E-10	-7.293629	0.0000
RESID(-1)^2 = β	0.765167	0.087765	8.718316	0.0000
RESID(-1)^2*(RESID(-1)<0) = λ	1.860870	0.135202	13.76359	0.0000
GARCH(-1) = δ	0.716590	0.009445	75.87022	0.0000
R-squared	-6.546598	Mean dependent var		-1.12E-05
Adjusted R-squared	-6.563506	S.D. dependent var		0.005707
S.E. of regression	0.015694	Akaike info criterion		-11.54304
Sum squared resid	0.329802	Schwarz criterion		-11.51205
Log likelihood	7759.151	Hannan-Quinn criter.		-11.53143
Durbin-Watson stat	1.019876			

7.3.2. Resultados completos do teste de robustez de viés de sinais.

Cryptocurrency analyzed: BAY

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTBAY

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	127.3994	63.60035	2.003124	0.0452
C(2) = θ	-46.30182	110.8133	-0.417836	0.6761
Variance Equation				
C	159352.4	204194.6	0.780395	0.4352
RESID(-1)^2	-0.000977	0.000188	-5.196831	0.0000
RESID(-1)^2*(RESID(-1)<0)	-0.100754	2.745907	-0.036692	0.9707
GARCH(-1)	0.570870	0.549023	1.039794	0.2984
R-squared	0.001436	Mean dependent var		107.3854
Adjusted R-squared	0.000692	S.D. dependent var		569.9955
S.E. of regression	569.7984	Akaike info criterion		15.53296
Sum squared resid	4.36E+08	Schwarz criterion		15.55619
Log likelihood	-10432.15	Hannan-Quinn criter.		15.54167
Durbin-Watson stat	2.016980			

Cryptocurrency analyzed: BBR

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTBBR

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	1880.405	55.79912	33.69954	0.0000
C(2) = θ	-1879.727	274.4440	-6.849219	0.0000
Variance Equation				
C	1867651.	197973.0	9.433870	0.0000
RESID(-1)^2	0.000534	0.004401	0.121253	0.9035
RESID(-1)^2*(RESID(-1)<0)	409.0901	29.09231	14.06179	0.0000
GARCH(-1)	2.15E-05	0.000186	0.115260	0.9082
R-squared	0.000742	Mean dependent var		969.5946
Adjusted R-squared	-0.000002	S.D. dependent var		28884.35
S.E. of regression	28884.38	Akaike info criterion		20.84354
Sum squared resid	1.12E+12	Schwarz criterion		20.86677
Log likelihood	-14000.86	Hannan-Quinn criter.		20.85225
Durbin-Watson stat	1.960895			

Cryptocurrencie analyzed: BCN

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTBCN

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	62.12138	2.568810	24.18294	0.0000
C(2) = θ	78.04765	3.299484	23.65450	0.0000
Variance Equation				
C	-1676.188	1344.494	-1.246706	0.2125
RESID(-1)^2	-0.002199	0.000515	-4.267832	0.0000
RESID(-1)^2*(RESID(-1)<0)	14.98665	1.244973	12.03773	0.0000
GARCH(-1)	0.592032	0.007068	83.76770	0.0000
R-squared	-0.019038	Mean dependent var		134.2147
Adjusted R-squared	-0.019797	S.D. dependent var		483.2947
S.E. of regression	488.0552	Akaike info criterion		14.95864
Sum squared resid	3.20E+08	Schwarz criterion		14.98187
Log likelihood	-10046.21	Hannan-Quinn criter.		14.96734
Durbin-Watson stat	2.033241			

Cryptocurrencie analyzed: BITCNY

Dependent Variable: (RESID/VARGJR)^2

(RESID/VARGJR)^2 = C(1) + C(2)*DTBITCNY

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	35.74250	361.4071	0.098898	0.9212
C(2) = θ	600.8046	358.2897	1.676868	0.0936
Variance Equation				
C	22700348	484594.4	46.84401	0.0000
RESID(-1)^2	-0.000978	0.013696	-0.071425	0.9431
RESID(-1)^2*(RESID(-1)<0)	-55.41098	6.158383	-8.997651	0.0000
GARCH(-1)	0.000596	0.001338	0.445213	0.6562
R-squared	-0.000299	Mean dependent var		263.8977
Adjusted R-squared	-0.001044	S.D. dependent var		4277.814
S.E. of regression	4280.047	Akaike info criterion		18.52859
Sum squared resid	2.46E+10	Schwarz criterion		18.55182
Log likelihood	-12445.21	Hannan-Quinn criter.		18.53729
Durbin-Watson stat	2.002349			

Cryptocurrencie analyzed: BITUSD

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTBITUSD

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	47.83901	0.735273	65.06288	0.0000
C(2) = θ	0.023810	0.013193	1.804705	0.0711
Variance Equation				
C	740395.1	8347.101	88.70087	0.0000
RESID(-1)^2	-0.002248	2.56E-05	-87.83619	0.0000
RESID(-1)^2*(RESID(-1)<0)	-322.3614	6.472333	-49.80606	0.0000
GARCH(-1)	0.007677	0.001018	7.544734	0.0000
R-squared	-0.000530	Mean dependent var		61.83703
Adjusted R-squared	-0.001276	S.D. dependent var		608.4606
S.E. of regression	608.8485	Akaike info criterion		14.68526
Sum squared resid	4.97E+08	Schwarz criterion		14.70849
Log likelihood	-9862.494	Hannan-Quinn criter.		14.69396
Durbin-Watson stat	1.992656			

Cryptocurrencie analyzed: BLK

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTBLK

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	74.22386	13.94215	5.323703	0.0000
C(2) = θ	156.7807	21.60752	7.255837	0.0000
Variance Equation				
C	315657.6	24344.56	12.96625	0.0000
RESID(-1)^2	-0.001762	0.000338	-5.212275	0.0000
RESID(-1)^2*(RESID(-1)<0)	-7.400244	1.294590	-5.716284	0.0000
GARCH(-1)	0.828252	0.013940	59.41546	0.0000
R-squared	-0.016597	Mean dependent var		284.1156
Adjusted R-squared	-0.017354	S.D. dependent var		1104.511
S.E. of regression	1114.054	Akaike info criterion		16.71635
Sum squared resid	1.67E+09	Schwarz criterion		16.73958
Log likelihood	-11227.39	Hannan-Quinn criter.		16.72505
Durbin-Watson stat	1.976900			

Cryptocurrencie analyzed: BLOCK

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTBLOCK

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	80.54757	2.092521	38.49307	0.0000
C(2) = θ	-0.507224	0.266823	-1.900973	0.0573
Variance Equation				
C	149345.7	1043.417	143.1314	0.0000
RESID(-1)^2	-0.003413	0.000515	-6.630545	0.0000
RESID(-1)^2*(RESID(-1)<0)	-23.32107	1.228519	-18.98307	0.0000
GARCH(-1)	0.305375	0.005024	60.77743	0.0000
R-squared	-0.001171	Mean dependent var		69.75347
Adjusted R-squared	-0.001917	S.D. dependent var		307.9868
S.E. of regression	308.2818	Akaike info criterion		14.04736
Sum squared resid	1.28E+08	Schwarz criterion		14.07059
Log likelihood	-9433.824	Hannan-Quinn criter.		14.05606
Durbin-Watson stat	2.034494			

Cryptocurrencie analyzed: BTC

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTBTC

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	1604.789	0.216629	7408.019	0.0000
C(2) = θ	-816.9756	36.57258	-22.33847	0.0000
Variance Equation				
C	2675669.	97365.07	27.48079	0.0000
RESID(-1)^2	-0.002001	5.64E-05	-35.45060	0.0000
RESID(-1)^2*(RESID(-1)<0)	-2.041234	0.065163	-31.32487	0.0000
GARCH(-1)	0.986565	0.000610	1616.689	0.0000
R-squared	-0.005289	Mean dependent var		1423.066
Adjusted R-squared	-0.006038	S.D. dependent var		6720.945
S.E. of regression	6741.205	Akaike info criterion		19.91184
Sum squared resid	6.10E+10	Schwarz criterion		19.93507
Log likelihood	-13374.75	Hannan-Quinn criter.		19.92054
Durbin-Watson stat	1.971029			

Cryptocurrencie analyzed: BTSDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTBTSGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	162.3752	9.402665	17.26906	0.0000
C(2) = θ	-1.175797	0.388668	-3.025197	0.0025
Variance Equation				
C	2264033.	37197.92	60.86451	0.0000
RESID(-1) ²	-0.001575	0.000663	-2.374194	0.0176
RESID(-1) ² *(RESID(-1)<0)	-87.01784	8.923420	-9.751624	0.0000
GARCH(-1)	0.244837	0.008145	30.05964	0.0000
R-squared	-0.008214	Mean dependent var		287.3515
Adjusted R-squared	-0.008965	S.D. dependent var		1384.612
S.E. of regression	1390.804	Akaike info criterion		16.76992
Sum squared resid	2.60E+09	Schwarz criterion		16.79315
Log likelihood	-11263.38	Hannan-Quinn criter.		16.77862
Durbin-Watson stat	1.979642			

Cryptocurrencie analyzed: BURSTDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTBURSTGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	182.1084	20.06173	9.077400	0.0000
C(2) = θ	-39.04813	5.556966	-7.026879	0.0000
Variance Equation				
C	228958.1	8191.308	27.95135	0.0000
RESID(-1) ²	-0.002415	0.004215	-0.573032	0.5666
RESID(-1) ² *(RESID(-1)<0)	-3.344830	0.739249	-4.524633	0.0000
GARCH(-1)	-0.066846	0.045524	-1.468368	0.1420
R-squared	-0.002352	Mean dependent var		153.8633
Adjusted R-squared	-0.003098	S.D. dependent var		412.0092
S.E. of regression	412.6470	Akaike info criterion		14.85776
Sum squared resid	2.29E+08	Schwarz criterion		14.88099
Log likelihood	-9978.417	Hannan-Quinn criter.		14.86647
Durbin-Watson stat	2.113088			

Cryptocurrencie analyzed: CLOAK

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTCLOAK

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	105.5127	5.282545	19.97384	0.0000
C(2) = θ	-89.32145	16.82313	-5.309443	0.0000
Variance Equation				
C	49293.05	2214.810	22.25611	0.0000
RESID(-1)^2	-0.001179	0.000554	-2.128082	0.0333
RESID(-1)^2*(RESID(-1)<0)	-4.874828	0.529502	-9.206432	0.0000
GARCH(-1)	0.600178	0.020956	28.63993	0.0000
R-squared	-0.021437	Mean dependent var		67.16441
Adjusted R-squared	-0.022198	S.D. dependent var		313.0088
S.E. of regression	316.4639	Akaike info criterion		14.19119
Sum squared resid	1.34E+08	Schwarz criterion		14.21442
Log likelihood	-9530.480	Hannan-Quinn criter.		14.19989
Durbin-Watson stat	2.040088			

Cryptocurrencie analyzed: CRW

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTCRW

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	6.234521	0.896109	6.957328	0.0000
C(2) = θ	1.631801	0.333516	4.892715	0.0000
Variance Equation				
C	328.4166	22.44173	14.63419	0.0000
RESID(-1)^2	-0.005867	0.000237	-24.75958	0.0000
RESID(-1)^2*(RESID(-1)<0)	-9.089481	2.076341	-4.377645	0.0000
GARCH(-1)	1.001844	4.21E-05	23804.94	0.0000
R-squared	-0.077710	Mean dependent var		55.90116
Adjusted R-squared	-0.078513	S.D. dependent var		175.3634
S.E. of regression	182.1175	Akaike info criterion		12.33351
Sum squared resid	44509826	Schwarz criterion		12.35674
Log likelihood	-8282.119	Hannan-Quinn criter.		12.34221
Durbin-Watson stat	1.632340			

Cryptocurrencie analyzed: CSCDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTSCGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	0.829143	0.003444	240.7833	0.0000
C(2) = θ	-0.742958	0.003408	-218.0050	0.0000
Variance Equation				
C	178.0558	2.915575	61.07057	0.0000
RESID(-1) ²	0.056401	0.014502	3.889228	0.0001
RESID(-1) ² *(RESID(-1)<0)	320460.4	3237.885	98.97214	0.0000
GARCH(-1)	0.006553	0.000153	42.70986	0.0000
R-squared	-0.002932	Mean dependent var		15.14952
Adjusted R-squared	-0.003679	S.D. dependent var		269.4042
S.E. of regression	269.8993	Akaike info criterion		10.25425
Sum squared resid	97758821	Schwarz criterion		10.27748
Log likelihood	-6884.853	Hannan-Quinn criter.		10.26295
Durbin-Watson stat	1.263100			

Cryptocurrencie analyzed: DASHDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTDASHGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	381.1268	12.77238	29.83992	0.0000
C(2) = θ	-43.79427	2.943109	-14.88028	0.0000
Variance Equation				
C	3647454.	27410.18	133.0693	0.0000
RESID(-1) ²	-0.004394	0.001246	-3.526300	0.0004
RESID(-1) ² *(RESID(-1)<0)	-20.69383	1.421851	-14.55415	0.0000
GARCH(-1)	-0.167711	0.017658	-9.497976	0.0000
R-squared	-0.003851	Mean dependent var		441.6867
Adjusted R-squared	-0.004599	S.D. dependent var		1479.824
S.E. of regression	1483.223	Akaike info criterion		17.09633
Sum squared resid	2.95E+09	Schwarz criterion		17.11956
Log likelihood	-11482.74	Hannan-Quinn criter.		17.10504
Durbin-Watson stat	2.022602			

Cryptocurrencie analyzed: DGBDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTDGBGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	72.81839	6.036803	12.06241	0.0000
C(2) = θ	21.84438	2.078799	10.50818	0.0000
Variance Equation				
C	36354.81	566.8060	64.13978	0.0000
RESID(-1) ²	-0.003980	0.000137	-28.96904	0.0000
RESID(-1) ² *(RESID(-1)<0)	-5.773962	0.714694	-8.078925	0.0000
GARCH(-1)	0.960798	0.000210	4577.724	0.0000
R-squared	-0.024054	Mean dependent var		184.9826
Adjusted R-squared	-0.024817	S.D. dependent var		641.2341
S.E. of regression	649.1422	Akaike info criterion		15.55042
Sum squared resid	5.65E+08	Schwarz criterion		15.57365
Log likelihood	-10443.88	Hannan-Quinn criter.		15.55912
Durbin-Watson stat	1.887893			

Cryptocurrencie analyzed: DMDDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTDMDGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	165.9167	4.020695	41.26567	0.0000
C(2) = θ	5.126025	1.568913	3.267245	0.0011
Variance Equation				
C	143738.3	6986.006	20.57518	0.0000
RESID(-1) ²	-0.000529	0.001296	-0.408059	0.6832
RESID(-1) ² *(RESID(-1)<0)	17.93293	0.944371	18.98929	0.0000
GARCH(-1)	-0.070195	0.016095	-4.361188	0.0000
R-squared	-0.001458	Mean dependent var		192.1740
Adjusted R-squared	-0.002204	S.D. dependent var		609.1847
S.E. of regression	609.8557	Akaike info criterion		15.46394
Sum squared resid	4.99E+08	Schwarz criterion		15.48717
Log likelihood	-10385.77	Hannan-Quinn criter.		15.47264
Durbin-Watson stat	2.020343			

Cryptocurrencie analyzed: DOGE

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTDOGE

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	206.7928	23.84051	8.674010	0.0000
C(2) = θ	574.6752	40.96110	14.02978	0.0000
Variance Equation				
C	6878488.	124293.7	55.34061	0.0000
RESID(-1)^2	-0.003417	0.001615	-2.116459	0.0343
RESID(-1)^2*(RESID(-1)<0)	-11.33940	1.291221	-8.781919	0.0000
GARCH(-1)	0.180577	0.010056	17.95777	0.0000
R-squared	-0.014802	Mean dependent var		664.6934
Adjusted R-squared	-0.015558	S.D. dependent var		2486.601
S.E. of regression	2505.870	Akaike info criterion		18.18210
Sum squared resid	8.43E+09	Schwarz criterion		18.20533
Log likelihood	-12212.37	Hannan-Quinn criter.		18.19080
Durbin-Watson stat	1.972583			

Cryptocurrencie analyzed: ECC

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTECC

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	4.498586	0.561345	8.013947	0.0000
C(2) = θ	-2.273047	0.479233	-4.743096	0.0000
Variance Equation				
C	-12.40362	0.925636	-13.40011	0.0000
RESID(-1)^2	0.179973	0.008369	21.50479	0.0000
RESID(-1)^2*(RESID(-1)<0)	1.786546	0.480060	3.721503	0.0002
GARCH(-1)	0.909420	0.001827	497.8140	0.0000
R-squared	-0.099242	Mean dependent var		21.81984
Adjusted R-squared	-0.100061	S.D. dependent var		58.28916
S.E. of regression	61.13589	Akaike info criterion		9.710529
Sum squared resid	5015855.	Schwarz criterion		9.733759
Log likelihood	-6519.476	Hannan-Quinn criter.		9.719231
Durbin-Watson stat	1.257302			

Cryptocurrencie analyzed: EMC2

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTEM C2

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	54.96185	0.031047	1770.296	0.0000
C(2) = θ	51.95170	4.951155	10.49284	0.0000
Variance Equation				
C	5010.685	101.0679	49.57741	0.0000
RESID(-1)^2	-0.002003	3.13E-05	-63.91534	0.0000
RESID(-1)^2*(RESID(-1)<0)	-1.242953	0.119147	-10.43207	0.0000
GARCH(-1)	0.998764	9.35E-05	10683.96	0.0000
R-squared	-0.010540	Mean dependent var		101.3021
Adjusted R-squared	-0.011293	S.D. dependent var		360.9689
S.E. of regression	363.0013	Akaike info criterion		14.36746
Sum squared resid	1.77E+08	Schwarz criterion		14.39069
Log likelihood	-9648.936	Hannan-Quinn criter.		14.37617
Durbin-Watson stat	2.063300			

Cryptocurrencie analyzed: ETH

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTETH

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	339.1115	17.10210	19.82865	0.0000
C(2) = θ	182.7546	7.893894	23.15138	0.0000
Variance Equation				
C	41865.56	24390.41	1.716476	0.0861
RESID(-1)^2	-0.001908	0.000789	-2.417619	0.0156
RESID(-1)^2*(RESID(-1)<0)	4.746782	0.440210	10.78299	0.0000
GARCH(-1)	0.565275	0.014156	39.93079	0.0000
R-squared	-0.003375	Mean dependent var		341.8864
Adjusted R-squared	-0.004122	S.D. dependent var		1161.605
S.E. of regression	1163.997	Akaike info criterion		16.89416
Sum squared resid	1.82E+09	Schwarz criterion		16.91739
Log likelihood	-11346.87	Hannan-Quinn criter.		16.90286
Durbin-Watson stat	2.024206			

Cryptocurrencie analyzed: FLO

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTFLO

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	57.48165	2.012000	28.56941	0.0000
C(2) = θ	52.39302	2.744019	19.09353	0.0000
Variance Equation				
C	1441.571	722.7518	1.994559	0.0461
RESID(-1)^2	-0.001319	0.000759	-1.739315	0.0820
RESID(-1)^2*(RESID(-1)<0)	10.33297	0.738497	13.99190	0.0000
GARCH(-1)	0.454043	0.009012	50.38309	0.0000
R-squared	-0.004198	Mean dependent var		98.08236
Adjusted R-squared	-0.004946	S.D. dependent var		273.2405
S.E. of regression	273.9154	Akaike info criterion		13.87563
Sum squared resid	1.01E+08	Schwarz criterion		13.89886
Log likelihood	-9318.422	Hannan-Quinn criter.		13.88433
Durbin-Watson stat	2.040841			

Cryptocurrencie analyzed:FTC

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTFTC

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	64.58201	1.147028	56.30378	0.0000
C(2) = θ	-62.12125	10.99319	-5.650883	0.0000
Variance Equation				
C	99510.62	1390.122	71.58407	0.0000
RESID(-1)^2	-0.000205	0.000822	-0.249549	0.8029
RESID(-1)^2*(RESID(-1)<0)	271.4771	9.944009	27.30057	0.0000
GARCH(-1)	-0.024132	0.001900	-12.70062	0.0000
R-squared	-0.028329	Mean dependent var		129.1016
Adjusted R-squared	-0.029096	S.D. dependent var		625.8571
S.E. of regression	634.8966	Akaike info criterion		14.94923
Sum squared resid	5.41E+08	Schwarz criterion		14.97246
Log likelihood	-10039.88	Hannan-Quinn criter.		14.95793
Durbin-Watson stat	1.998597			

Cryptocurrencie analyzed: GAME

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTGAME

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	64.43318	11.81335	5.454267	0.0000
C(2) = θ	43.26291	5.660511	7.642933	0.0000
Variance Equation				
C	35224.18	3430.510	10.26792	0.0000
RESID(-1)^2	-0.003771	0.000180	-20.91988	0.0000
RESID(-1)^2*(RESID(-1)<0)	-4.497040	1.129387	-3.981843	0.0001
GARCH(-1)	0.899283	0.007285	123.4469	0.0000
R-squared	-0.015369	Mean dependent var		137.8997
Adjusted R-squared	-0.016125	S.D. dependent var		416.8668
S.E. of regression	420.2144	Akaike info criterion		14.79625
Sum squared resid	2.37E+08	Schwarz criterion		14.81948
Log likelihood	-9937.078	Hannan-Quinn criter.		14.80495
Durbin-Watson stat	1.862231			

Cryptocurrencie analyzed: GRS

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTGRS

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	30.28080	0.766489	39.50583	0.0000
C(2) = θ	20.21111	0.422746	47.80915	0.0000
Variance Equation				
C	12558.30	297.6483	42.19173	0.0000
RESID(-1)^2	-0.000313	0.000116	-2.690694	0.0071
RESID(-1)^2*(RESID(-1)<0)	86.39708	5.003125	17.26862	0.0000
GARCH(-1)	-0.028245	0.002682	-10.52997	0.0000
R-squared	-0.012777	Mean dependent var		67.30900
Adjusted R-squared	-0.013532	S.D. dependent var		280.1739
S.E. of regression	282.0633	Akaike info criterion		13.68059
Sum squared resid	1.07E+08	Schwarz criterion		13.70382
Log likelihood	-9187.357	Hannan-Quinn criter.		13.68929
Durbin-Watson stat	2.024481			

Cryptocurrencie analyzed: LTCDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTLTCGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	101.9153	1.329211	76.67350	0.0000
C(2) = θ	-100.8091	30.54162	-3.300712	0.0010
Variance Equation				
C	705070.4	11021.54	63.97202	0.0000
RESID(-1) ²	0.418501	0.022042	18.98676	0.0000
RESID(-1) ² *(RESID(-1)<0)	6393.119	206.2651	30.99467	0.0000
GARCH(-1)	0.128552	0.001648	78.01783	0.0000
R-squared	-0.014207	Mean dependent var		489.7782
Adjusted R-squared	-0.014962	S.D. dependent var		3601.247
S.E. of regression	3628.089	Akaike info criterion		18.35411
Sum squared resid	1.77E+10	Schwarz criterion		18.37734
Log likelihood	-12327.96	Hannan-Quinn criter.		18.36281
Durbin-Watson stat	1.976360			

Cryptocurrencie analyzed: MAIDDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTMAIDGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	204.2358	17.63382	11.58205	0.0000
C(2) = θ	83.81121	11.96666	7.003725	0.0000
Variance Equation				
C	-7970.251	1274.637	-6.252959	0.0000
RESID(-1) ²	-0.007111	0.000183	-38.85430	0.0000
RESID(-1) ² *(RESID(-1)<0)	0.740584	0.146205	5.065379	0.0000
GARCH(-1)	0.971215	0.002158	450.1005	0.0000
R-squared	-0.002984	Mean dependent var		256.8481
Adjusted R-squared	-0.003731	S.D. dependent var		625.0480
S.E. of regression	626.2131	Akaike info criterion		15.64632
Sum squared resid	5.26E+08	Schwarz criterion		15.66955
Log likelihood	-10508.33	Hannan-Quinn criter.		15.65502
Durbin-Watson stat	2.018879			

Cryptocurrencie analyzed: MONA

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTMONA

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	112.9468	14.57957	7.746926	0.0000
C(2) = θ	359.2571	69.19375	5.192045	0.0000
Variance Equation				
C	-18697.10	5190.278	-3.602331	0.0003
RESID(-1)^2	-0.002268	8.71E-05	-26.04867	0.0000
RESID(-1)^2*(RESID(-1)<0)	3.572883	1.086823	3.287456	0.0010
GARCH(-1)	0.881002	0.006777	130.0072	0.0000
R-squared	-0.017334	Mean dependent var		367.5009
Adjusted R-squared	-0.018092	S.D. dependent var		1550.890
S.E. of regression	1564.856	Akaike info criterion		17.34254
Sum squared resid	3.29E+09	Schwarz criterion		17.36577
Log likelihood	-11648.19	Hannan-Quinn criter.		17.35124
Durbin-Watson stat	2.056968			

Cryptocurrencie analyzed: NAV

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTNAV

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	100.4403	3.840883	26.15033	0.0000
C(2) = θ	-9.235996	2.018124	-4.576525	0.0000
Variance Equation				
C	592.4241	1017.994	0.581953	0.5606
RESID(-1)^2	-0.001117	0.000788	-1.418406	0.1561
RESID(-1)^2*(RESID(-1)<0)	15.03228	1.279877	11.74510	0.0000
GARCH(-1)	0.337952	0.022379	15.10137	0.0000
R-squared	-0.002154	Mean dependent var		109.0999
Adjusted R-squared	-0.002901	S.D. dependent var		327.3001
S.E. of regression	327.7745	Akaike info criterion		14.15234
Sum squared resid	1.44E+08	Schwarz criterion		14.17557
Log likelihood	-9504.370	Hannan-Quinn criter.		14.16104
Durbin-Watson stat	2.084796			

Cryptocurrencie analyzed: NLG

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTNLG

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	237.3777	4.232889	56.07936	0.0000
C(2) = θ	-193.3394	6.259659	-30.88657	0.0000
Variance Equation				
C	148702.8	5288.993	28.11552	0.0000
RESID(-1)^2	-0.001037	0.001132	-0.916188	0.3596
RESID(-1)^2*(RESID(-1)<0)	22.35472	0.915667	24.41359	0.0000
GARCH(-1)	0.187062	0.008095	23.10838	0.0000
R-squared	-0.030285	Mean dependent var		202.5427
Adjusted R-squared	-0.031053	S.D. dependent var		754.0186
S.E. of regression	765.6363	Akaike info criterion		15.84925
Sum squared resid	7.87E+08	Schwarz criterion		15.87248
Log likelihood	-10644.69	Hannan-Quinn criter.		15.85795
Durbin-Watson stat	2.058150			

Cryptocurrencie analyzed: NMC

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTNMC

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) + C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	308.1622	15.48535	19.90024	0.0000
C(2) = θ	-14.29665	3.514743	-4.067622	0.0000
Variance Equation				
C	980107.9	29692.13	33.00902	0.0000
RESID(-1)^2	-0.005303	0.000307	-17.28077	0.0000
RESID(-1)^2*(RESID(-1)<0)	-10.90103	1.003449	-10.86356	0.0000
GARCH(-1)	0.748178	0.006695	111.7490	0.0000
R-squared	-0.001029	Mean dependent var		339.8648
Adjusted R-squared	-0.001775	S.D. dependent var		1349.199
S.E. of regression	1350.396	Akaike info criterion		16.92447
Sum squared resid	2.45E+09	Schwarz criterion		16.94770
Log likelihood	-11367.24	Hannan-Quinn criter.		16.93317
Durbin-Watson stat	1.964113			

Cryptocurrencie analyzed: NVC

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTNVC

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	217.0804	30.88286	7.029154	0.0000
C(2) = θ	161.3231	20.48303	7.875939	0.0000
Variance Equation				
C	1345636.	48918.04	27.50797	0.0000
RESID(-1)^2	-0.001315	0.000122	-10.75725	0.0000
RESID(-1)^2*(RESID(-1)<0)	-11.74603	3.262293	-3.600543	0.0003
GARCH(-1)	0.838538	0.009807	85.50321	0.0000
R-squared	-0.003030	Mean dependent var		327.5938
Adjusted R-squared	-0.003777	S.D. dependent var		1919.642
S.E. of regression	1923.264	Akaike info criterion		17.90875
Sum squared resid	4.96E+09	Schwarz criterion		17.93198
Log likelihood	-12028.68	Hannan-Quinn criter.		17.91745
Durbin-Watson stat	1.964728			

Cryptocurrencie analyzed: NXS

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTNXXS

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	79.53248	6.501887	12.23222	0.0000
C(2) = θ	27.43901	2.243842	12.22858	0.0000
Variance Equation				
C	5584.400	1368.485	4.080718	0.0000
RESID(-1)^2	-0.002583	0.000754	-3.425112	0.0006
RESID(-1)^2*(RESID(-1)<0)	3.318195	0.543447	6.105831	0.0000
GARCH(-1)	0.644055	0.022308	28.87067	0.0000
R-squared	-0.009680	Mean dependent var		89.48625
Adjusted R-squared	-0.010433	S.D. dependent var		245.4505
S.E. of regression	246.7276	Akaike info criterion		13.81106
Sum squared resid	81693567	Schwarz criterion		13.83429
Log likelihood	-9275.033	Hannan-Quinn criter.		13.81976
Durbin-Watson stat	2.027036			

Cryptocurrencie analyzed: NXT

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTNXT

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	292.0566	1.984811	147.1458	0.0000
C(2) = θ	-66.20545	5.779174	-11.45587	0.0000
Variance Equation				
C	134902.9	7273.292	18.54771	0.0000
RESID(-1)^2	-0.007034	0.000262	-26.79633	0.0000
RESID(-1)^2*(RESID(-1)<0)	-2.467313	0.108637	-22.71150	0.0000
GARCH(-1)	0.950556	0.002894	328.4929	0.0000
R-squared	-0.008204	Mean dependent var		343.2220
Adjusted R-squared	-0.008955	S.D. dependent var		1016.125
S.E. of regression	1020.665	Akaike info criterion		16.40874
Sum squared resid	1.40E+09	Schwarz criterion		16.43197
Log likelihood	-11020.67	Hannan-Quinn criter.		16.41744
Durbin-Watson stat	1.967083			

Cryptocurrencie analyzed: POT

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTPOT

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	134.7560	1.207808	111.5707	0.0000
C(2) = θ	-41.78791	2.400026	-17.41144	0.0000
Variance Equation				
C	194857.5	7922.490	24.59549	0.0000
RESID(-1)^2	-0.002841	0.000551	-5.156649	0.0000
RESID(-1)^2*(RESID(-1)<0)	-11.75720	0.437824	-26.85369	0.0000
GARCH(-1)	0.409378	0.030836	13.27604	0.0000
R-squared	-0.014833	Mean dependent var		163.0148
Adjusted R-squared	-0.015589	S.D. dependent var		462.5980
S.E. of regression	466.1899	Akaike info criterion		15.01161
Sum squared resid	2.92E+08	Schwarz criterion		15.03484
Log likelihood	-10081.80	Hannan-Quinn criter.		15.02031
Durbin-Watson stat	2.081783			

Cryptocurrencie analyzed: PPCDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTPPCGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	469.1626	13.75488	34.10882	0.0000
C(2) = θ	-186.9422	7.133195	-26.20736	0.0000
Variance Equation				
C	367685.2	17717.37	20.75281	0.0000
RESID(-1) ²	-0.004816	0.000889	-5.415786	0.0000
RESID(-1) ² *(RESID(-1)<0)	-2.524345	0.104396	-24.18039	0.0000
GARCH(-1)	0.911470	0.004418	206.3141	0.0000
R-squared	-0.003044	Mean dependent var		402.1491
Adjusted R-squared	-0.003791	S.D. dependent var		1404.489
S.E. of regression	1407.149	Akaike info criterion		17.04963
Sum squared resid	2.66E+09	Schwarz criterion		17.07286
Log likelihood	-11451.35	Hannan-Quinn criter.		17.05833
Durbin-Watson stat	1.967940			

Cryptocurrencie analyzed: RDDDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTRDDGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	60.31470	6.795402	8.875810	0.0000
C(2) = θ	52.23220	8.797163	5.937391	0.0000
Variance Equation				
C	17341.35	1184.531	14.63984	0.0000
RESID(-1) ²	0.018673	0.002230	8.372587	0.0000
RESID(-1) ² *(RESID(-1)<0)	-1.407816	0.308974	-4.556425	0.0000
GARCH(-1)	0.683698	0.021083	32.42827	0.0000
R-squared	-0.005272	Mean dependent var		87.95690
Adjusted R-squared	-0.006022	S.D. dependent var		201.1261
S.E. of regression	201.7307	Akaike info criterion		13.39234
Sum squared resid	54613053	Schwarz criterion		13.41557
Log likelihood	-8993.655	Hannan-Quinn criter.		13.40104
Durbin-Watson stat	1.911457			

Cryptocurrencie analyzed: SYS

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTSYS

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	35.85412	0.882649	40.62102	0.0000
C(2) = θ	-5.085202	0.371430	-13.69086	0.0000
Variance Equation				
C	4876.734	784.0082	6.220258	0.0000
RESID(-1)^2	-0.002140	8.90E-05	-24.04562	0.0000
RESID(-1)^2*(RESID(-1)<0)	242.4042	10.72564	22.60044	0.0000
GARCH(-1)	0.606298	0.009615	63.06006	0.0000
R-squared	-0.055334	Mean dependent var		136.5412
Adjusted R-squared	-0.056120	S.D. dependent var		439.0277
S.E. of regression	451.1787	Akaike info criterion		14.85328
Sum squared resid	2.73E+08	Schwarz criterion		14.87651
Log likelihood	-9975.403	Hannan-Quinn criter.		14.86198
Durbin-Watson stat	1.936184			

Cryptocurrencie analyzed: UBQ

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTUBQ

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	36.27716	2.730712	13.28487	0.0000
C(2) = θ	22.09007	0.712900	30.98623	0.0000
Variance Equation				
C	224740.9	4528.638	49.62660	0.0000
RESID(-1)^2	0.412134	0.026535	15.53167	0.0000
RESID(-1)^2*(RESID(-1)<0)	-49.68540	4.116678	-12.06929	0.0000
GARCH(-1)	-0.001244	0.004197	-0.296342	0.7670
R-squared	-0.033081	Mean dependent var		133.6450
Adjusted R-squared	-0.033851	S.D. dependent var		471.2944
S.E. of regression	479.2049	Akaike info criterion		14.89755
Sum squared resid	3.08E+08	Schwarz criterion		14.92078
Log likelihood	-10005.15	Hannan-Quinn criter.		14.90625
Durbin-Watson stat	1.728382			

Cryptocurrencie analyzed: UNO

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTUNO

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	239.4187	101.4466	2.360045	0.0183
C(2) = θ	-116.8506	113.3194	-1.031162	0.3025
Variance Equation				
C	376249.8	443063.1	0.849201	0.3958
RESID(-1)^2	-0.001141	0.000266	-4.293923	0.0000
RESID(-1)^2*(RESID(-1)<0)	0.161635	0.380033	0.425317	0.6706
GARCH(-1)	0.567579	0.512172	1.108180	0.2678
R-squared	-0.000776	Mean dependent var		196.6231
Adjusted R-squared	-0.001522	S.D. dependent var		892.4165
S.E. of regression	893.0954	Akaike info criterion		16.42026
Sum squared resid	1.07E+09	Schwarz criterion		16.44349
Log likelihood	-11028.41	Hannan-Quinn criter.		16.42896
Durbin-Watson stat	1.995666			

Cryptocurrencie analyzed: VIA

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTVIA

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	159.8922	16.86149	9.482686	0.0000
C(2) = θ	-73.51553	10.08085	-7.292595	0.0000
Variance Equation				
C	15993.42	784.6779	20.38215	0.0000
RESID(-1)^2	-0.008174	0.000468	-17.45356	0.0000
RESID(-1)^2*(RESID(-1)<0)	-0.942332	0.215050	-4.381918	0.0000
GARCH(-1)	0.937761	0.003701	253.3642	0.0000
R-squared	-0.009233	Mean dependent var		129.8719
Adjusted R-squared	-0.009985	S.D. dependent var		338.7660
S.E. of regression	340.4531	Akaike info criterion		14.42472
Sum squared resid	1.56E+08	Schwarz criterion		14.44795
Log likelihood	-9687.413	Hannan-Quinn criter.		14.43342
Durbin-Watson stat	2.040297			

Cryptocurrencie analyzed: VTC

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTVTC

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	134.4100	4.250539	31.62188	0.0000
C(2) = θ	28.57653	1.654803	17.26884	0.0000
Variance Equation				
C	-2495.741	3021.001	-0.826131	0.4087
RESID(-1)^2	-0.001972	0.000268	-7.345192	0.0000
RESID(-1)^2*(RESID(-1)<0)	15.51285	1.019617	15.21439	0.0000
GARCH(-1)	0.494729	0.008276	59.77865	0.0000
R-squared	-0.002609	Mean dependent var		171.3082
Adjusted R-squared	-0.003356	S.D. dependent var		617.7159
S.E. of regression	618.7515	Akaike info criterion		15.47616
Sum squared resid	5.14E+08	Schwarz criterion		15.49939
Log likelihood	-10393.98	Hannan-Quinn criter.		15.48486
Durbin-Watson stat	2.004709			

Cryptocurrencie analyzed: XCP

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTXCP

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	175.1002	11.09074	15.78796	0.0000
C(2) = θ	-25.64079	3.444581	-7.443805	0.0000
Variance Equation				
C	95960.86	2733.023	35.11162	0.0000
RESID(-1)^2	-0.002826	0.001388	-2.036174	0.0417
RESID(-1)^2*(RESID(-1)<0)	-3.465966	0.496559	-6.979965	0.0000
GARCH(-1)	0.686270	0.012586	54.52520	0.0000
R-squared	-0.001635	Mean dependent var		152.7551
Adjusted R-squared	-0.002381	S.D. dependent var		410.6347
S.E. of regression	411.1233	Akaike info criterion		14.70985
Sum squared resid	2.27E+08	Schwarz criterion		14.73308
Log likelihood	-9879.018	Hannan-Quinn criter.		14.71855
Durbin-Watson stat	1.892794			

Cryptocurrencie analyzed: XDN

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTXDN

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	105.8521	4.788592	22.10506	0.0000
C(2) = θ	-0.414057	0.751684	-0.550839	0.5817
Variance Equation				
C	108887.1	1711.385	63.62514	0.0000
RESID(-1)^2	-0.004919	0.000440	-11.18232	0.0000
RESID(-1)^2*(RESID(-1)<0)	-9.909877	0.934980	-10.59902	0.0000
GARCH(-1)	0.661462	0.007411	89.25898	0.0000
R-squared	-0.003235	Mean dependent var		127.9535
Adjusted R-squared	-0.003982	S.D. dependent var		390.3437
S.E. of regression	391.1202	Akaike info criterion		14.67067
Sum squared resid	2.05E+08	Schwarz criterion		14.69389
Log likelihood	-9852.687	Hannan-Quinn criter.		14.67937
Durbin-Watson stat	2.018257			

Cryptocurrencie analyzed: XLM

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTXLM

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	840.9433	31.22787	26.92925	0.0000
C(2) = θ	-825.9767	130.1181	-6.347900	0.0000
Variance Equation				
C	1322638.	155563.2	8.502258	0.0000
RESID(-1)^2	-0.000908	2.85E-05	-31.87228	0.0000
RESID(-1)^2*(RESID(-1)<0)	-2.161527	0.169455	-12.75578	0.0000
GARCH(-1)	0.712879	0.037006	19.26364	0.0000
R-squared	-0.040630	Mean dependent var		281.9823
Adjusted R-squared	-0.041405	S.D. dependent var		1815.609
S.E. of regression	1852.815	Akaike info criterion		17.62274
Sum squared resid	4.61E+09	Schwarz criterion		17.64597
Log likelihood	-11836.48	Hannan-Quinn criter.		17.63145
Durbin-Watson stat	2.030085			

Cryptocurrencie analyzed: XMRDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTXMRGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	338.9466	26.60048	12.74213	0.0000
C(2) = θ	-163.3454	16.19895	-10.08371	0.0000
Variance Equation				
C	1360404.	10372.29	131.1576	0.0000
RESID(-1) ²	-0.002279	0.000671	-3.394935	0.0007
RESID(-1) ² *(RESID(-1)<0)	-2.900670	0.508341	-5.706147	0.0000
GARCH(-1)	-0.856351	0.008806	-97.24346	0.0000
R-squared	-0.009824	Mean dependent var		283.6088
Adjusted R-squared	-0.010577	S.D. dependent var		829.1822
S.E. of regression	833.5557	Akaike info criterion		16.18965
Sum squared resid	9.32E+08	Schwarz criterion		16.21287
Log likelihood	-10873.44	Hannan-Quinn criter.		16.19835
Durbin-Watson stat	2.008931			

Cryptocurrencie analyzed: XPMDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTXPMGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	205.3599	6.756829	30.39294	0.0000
C(2) = θ	-50.65933	1.813141	-27.94010	0.0000
Variance Equation				
C	1653547.	13460.42	122.8450	0.0000
RESID(-1) ²	-0.002173	0.004028	-0.539576	0.5895
RESID(-1) ² *(RESID(-1)<0)	-38.77133	2.520021	-15.38532	0.0000
GARCH(-1)	0.044047	0.006752	6.523489	0.0000
R-squared	-0.001388	Mean dependent var		228.0205
Adjusted R-squared	-0.002134	S.D. dependent var		1025.123
S.E. of regression	1026.216	Akaike info criterion		16.32462
Sum squared resid	1.41E+09	Schwarz criterion		16.34785
Log likelihood	-10964.14	Hannan-Quinn criter.		16.33332
Durbin-Watson stat	1.979022			

Cryptocurrencie analyzed: XRPDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTXRPGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	327.2099	7.348509	44.52739	0.0000
C(2) = θ	131.1377	10.79017	12.15344	0.0000
Variance Equation				
C	-118229.1	2034.360	-58.11612	0.0000
RESID(-1) ²	-0.001454	1.88E-05	-77.22486	0.0000
RESID(-1) ² *(RESID(-1)<0)	1.486370	0.092904	15.99906	0.0000
GARCH(-1)	0.997424	9.50E-05	10494.66	0.0000
R-squared	-0.001604	Mean dependent var		493.7069
Adjusted R-squared	-0.002350	S.D. dependent var		2583.883
S.E. of regression	2586.918	Akaike info criterion		17.95581
Sum squared resid	8.98E+09	Schwarz criterion		17.97904
Log likelihood	-12060.31	Hannan-Quinn criter.		17.96452
Durbin-Watson stat	2.028087			

Cryptocurrencie analyzed: XVGDependent Variable: (RESID/VARGJR)²

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)² = C(1) + C(2)*DTXVGGARCH = C(3) + C(4)*RESID(-1)² + C(5)*RESID(-1)²*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	72.35973	3.642559	19.86508	0.0000
C(2) = θ	-42.72670	2.484856	-17.19484	0.0000
Variance Equation				
C	-2028.127	162.3461	-12.49261	0.0000
RESID(-1) ²	-0.001776	0.000140	-12.69310	0.0000
RESID(-1) ² *(RESID(-1)<0)	3.554444	0.488827	7.271372	0.0000
GARCH(-1)	0.876882	0.009736	90.06341	0.0000
R-squared	0.001652	Mean dependent var		61.31353
Adjusted R-squared	0.000908	S.D. dependent var		212.1235
S.E. of regression	212.0272	Akaike info criterion		13.25718
Sum squared resid	60330302	Schwarz criterion		13.28041
Log likelihood	-8902.824	Hannan-Quinn criter.		13.26588
Durbin-Watson stat	2.017520			

Cryptocurrencie analyzed: XWC

Dependent Variable: (RESID/VARGJR)^2

Method: ML ARCH - Normal distribution (BFGS / Marquardt steps)

(RESID/VARGJR)^2 = C(1) + C(2)*DTXWC

GARCH = C(3) + C(4)*RESID(-1)^2 + C(5)*RESID(-1)^2*(RESID(-1)<0) +

C(6)*GARCH(-1)

Variable	Coefficient	Std. Error	z-Statistic	Prob.
C(1) = α	97.87884	13.49609	7.252385	0.0000
C(2) = θ	-82.31093	6.069875	-13.56056	0.0000
Variance Equation				
C	33032.28	2840.038	11.63093	0.0000
RESID(-1)^2	-0.001712	0.000301	-5.696222	0.0000
RESID(-1)^2*(RESID(-1)<0)	-5.112080	1.216556	-4.202090	0.0000
GARCH(-1)	0.842303	0.012514	67.30861	0.0000
R-squared	-0.005648	Mean dependent var		70.53581
Adjusted R-squared	-0.006398	S.D. dependent var		360.6808
S.E. of regression	361.8327	Akaike info criterion		14.43061
Sum squared resid	1.76E+08	Schwarz criterion		14.45384
Log likelihood	-9691.370	Hannan-Quinn criter.		14.43931
Durbin-Watson stat	2.037957			