

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CAMPUS SOROCABA
CENTRO DE CIÊNCIAS EM GESTÃO E TECNOLOGIA
CURSO DE CIÊNCIAS ECONÔMICAS

THIAGO MATEOS SALGADO

**IMPACTO DO LANÇAMENTO DO GPT-4 NA VOLATILIDADE CONDICIONAL
DE UMA CESTA DE CRIPTOATIVOS: UMA ANÁLISE UTILIZANDO MODELOS
DA FAMÍLIA ARCH**

Sorocaba

2025

UNIVERSIDADE FEDERAL DE SÃO CARLOS
CAMPUS SOROCABA
CENTRO DE CIÊNCIAS EM GESTÃO E TECNOLOGIA
CURSO DE CIÊNCIAS ECONÔMICAS

THIAGO MATEOS SALGADO

**IMPACTO DO LANÇAMENTO DO GPT-4 NA VOLATILIDADE CONDICIONAL
DE UMA CESTA DE CRIPTOATIVOS: UMA ANÁLISE UTILIZANDO MODELOS
DA FAMÍLIA ARCH**

Trabalho de Conclusão de Curso apresentado ao Centro de Ciências em Gestão e Tecnologia da Universidade Federal de São Carlos, *campus* Sorocaba, para obtenção do título/grau de bacharel em Ciências Econômicas.

Orientação: Profa. Dra. Andreza Aparecida Palma

Sorocaba
2025

Salgado, Thiago Mateos

Impacto do lançamento do GPT-4 na volatilidade condicional de uma cesta de criptoativos: uma análise utilizando modelos da família ARCH / Thiago Mateos Salgado -- 2025.
45f.

TCC (Graduação) - Universidade Federal de São Carlos, campus Sorocaba, Sorocaba

Orientador (a): Andreza Aparecida Palma

Banca Examinadora: Aniela Fagundes Carrara, Lúcia Regina Centurião

Bibliografia

1. Criptoativos. 2. ARCH. 3. Inteligência Artificial. I. Salgado, Thiago Mateos. II. Título.

Ficha catalográfica desenvolvida pela Secretaria Geral de Informática (SIn)

DADOS FORNECIDOS PELO AUTOR

Bibliotecário responsável: Maria Aparecida de Lourdes Mariano -
CRB/8 6979

DEDICATÓRIA

*Ao Tico, que alegrou os meus dias
por 15 anos.*

*Aos meus pais, Irene e Miguel, que
sempre me incentivaram a ser
minha melhor versão.*

AGRADECIMENTO

Primeiramente, gostaria de agradecer aos meus pais, Irene e Miguel, que sempre me apoiaram em minha jornada acadêmica mesmo nos momentos mais complexos. Não foi uma jornada fácil e, por isso, eu agradeço imensamente pelo apoio que tive. Fico muito feliz em poder dizer que sou, hoje, a melhor versão que poderia ser de mim mesmo. Quando escolhi economia, queria entender o mundo ao meu redor: como os mercados se moviam; como milhares de *terabytes* de informação influenciavam o modo de agir de bilhões de pessoas todos os dias; e até como uma notícia do outro lado do mundo poderia impactar o preço de um biscoito no mercado do meu bairro. Ao longo do tempo fui me apaixonando pelo curso: aprendi sobre assuntos que variaram desde mercado financeiro e macroeconomia até economia verde e modelos comportamentais microeconômicos. Essa trajetória foi simplesmente incrível e agradeço, também, a todo o corpo docente pelos ensinamentos.

Ainda, outra pessoa que merece uma menção especial é a minha professora, mentora e orientadora: Andreza. E pensar que passei de quase não saber programar para, hoje, ter um trabalho que se baseia em mais de 1000 (mil) linhas de código no irritante (mas confiável como sempre) Rstudio. Fico muito grato por todo o suporte que me foi oferecido ao longo do curso e pelas oportunidades de me desenvolver em monitorias que impactaram diretamente na minha didática, minha afinidade com o R e na escolha do tema tratado neste trabalho. Obrigado por me ajudar a me tornar o profissional que sou hoje.

Por fim, agradeço aqui, também, aos meus amigos e namorada que me acompanharam ao longo do caminho e tornaram a experiência universitária mais leve e divertida. Vocês são parte essencial de tudo ter dado certo.

RESUMO

SALGADO, Thiago Mateos. **Impacto do lançamento do GPT-4 na volatilidade condicional de uma cesta de criptoativos: uma análise utilizando modelos da família ARCH**. 2025.44 f. Trabalho de Conclusão de Curso (Graduação em Ciências Econômicas) – Centro de Ciências em Gestão e Tecnologia, Universidade Federal de São Carlos, Sorocaba, 2025.

O presente trabalho teve como objetivo analisar o impacto do lançamento do GPT-4, da empresa OpenAI, na volatilidade condicional de uma cesta de criptoativos. Para isso, foram utilizados dados diários do ano de 2023 referentes às 3 criptomoedas representativas Bitcoin, Ethereum e Solana. A metodologia aplicada consistiu na estimação de modelos da família ARCH antes e depois do lançamento da ferramenta de inteligência artificial. Como resultado da estimação dos modelos, identificou-se, para a maior parte (duas) das criptomoedas analisadas, a presença de choques de curto efeito que se dissipam no médio e longo prazo, o que denota um sentimento de euforia no setor tecnológico com impactos perceptíveis no mercado de criptoativos.

Palavras-chave: Criptoativos; ARCH; GARCH; Inteligência artificial; GPT-4.

ABSTRACT

The objective of this study was to analyze the impact of the launch of OpenAI's GPT-4 on the conditional volatility of a basket of crypto assets. To this end, daily data from 2023 were used for the three representative cryptocurrencies Bitcoin, Ethereum, and Solana. The methodology applied consisted of estimating ARCH family models before and after the launch of the artificial intelligence tool. As a result of the model estimation, for most (two) of the cryptocurrencies analyzed, the presence of short-term shocks that dissipate in the medium and long term was identified, which denotes a feeling of euphoria in the technology sector with noticeable impacts on the cryptoassets market.

Keywords: Cryptoassets; ARCH; GARCH; Artificial intelligence; GPT-4.

LISTA DE GRÁFICOS

Gráfico 1 – Retornos diários do BTC/USD (2023).....	17
Gráfico 2 – Retornos diários do ETH/USD (2023).....	18
Gráfico 3 – Retornos diários do SOL/USD (2023).....	19
Gráfico 4 – Distribuição normal e t-student para o BTC/USD (2023).....	20
Gráfico 5 – Distribuição normal e t-student para o ETH/USD (2023).....	20
Gráfico 6 – Distribuição normal e t-student para o SOL/USD (2023).....	21
Gráfico 7 – PACF dos retornos ao quadrado para o BTC/USD (2023).....	21
Gráfico 8 – PACF dos retornos ao quadrado para o ETH/USD (2023).....	22
Gráfico 9 – PACF dos retornos ao quadrado para o SOL/USD (2023).....	22
Gráfico 10 – Dinâmica da volatilidade condicional para o BTC/USD (2023).....	39
Gráfico 11 – Dinâmica da volatilidade condicional para o ETH/USD (2023).....	40
Gráfico 12 – Dinâmica da volatilidade condicional para o SOL/USD (2023).....	41

LISTA DE TABELAS

Tabela 1 — Estatísticas descritivas por ativo (2023).....	17
Tabela 2 — Diagnóstico inicial para o BTC/USD (2023).....	23
Tabela 3 — Diagnóstico inicial para o ETH/USD (2023).....	24
Tabela 4 — Diagnóstico inicial para o SOL/USD (2023).....	25
Tabela 5 — Parâmetros ARMA por criptoativo (2023).....	26
Tabela 6 — Modelo sGARCH para o BTC/USD (2023).....	27
Tabela 7 — Modelo eGARCH para o BTC/USD (2023).....	28
Tabela 8 — Modelo gjrGARCH para o BTC/USD (2023).....	29
Tabela 9 — Modelo sGARCH para o ETH/USD (2023).....	30
Tabela 10 — Modelo eGARCH para o ETH/USD (2023).....	31
Tabela 11 — Modelo gjrGARCH para o ETH/USD (2023).....	32
Tabela 12 — Modelo sGARCH para o SOL/USD (2023).....	33
Tabela 13 — Modelo eGARCH para o SOL/USD (2023).....	34
Tabela 14 — Modelo gjrGARCH para o SOL/USD (2023).....	35
Tabela 15 — Critérios de informação e erro por modelo do BTC/USD (2023).....	36
Tabela 16 — Critérios de informação e erro por modelo do ETH/USD (2023).....	36
Tabela 17 — Critérios de informação e erro por modelo do SOL/USD (2023).....	36
Tabela 18 — Volatilidade condicional do BTC/USD (2023).....	37
Tabela 19 — Volatilidade condicional do ETH/USD (2023).....	37
Tabela 20 — Volatilidade condicional do SOL/USD (2023).....	37

SUMÁRIO

INTRODUÇÃO.....	12
FUNDAMENTAÇÃO TEÓRICA	13
METODOLOGIA	15
RESULTADOS.....	17
CONSIDERAÇÕES FINAIS.....	42
REFERÊNCIAS.....	43

1. INTRODUÇÃO

O presente trabalho teve como objetivo analisar o impacto do lançamento do GPT-4, da empresa OpenAI, na volatilidade condicional de uma cesta de criptoativos. Dados diários referentes ao ano de 2023 (desde o início de janeiro até o fim de dezembro) do Bitcoin, Ethereum e Solana¹ foram utilizados, com os preços obtidos através do *Yahoo Finance*, com a ajuda do R (v. 4.5.2) pelo pacote *BatchGetSymbols*; o evento considerado foi o lançamento do GPT-4 em 13 de março e as janelas utilizadas foram uma curta ($\approx 2,5$ meses) antes do evento e uma longa ($\approx 9,5$ meses) depois do evento, assim como janelas simétricas de 7, 14, 21 e 28 dias².

Em um contexto de avanço contínuo da tecnologia nas últimas décadas, a escolha do GPT-4 como evento disruptivo se justifica por ser o primeiro modelo multimodal desenvolvido pela

OpenAI capaz de processar tanto texto quanto imagens, o que representa um avanço significativo em relação às versões anteriores. Além disso, o GPT-4 superou o GPT-3.5 em diversos testes de desempenho e capacidade, sendo capaz de analisar falhas e vulnerabilidades em contratos inteligentes na rede Ethereum (OpenAI, 2023). Nessa esfera, é evidente a ligação entre os ecossistemas de inteligência artificial (IA) e criptomoedas, uma vez que inovações de IA podem interferir, por exemplo, na dinâmica de mercados baseados em *blockchain*.

Quanto ao embasamento teórico, este trabalho se fundamenta em fatos estilizados de séries temporais financeiras como a heterocedasticidade condicional e os clusters de volatilidade, que estabelecem a base para a aplicação dos modelos ARCH/GARCH (ENGLE, 1982; BOLLERSLEV, 1986). Outras extensões destes modelos incluem a assimetria e o efeito de alavancagem, que são relevantes para verificar diferentes respostas a choques (NELSON, 1991; GLOSTEN et al., 1993), tal como observado no trabalho de YILDIRIM e BEKUN (2023).

Destarte, a metodologia aplicada consistiu em: extração dos dados (*BatchGetSymbols*); construção das séries de retornos; estimação da média através de ARMA/ARIMA; teste de heterocedasticidade condicional; e estimação dos modelos sGARCH (*standard* GARCH, modelo padrão), eGARCH (*exponential* GARCH, ou GARCH exponencial) e gjrGARCH (Glosten–Jagannathan–Runkle GARCH) incorporando a estrutura ARMA. Os modelos foram comparados com base nos critérios AIC/BIC, MAE e em diagnósticos sobre os resíduos padronizados (GALANOS, 2025; HYNDMAN et al., 2025; LJUNG; BOX, 1978).

¹ A seleção dos criptoativos se deu com base em relevância de mercado, diversidade tecnológica, disponibilidade de dados e representatividade no ecossistema cripto.

² Para a análise apresentada, o período de 7 dias é considerado como curto prazo, enquanto 14 a 21 dias representam o médio prazo e 28 dias o longo prazo. Essas classificações tiveram origem na natureza dinâmica e alta sensibilidade informacional do mercado de criptoativos.

2. FUNDAMENTAÇÃO TEÓRICA

Ao contrário do estabelecido no modelo de mercado eficiente elaborado por Fama (1970), em que os ativos refletem instantaneamente e por completo todas as informações disponíveis, Hong e Stein (1999), Clarke et al. (2019) e Kogan et al. (2021) comprovaram, de forma análoga à evidência empírica, que informações podem impactar o mercado financeiro através da criação de choques ou bolhas especulativas. Quando séries temporais financeiras são avaliadas de acordo com essa perspectiva, é possível identificar a presença de características próprias como volatilidade condicional e certos padrões de dependência temporal (Cont, 2001).

Sob essa ótica, Engle (1982) propôs o modelo ARCH, no qual a variância condicional segue um processo autorregressivo, o que possibilita mensurar a propagação de choques informacionais. A posteriori, Bollerslev (1986) desenvolveu o modelo GARCH, que é a generalização do ARCH, que permite modelos mais parcimoniosos, de forma semelhante ao modelo ARMA para a média condicional.

A literatura avançou ainda mais ao aprimorar a modelagem da resposta da variância em relação ao conteúdo do choque: Nelson (1991), com o eGARCH (*exponential GARCH*), que permite capturar assimetrias, de modo que choques negativos podem ter efeitos distintos sobre a volatilidade em relação a choques positivos; e Glosten, Jagannathan e Runkle (1993), com o gjrGARCH, que modela explicitamente o chamado “efeito alavancagem”, em que notícias negativas tendem a aumentar mais a volatilidade do que notícias positivas de mesma magnitude.

No processo metodológico implementado, foi utilizada também a seleção automática de ordens via `auto.arima()` (Hyndman; Khandakar, 2008), além de testes de diagnóstico como Ljung–Box (Ljung; Box, 1978) aplicados sobre resíduos e resíduos ao quadrado, que permitem detectar autocorrelação remanescente e padrões de heterocedasticidade condicional.

Cabe destacar que, para a estimação prática dos modelos de volatilidade, foi empregado o pacote `rugarch` desenvolvido por Galanos (2025), que disponibiliza uma ampla gama de especificações da família ARCH, incluindo sGARCH (Eq. 1), eGARCH (Eq. 2) e gjrGARCH (Eq.3), além de ferramentas para diagnóstico, simulação e previsão.

$$\sigma^2_t = \omega + \sum_{i=1}^p \alpha_i \epsilon^2_{t-i} + \sum_{j=1}^q \beta_j \sigma^2_{t-j} \quad (\text{Eq. 1})$$

$$\log(\sigma^2_t) = \omega + \sum_{j=1}^p \beta_j \log(\sigma^2_{t-j}) + \sum_{k=1}^Q \alpha_k \frac{|\epsilon_{t-k}|}{\sigma_{t-k}}$$

$$+ \sum_{k=1}^Q \gamma_k \left(\frac{\epsilon_{t-k}}{\sigma_{t-k}} - E \left[\frac{|\epsilon_{t-k}|}{\sigma_{t-k}} \right] \right) \quad (\text{Eq. 2})$$

$$\sigma_t^2 = \omega + \sum_{i=1}^q (\alpha_i \pm \gamma_i I_{i,t-i}) \epsilon_{t-i}^2 + \sum_{j=1}^p \beta_j \sigma_{t-j}^2 \quad (\text{Eq. 3})$$

Na Eq. 1, tem-se que σ_t^2 representa a variância condicional no tempo t ; ω corresponde ao nível base de volatilidade; os termos $\alpha_i \epsilon_{t-i}^2$ capturam o efeito dos choques passados (resíduos ao quadrado); e os termos $\beta_j \sigma_{t-j}^2$ traduzem a persistência da própria variância ao longo do tempo.

Já na Eq. 2, $\log(\sigma_t^2)$ representa a variância condicional em escala logarítmica, retornando um resultado positivo; ω define o nível médio da log-volatilidade; os termos $\beta_j \log(\sigma_{t-j}^2)$ refletem o efeito da volatilidade passada; os termos $\alpha_k (\epsilon_{t-k} / \sigma_{t-k})$ incorporam choques padronizados, ajustados pela volatilidade anterior; e os termos $\gamma_k (\epsilon_{t-k} / \sigma_{t-k} - E[\epsilon_{t-k} / \sigma_{t-k}])$ medem desvios em relação à média para captura de assimetria.

Por último, em Eq. 3, σ_t^2 novamente representa a variância condicional; ω corresponde ao nível base de volatilidade; os termos $\alpha_i \epsilon_{t-i}^2$ traduzem, assim como na Eq. 1, o impacto dos choques passados; os termos adicionais $\gamma_i I_{i,t-i} \epsilon_{t-i}^2$ capturam o chamado efeito alavancagem, em que notícias negativas tendem a aumentar mais a volatilidade do que notícias positivas de mesma magnitude; e os termos $\beta_j \sigma_{t-j}^2$, como em sGARCH, incluem a persistência da variância ao longo do tempo.

3. METODOLOGIA

Foram utilizados neste estudo dados referentes ao ano de 2023 (por completo, desde 01 de janeiro até 31 de dezembro) provenientes do *Yahoo Finance* e extraídos por meio da utilização do software estatístico R (versão 4.5.2) com o pacote *BatchGetSymbols*. O período foi escolhido com base nas seguintes premissas: i) seleção de amostra menor para redução de ruídos oriundos de outros eventos; ii) inclusão de evento relevante ao ecossistema da inteligência artificial, tendo sido escolhido o lançamento do LLM GPT4 em 13 de março; iii) segundo analistas (BityBank, 2024), o ano de 2023 foi marcado pelo chamado tech boom e, assim, mostra-se uma janela interessante de dados para o tema tratado da perspectiva da existência de um sentimento de euforia e aumento de especulação destes ativos; iv) para melhor captar os efeitos do evento discutido, optou-se pela observação da volatilidade em dois períodos principais, sendo um mais curto (2 meses e meio), precedente ao evento, e outro mais longo (9 meses e meio), subsequente ao evento, conforme a prática válida em estudos de eventos (Brown; Warner, 1985)³.

No que concerne aos criptoativos, estes foram escolhidos de acordo com relevância de mercado, diversidade tecnológica, disponibilidade de dados e representatividade no ecossistema cripto, consistindo em: i) Bitcoin, a primeira e mais conhecida criptomoeda, criada em 2008 por Satoshi Nakamoto, e focado em ser reserva de valor e meio de pagamento descentralizado; ii) Ethereum, uma plataforma de blockchain programável lançada em 2015 por Vitalik Buterin cujo foco é o pagamento e estabelecimento de contratos inteligentes, ou seja, que não precisam de intermediários; e iii) Solana, outra blockchain, mais recente, cujo enfoque é velocidade, baixo custo por transação e, por conta disso, escalabilidade.

Uma característica marcante das séries financeiras é a presença de heterocedasticidade condicional, isto é, a variância dos erros não permanece constante ao longo do tempo, mas depende da informação passada. Esse fenômeno se manifesta em períodos de alta volatilidade seguidos por períodos de relativa calma, formando os chamados “clusters de volatilidade”. Assim, torna-se importante a elaboração de modelos que se adaptem a essa característica e capturem essa dinâmica objetivando melhor ajuste aos dados. Nesse sentido, é importante ressaltar que o primeiro modelo proposto para capturar tal dinâmica foi o ARCH (*Autoregressive Conditional Heteroscedasticity*), proposto por Engle (1982), cuja formulação

³Os autores demonstram que a metodologia de estudos de eventos é robusta mesmo com diferentes especificações de janelas, recomendando a análise de períodos distintos antes e depois do evento para captar tanto movimentos antecipatórios, como vazamentos de informação ou especulação, quanto efeitos subsequentes, como a integração gradual do choque no mercado.

estabelece que a variância condicional em cada período é função dos quadrados dos erros passados, permitindo que choques anteriores influenciem diretamente a volatilidade atual. Posteriormente, Bollerslev (1986) generalizou essa estrutura ao propor o GARCH (*Generalized ARCH*), que incorpora também defasagens da própria variância condicional, ampliando a flexibilidade e a capacidade de modelar a persistência da volatilidade. A literatura avançou para diferentes extensões, consistindo em: i) sGARCH (GARCH padrão); ii) eGARCH (GARCH exponencial); e iii) gjrGARCH, desenvolvido por Glosten, Jagannathan e Runkle (1993). Tais modelos são, atualmente, ferramentas centrais na análise de risco e previsão de volatilidade em mercados financeiros. Conforme destacam Yildirim e Bekun (2023), ao aplicar ARCH, GARCH e EGARCH para prever a volatilidade dos retornos do Bitcoin, é possível capturar a natureza dinâmica e não linear da volatilidade observada nos criptoativos.

Em resumo, a metodologia utilizada neste trabalho consiste em: i) extração dos dados (via pacote `BatchGetSymbols`); ii) verificação da estacionariedade das séries por meio do teste ADF (Dickey-Fuller aumentado); iii) identificação da dinâmica média via ARMA/ARIMA com validação por ACF/PACF e testes de Ljung–Box; iv) verificação de heterocedasticidade condicional com ARCH-LM; v) estimação de modelos candidatos sGARCH, eGARCH e gjrGARCH (utilizando o pacote `rugarch`, entre outros); vi) avaliação por critérios de informação (AIC/BIC) e métricas de erro preditivo (MAE); e vii) cálculo da volatilidade condicional nas janelas selecionadas.

4. RESULTADOS

Primeiramente, a partir da tabela abaixo (Tabela 1), tem-se que, em primeiro plano, todas as criptomoedas apresentam excesso de curtose e, assim, possuem caudas pesadas, o que implica maior chance de ocorrência de eventos extremos em comparação com a distribuição normal. Além disso, com um nível de significância de 5%, rejeita-se a hipótese nula de que as séries possuem raiz unitária e, logo, verifica-se que todas as séries são estacionárias pelo teste ADF (Dickey-Fuller aumentado), isto é, apresentam média e variância constantes ao longo do tempo.

Tabela 1 — Estatísticas descritivas por ativo (2023)

ticker	Estatísticas Descritivas por Criptoativo						Teste de Estacionariedade (ADF)	
	media	desvio_padrao	variância	curtose	assimetria	distribuicao	adf_p	estacionaria
BTC-USD	0.0025633	0.0226847	0.0005146	5.947374	0.6912219	Cauda Pesada	0.010	Estacionária
ETH-USD	0.0017629	0.0243097	0.0005910	5.155439	0.3654877	Cauda Pesada	0.010	Estacionária
SOL-USD	0.0063717	0.0500480	0.0025048	6.584482	1.0633327	Cauda Pesada	0.010	Estacionária

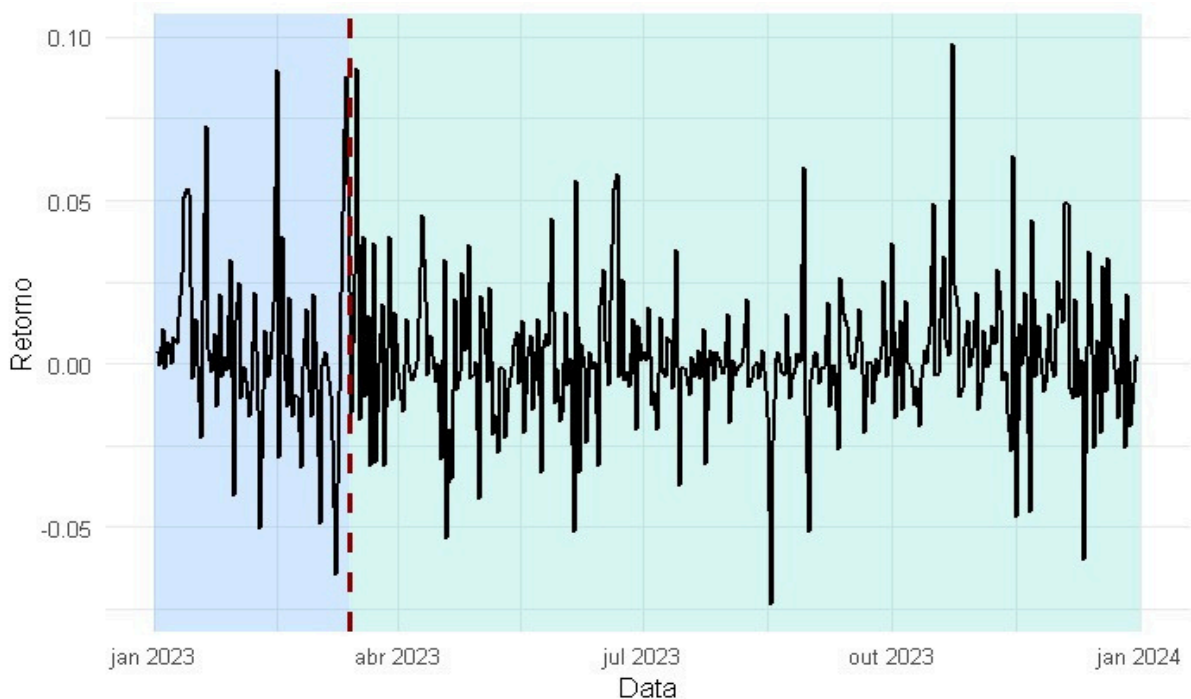
Nota:

Curtose > 3 indica cauda pesada; Assimetria positiva indica distribuição enviesada à direita. ADF: H0 = raiz unitária.

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Para melhor compreensão das séries, os gráficos 1, 2 e 3 apresentam a evolução dos retornos diários, calculados como sendo a diferença dos logaritmos naturais dos preços de fechamento:


Gráfico 1 — Retornos diários do BTC/USD (2023)



Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

O BTC/USD (Gráfico 1) apresenta períodos de grande volatilidade antes e depois do evento estudado, mas detém o menor desvio padrão dentre as criptomoedas analisadas. Além disso, é notável um pico no retorno diário pouco após o evento.

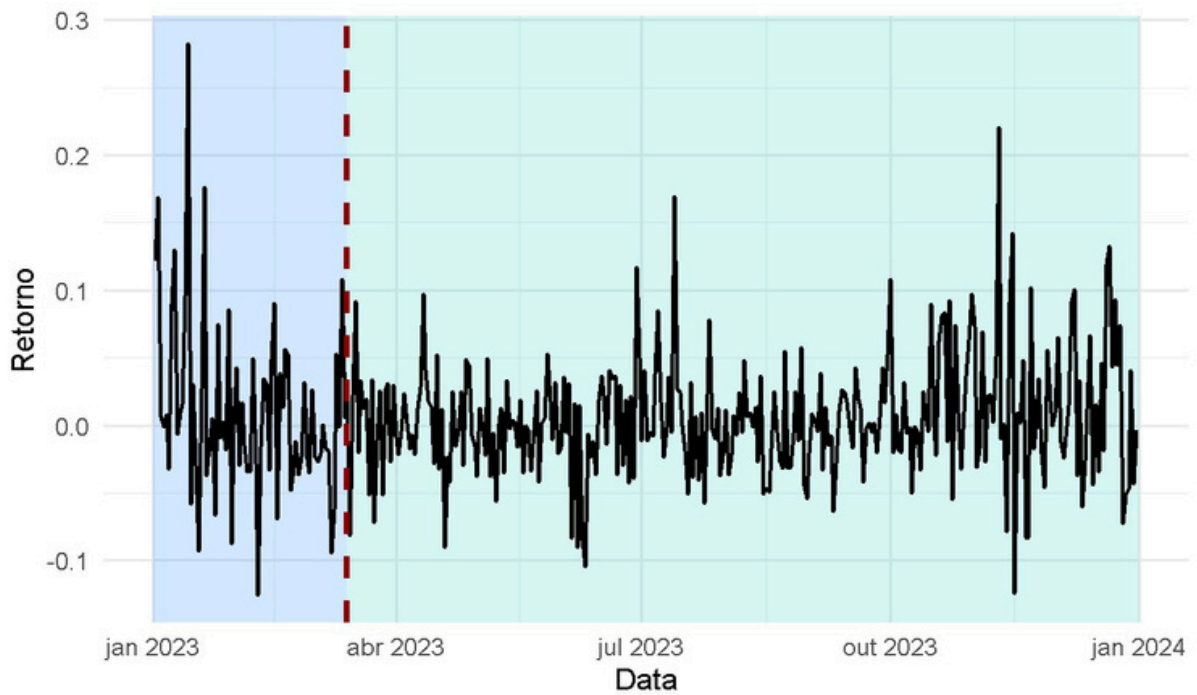
Gráfico 2 — Retornos diários do ETH/USD (2023)



Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Quanto ao ETH/USD (Gráfico 2), nota-se um desvio padrão ligeiramente menor e dentro do esperado para criptomoedas, ou seja, grandes variações diárias que chegam, em picos, a mais de 10%. Comportamentos similares são observados na criptomoeda Solana (Gráfico 3) que, por sua vez, tem desvio padrão mais exacerbado (mais que o dobro das demais criptomoedas) de forma perceptível no gráfico.

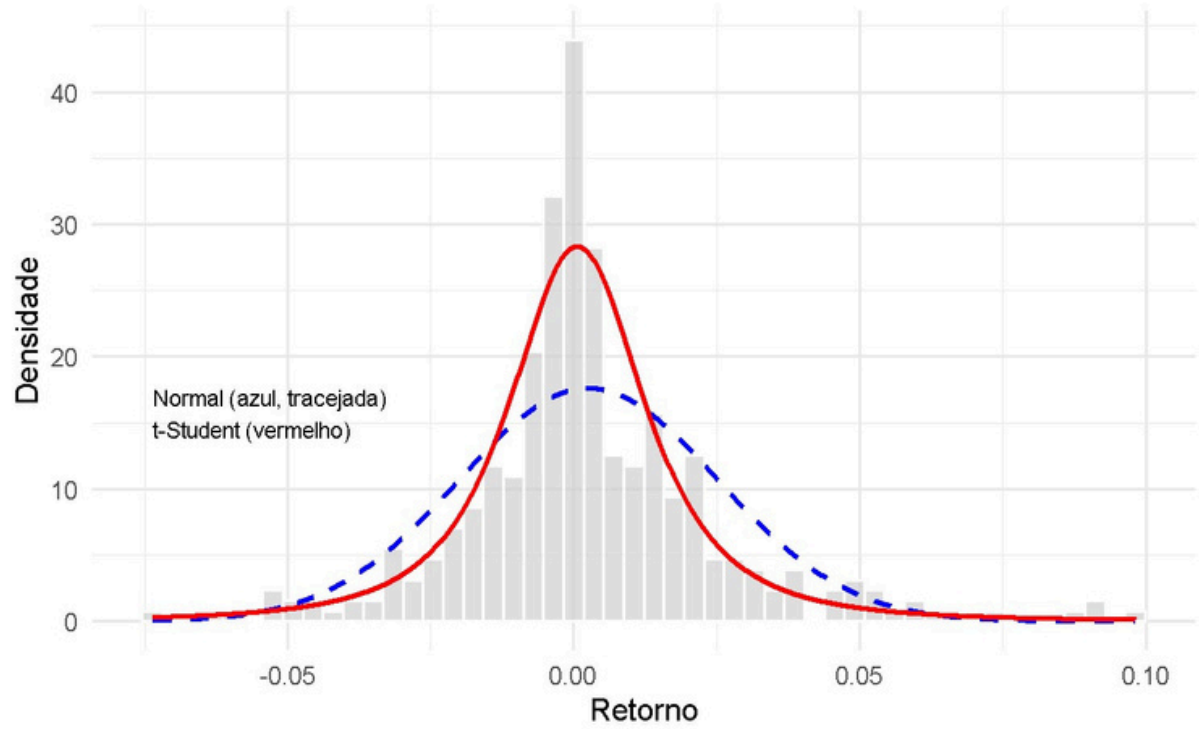
Gráfico 3 — Retornos diários do SOL/USD (2023)



Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

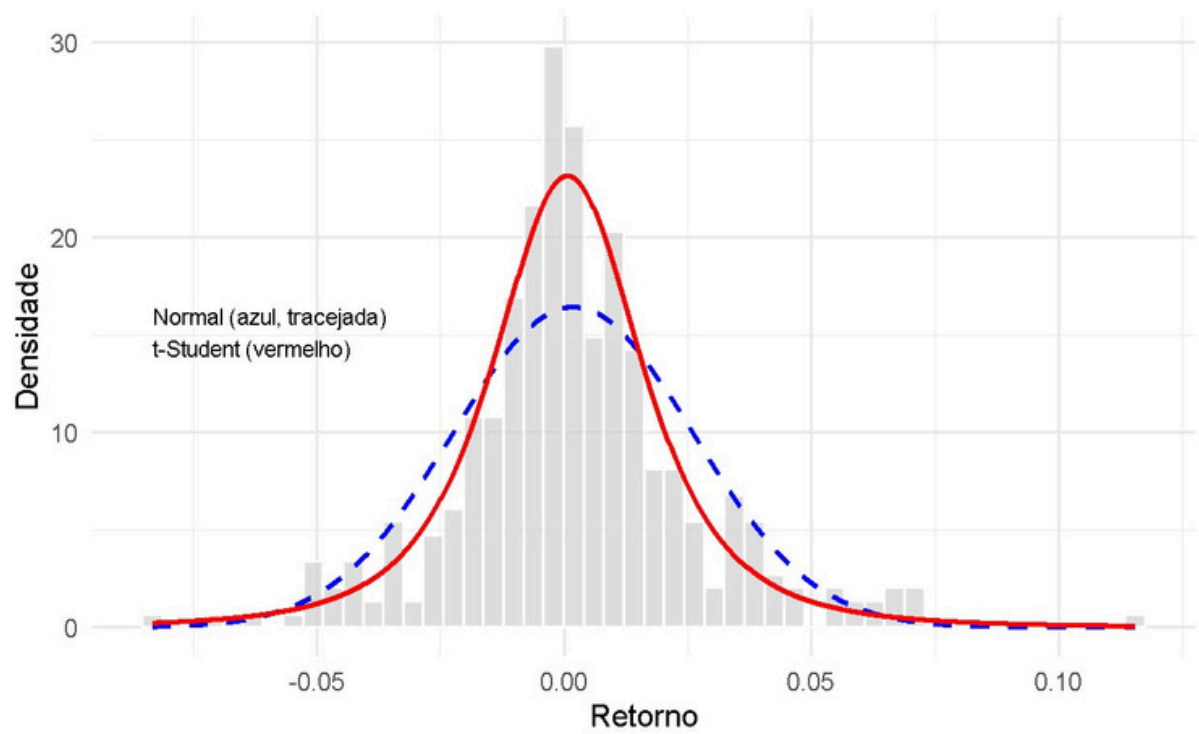
Uma vez vistas as séries e notada a curtose calculada, percebe-se que uma distribuição com caudas mais pesadas, como a de Student, seria mais adequada para a modelagem dos dados, uma vez que captura de forma mais realista a presença de valores atípicos e a maior variabilidade observada nos retornos. Isso é confirmado pelos gráficos 4, 5 e 6, a seguir, que representam a comparação entre a distribuição t de Student e a normal para as criptomoedas analisadas:

Gráfico 4 — Distribuição normal e t-student para o BTC/USD (2023)



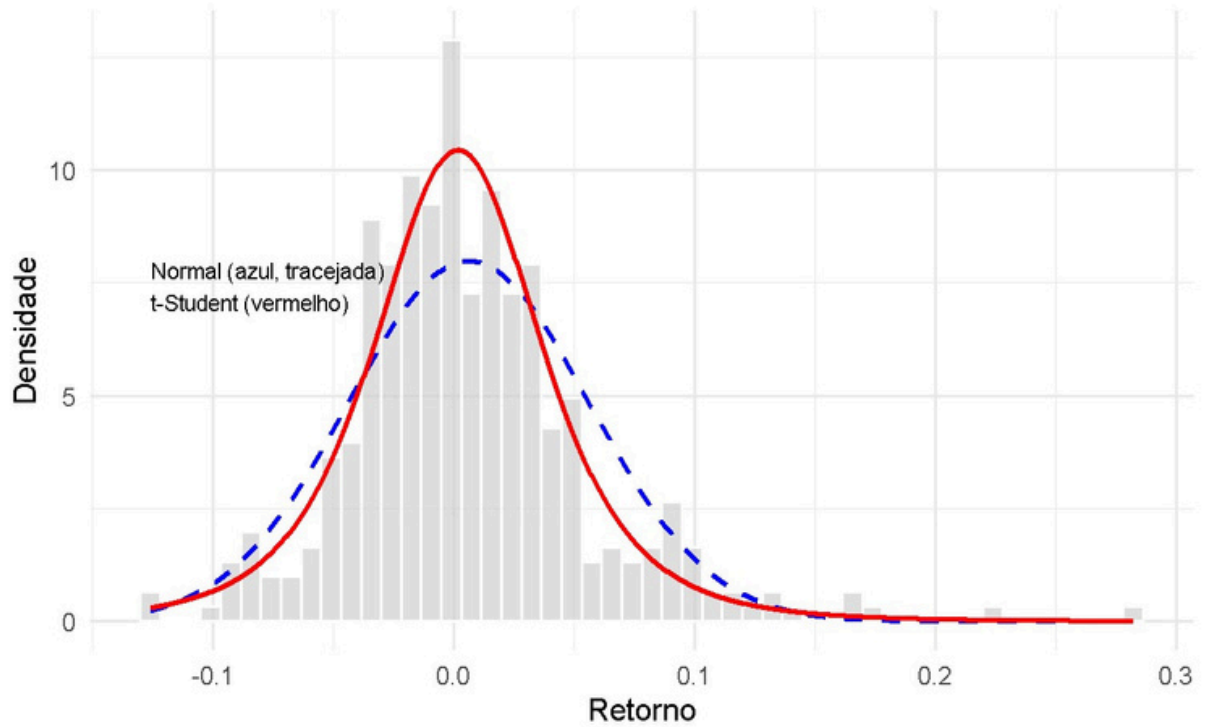
Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Gráfico 5 — Distribuição normal e t-student para o ETH/USD (2023)



Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Gráfico 6 — Distribuição normal e t-student para o SOL/USD (2023)




Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Além do estudo da distribuição de cada série, é relevante o entendimento de seu comportamento. Destarte, os gráficos abaixo (Gráficos 7, 8 e 9) mostram os correlogramas dos resíduos ao quadrado a fim de verificar efeitos de heterocedasticidade condicional, como segue:

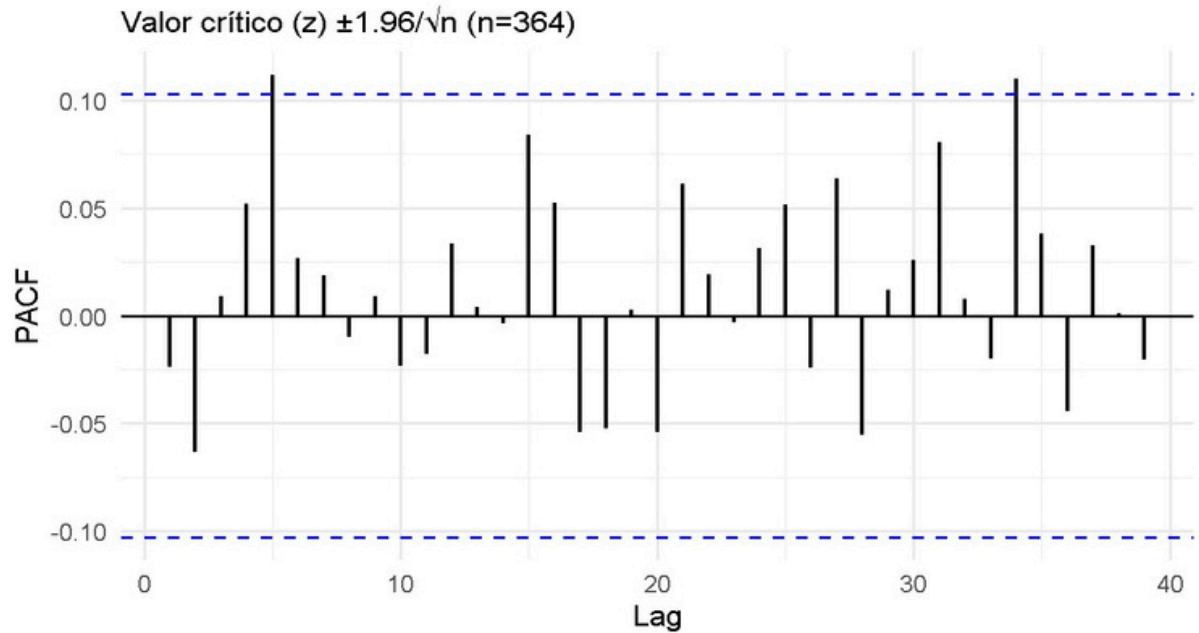
Gráfico 7 — PACF dos retornos ao quadrado para o BTC/USD (2023)

Valor crítico (z) $\pm 1.96/\sqrt{n}$ (n=364)



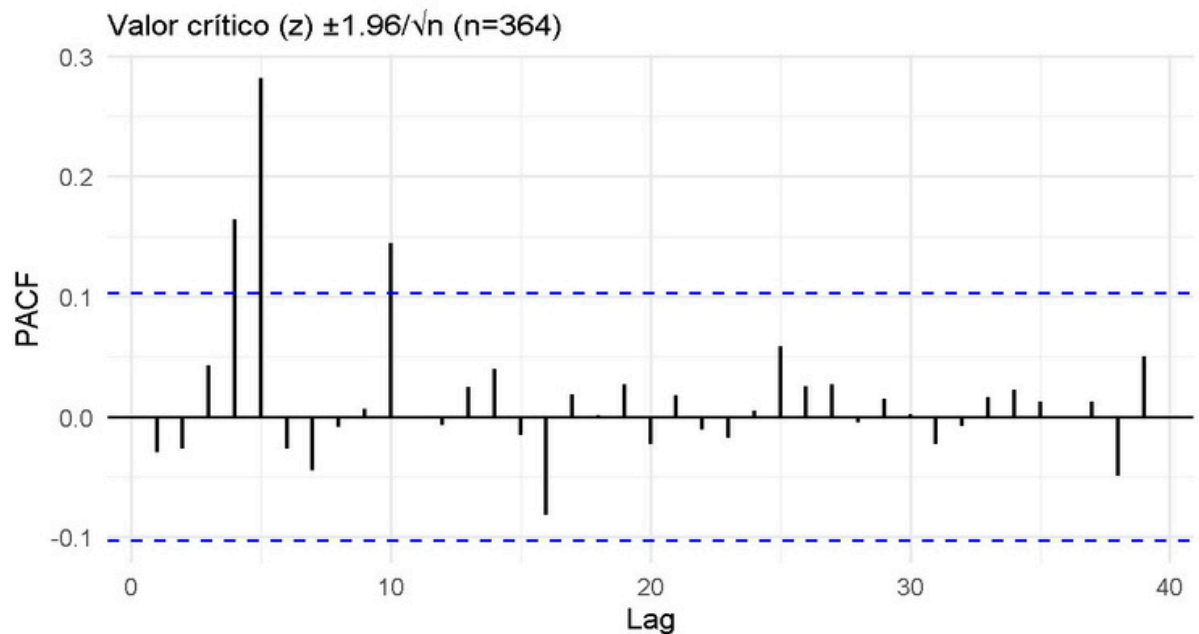
Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Gráfico 8 — PACF dos retornos ao quadrado para o ETH/USD (2023)



Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Gráfico 9 — PACF dos retornos ao quadrado para o SOL/USD (2023)



Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Pelos gráficos acima, tem-se que: i) a série de Bitcoin apresenta dependência nas defasagens 3 e 25; ii) Ethereum apresenta dependência em 5 e 34; e iii) Solana, por sua vez, em 4, 5 e 10. Em vista dos lags demonstrados, considera-se relevante um diagnóstico inicial (presente nas

Tabelas 2, 3 e 4) para cada criptoativo, objetivando uma melhor compreensão sobre as dependências observados na PACF:

Tabela 2 — Diagnóstico inicial para o BTC/USD (2023)

lag	Ljung-Box Retornos	Ljung-Box Retornos ²	ARCH
1	0.7855	0.0084 ***	0.0087 ***
2	0.3189	0.0299 **	0.0328 **
3	0.3877	0.0585 *	0.0644 *
4	0.5299	0.0210 **	0.0168 **
5	0.6659	0.0400 **	0.0338 **
7	0.8462	0.0446 **	0.0485 **
10	0.7172	0.1463	0.1728
14	0.6529	0.2211	0.2508
21	0.7153	0.4076	0.5085
25	0.6013	0.5619	0.5633
28	0.6395	0.1781	0.2269
34	0.6926	0.2138	0.3518

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Como visto nos correlogramas apresentados e no teste acima (Tabela 2), é possível afirmar que, adotando um nível de significância de 5% ($\alpha = 0,05$), existe efeito ARCH e confirma-se que a série apresenta heterocedasticidade condicional, ou seja, a variância tem memória: variâncias passadas afetam variâncias presentes.

Tabela 3 — Diagnóstico inicial para o ETH/USD (2023)

lag	Ljung-Box Retornos	Ljung-Box Retornos ²	ARCH
1	0.0404 **	0.6981	0.6995
2	0.1008	0.8394	0.8416
3	0.2027	0.6013	0.6177
4	0.3239	0.7578	0.7625
5	0.4555	0.7007	0.7242
7	0.4728	0.3047	0.3718
10	0.1421	0.5717	0.6462
14	0.1966	0.8143	0.8286
21	0.2235	0.8184	0.8827
25	0.2573	0.8261	0.9303
28	0.1091	0.8118	0.9063
34	0.1258	0.8263	0.9289

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Quanto à ETH (Tabela 3), adotando também um nível de significância de 5% ($\alpha = 0,05$), rejeita-se a hipótese nula de ausência de autocorrelação e, assim, há necessidade de um modelo adequado que impeça que valores passados da série não afetem os valores presentes.

Tabela 4 — Diagnóstico inicial para o SOL/USD (2023)

lag	Ljung-Box Retornos	Ljung-Box Retornos ²	ARCH
1	0.4781	0.0395 **	0.0395 **
2	0.7469	0.1131	0.2136
3	0.8919	0.1934	0.2893
4	0.9583	0.2659	0.3644
5	0.8279	0.0064 ***	0.0127 **
7	0.5317	0.0000 ***	0.0000 ***
10	0.5153	0.0000 ***	0.0000 ***
14	0.5468	0.0000 ***	0.0000 ***
21	0.5629	0.0000 ***	0.1189
25	0.6173	0.0000 ***	0.1955
28	0.5966	0.0000 ***	0.2194
34	0.7119	0.0000 ***	0.4787

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Assim como na tabela 2, o teste da Solana, visto na tabela 4, apresenta a existência de memória na variância, ou seja, heterocedasticidade condicional. Assim, também é necessário um modelo ajustado a essa característica. Sob essa ótica, foi implementado em seguida um algoritmo de seleção automática de modelos ARIMA elaborado por Hyndman e Khandakar (2008), utilizado via função *auto.arima()*. Os resultados foram os seguintes:

Tabela 5 — Parâmetros ARMA por criptoativo (2023)

Parâmetros ARMA		
ticker	p	q
BTC-USD	0	0
ETH-USD	0	1
SOL-USD	2	0

Nota:

Estimativas obtidas com `auto.arima` ($d=0$, sem sazonalidade).

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

A partir disso, foram estipulados três modelos candidatos (sGARCH, eGARCH e gjrGARCH), todos incorporando os parâmetros ARMA calculados automaticamente, para cada criptoativo tratado. Além disso, foram testados todos os lags previamente considerados significativos ou relevantes ao estudo, com destaque para os recém-introduzidos lags semanais (7, 14, 21 e 28 dias) a serem utilizados como janela de observação dos resultados finais do presente estudo.

Os resultados para BTC, presentes nas tabelas 6, 7 e 8 abaixo, demonstram a necessidade de eliminação do modelo candidato gjrGARCH, uma vez identificada continuação dos indícios de autocorrelação nos resíduos quadráticos e de heterocedasticidade condicional antes vistos. Os demais modelos sGARCH e eGARCH apresentaram ajuste adequado aos dados, sem indícios de autocorrelação ou de memória na variância.

Tabela 6 — Modelo sGARCH para o BTC/USD (2023)

lag	Ljung-Box Resíduos	Ljung-Box Resíduos²	ARCH
1	0.9930	0.4986	0.5008
2	0.8451	0.6998	0.6901
3	0.8157	0.7708	0.7505
4	0.9095	0.8670	0.8390
5	0.9512	0.9306	0.9036
7	0.9923	0.8621	0.8458
10	0.8889	0.9607	0.9512
14	0.7793	0.9562	0.9574
21	0.7248	0.9813	0.9901
25	0.4981	0.9761	0.9829
28	0.5890	0.9686	0.9779
34	0.6566	0.9874	0.9930

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 7 — Modelo eGARCH para o BTC/USD (2023)

lag	Ljung-Box Resíduos	Ljung-Box Resíduos²	ARCH
1	0.7912	0.2541	0.2565
2	0.6859	0.3912	0.3787
3	0.8160	0.5118	0.5235
4	0.9176	0.6504	0.6638
5	0.9650	0.6071	0.6223
7	0.9920	0.7535	0.7646
10	0.9370	0.9063	0.9097
14	0.9118	0.8484	0.8637
21	0.8736	0.8643	0.8910
25	0.6896	0.8237	0.8384
28	0.7644	0.7187	0.8369
34	0.8430	0.8674	0.8998

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 8 — Modelo gjrGARCH para o BTC/USD (2023)

lag	Ljung-Box Resíduos	Ljung-Box Resíduos ²	ARCH
1	0.2722	0.0374 **	0.0384 **
2	0.3498	0.1061	0.1179
3	0.4400	0.1702	0.1817
4	0.6044	0.2833	0.3033
5	0.7267	0.3341	0.3656
7	0.8555	0.5150	0.5523
10	0.8095	0.7203	0.7590
14	0.7702	0.5061	0.6012
21	0.8389	0.5679	0.7398
25	0.8004	0.7448	0.7979
28	0.8680	0.7344	0.8364
34	0.8953	0.8648	0.9121

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

No que diz respeito aos testes dos modelos candidatos para ETH, disponíveis nas tabelas 9, 10 e 11 abaixo, tem-se que todos os modelos candidatos são elegíveis do ponto de vista de autocorrelação e heterocedasticidade, ou seja, todos os modelos foram capazes de se adaptar à autocorrelação detectada anteriormente nos dados.

Tabela 9 — Modelo sGARCH para o ETH/USD (2023)

lag	Ljung-Box Resíduos	Ljung-Box Resíduos²	ARCH
1	0.4221	0.6326	0.6344
2	0.5773	0.5766	0.5728
3	0.7175	0.5415	0.5278
4	0.8497	0.6788	0.6476
5	0.8961	0.8047	0.7767
7	0.7867	0.9227	0.9153
10	0.5139	0.9587	0.9583
14	0.6454	0.9942	0.9902
21	0.7628	0.9740	0.9773
25	0.5824	0.9939	0.9952
28	0.4950	0.9968	0.9975
34	0.6224	0.9990	0.9985

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 10 — Modelo eGARCH para o ETH/USD (2023)

lag	Ljung-Box Resíduos	Ljung-Box Resíduos²	ARCH
1	0.6978	0.4882	0.4904
2	0.7948	0.7173	0.7174
3	0.9177	0.4724	0.4927
4	0.9657	0.6414	0.6503
5	0.9713	0.7474	0.7631
7	0.8524	0.4829	0.5351
10	0.4511	0.7280	0.7729
14	0.4624	0.7496	0.8147
21	0.6929	0.6735	0.6989
25	0.6037	0.5048	0.6186
28	0.5711	0.5720	0.6977
34	0.6033	0.7213	0.8559

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 11 — Modelo gjrGARCH para o ETH/USD (2023)

lag	Ljung-Box Resíduos	Ljung-Box Resíduos²	ARCH
1	0.4414	0.8537	0.8544
2	0.6684	0.6324	0.6345
3	0.8211	0.5877	0.5897
4	0.9146	0.7237	0.7109
5	0.9438	0.8396	0.8267
7	0.8479	0.9328	0.9342
10	0.5098	0.9543	0.9614
14	0.6201	0.9944	0.9936
21	0.7724	0.9469	0.9591
25	0.5855	0.9799	0.9865
28	0.5294	0.9872	0.9913
34	0.6342	0.9955	0.9944

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Quanto aos modelos candidatos de SOL, disponíveis nas tabelas 12, 13 e 14, tem-se a necessidade de eliminação do modelo candidato eGARCH, uma vez identificada continuação dos indícios de autocorrelação nos resíduos quadráticos e de heterocedasticidade condicional antes vistos.

Tabela 12 — Modelo sGARCH para o SOL/USD (2023)

lag	Ljung-Box Resíduos	Ljung-Box Resíduos ²	ARCH
1	0.0743 *	0.3674	0.3669
2	0.1857	0.3502	0.4542
3	0.3380	0.3935	0.5036
4	0.4944	0.5130	0.6533
5	0.4497	0.2757	0.3837
7	0.3493	0.0667 *	0.1395
10	0.3274	0.1225	0.4489
14	0.4495	0.0535 *	0.9192
21	0.4549	0.3000	0.9996
25	0.5007	0.4408	0.9998
28	0.5080	0.5854	1.0000
34	0.5751	0.8038	1.0000

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 13 — Modelo eGARCH para o SOL/USD (2023)

lag	Ljung-Box Resíduos	Ljung-Box Resíduos ²	ARCH
1	0.1197	0.3267	0.3261
2	0.2980	0.3826	0.5187
3	0.4893	0.3493	0.4594
4	0.6475	0.4242	0.5720
5	0.7084	0.2725	0.3955
7	0.4295	0.0077 ***	0.0230 **
10	0.3644	0.0270 **	0.2011
14	0.4084	0.0056 ***	0.2647
21	0.5332	0.0597 *	0.9558
25	0.6588	0.1237	0.9779
28	0.6482	0.1730	0.9404
34	0.6326	0.3049	0.9657

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 14 — Modelo gjrGARCH para o SOL/USD (2023)

lag	Ljung-Box Resíduos	Ljung-Box Resíduos ²	ARCH
1	0.0972 *	0.3066	0.3057
2	0.2352	0.3315	0.4644
3	0.4081	0.4166	0.5564
4	0.5656	0.5127	0.6769
5	0.5380	0.2670	0.3688
7	0.4823	0.0807 *	0.1650
10	0.4224	0.1385	0.4786
14	0.5706	0.0713 *	0.9276
21	0.6076	0.3579	0.9993
25	0.6601	0.4995	0.9996
28	0.6654	0.6399	0.9999
34	0.6945	0.7961	0.9999

Nota:

*** $p < 0.01$; ** $p < 0.05$; * $p < 0.10$

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Uma vez eliminados modelos que não passaram no teste de diagnóstico, os restantes foram comparados (nas tabelas 15, 16 e 17) de acordo com os seguintes critérios: i) *Akaike Information Criterion* (AIC), que mede o ajuste penalizando a complexidade excessiva; ii) *Bayesian Information Criterion* (BIC), semelhante ao AIC, mas com penalização mais severa; e iii) Erro Médio Absoluto (MAE), que avalia a precisão por meio do erro médio absoluto entre valores observados e estimados. O resultado foi: para BTC, sGARCH apresentou melhor ajuste em todos os testes; para ETH, eGARCH teve melhores AIC e BIC, com mínima diferença no MAE; para SOL, o gjrGARCH foi escolhido por apresentar melhor AIC e robustez estatística com valores mais distantes do limiar escolhido de 5%. A partir dos modelos selecionados, foi calculada a volatilidade condicional em janelas semanais, como visto nas tabelas 18, 19 e 20.

Tabela 15 — Critérios de informação e erro por modelo do BTC/USD (2023)

Critérios de Informação e Erro			
Modelo	AIC	BIC	MAE_resíduos
sGARCH	-4.962546	-4.919720	0.0152845
eGARCH	-4.953797	-4.900264	0.0152845
gjrGARCH	-4.951339	-4.897807	0.0152845

Nota:

AIC e BIC são critérios de informação; MAE representa o erro médio absoluto dos resíduos.

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 16 — Critérios de informação e erro por modelo do ETH/USD (2023)

Critérios de Informação e Erro			
Modelo	AIC	BIC	MAE_resíduos
sGARCH	-4.741014	-4.687482	0.0169577
eGARCH	-4.791905	-4.727666	0.0169600
gjrGARCH	-4.740599	-4.676360	0.0169610

Nota:

AIC e BIC são critérios de informação; MAE representa o erro médio absoluto dos resíduos.

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 17 — Critérios de informação e erro por modelo do SOL/USD (2023)

Critérios de Informação e Erro			
Modelo	AIC	BIC	MAE_resíduos
sGARCH	-3.297025	-3.232786	0.0359027
eGARCH	-3.339112	-3.264167	0.0358731
gjrGARCH	-3.298542	-3.223597	0.0359149

Nota:

AIC e BIC são critérios de informação; MAE representa o erro médio absoluto dos resíduos.

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 18 — Volatilidade condicional do BTC/USD (2023)

Volatilidade Condicional				
janela	media_pre	media_pos	delta_pct	ativo
7	0.0434	0.0467	7.76	BTC
14	0.0386	0.0421	8.94	BTC
21	0.0366	0.0389	6.24	BTC
28	0.0384	0.0372	-3.11	BTC

Nota:

Δ (%) representa a variação percentual entre as médias pós e pré-evento.

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 19 — Volatilidade condicional do ETH/USD (2023)

Volatilidade Condicional				
janela	media_pre	media_pos	delta_pct	ativo
7	0.0279	0.0275	-1.45	ETH
14	0.0304	0.0256	-15.54	ETH
21	0.0317	0.0249	-21.35	ETH
28	0.0322	0.0254	-21.23	ETH

Nota:

Δ (%) representa a variação percentual entre as médias pós e pré-evento.

Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Tabela 20 — Volatilidade condicional do SOL/USD (2023)

Volatilidade Condicional				
janela	media_pre	media_pos	delta_pct	ativo
7	0.0428	0.0471	10.09	SOL
14	0.0443	0.0460	3.83	SOL
21	0.0466	0.0447	-3.95	SOL
28	0.0485	0.0435	-10.37	SOL

Nota:

Δ (%) representa a variação percentual entre as médias pós e pré-evento.


Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Quanto aos padrões de volatilidade condicional para 2023, apresentados nas Tabelas 18, 19 e 20 e vistos também nos Gráficos 10, 11 e 124, tem-se a constatação de respostas distintas dos criptoativos ao choque analisado. Para o BTC/USD, verificou-se aumento da volatilidade em janelas curtas, com variações de +7,76% (7 dias), +8,94% (14 dias) e +6,24% (21 dias), seguido de reversão em horizonte mais longo, com queda de -3,11% (28 dias). Para o ETH/USD, observou-se diminuição considerável da volatilidade após o evento, com reduções de -15,21% (14 dias), -21,51% (21 dias) e -21,51% (28 dias), indicando comportamento distinto e possivelmente estabilizador em resposta ao choque. Já no caso do SOL/USD, identificou-se padrão semelhante ao do Bitcoin, com elevação inicial de +10,09% (7 dias) e +3,83% (14 dias), seguida de reversão em janelas mais longas, com quedas de -3,95% (21 dias) e -10,37% (28 dias).

Ou seja, cada ativo respondeu de forma particular ao evento: o Bitcoin e a Solana apresentaram impacto concentrado no curto prazo, com reversão posterior, enquanto o Ethereum demonstrou trajetória de ajuste mais consistente e estabilizadora ao longo do tempo. Para o investidor, isso significa, principalmente, que: i) eventos relevantes do mundo tecnológico podem criar, através de um sentimento geral de euforia e consequente aumento da especulação em ativos relacionados a tecnologia, oportunidades de investimento em ativos mais sensíveis à informação; e ii) a manutenção de carteiras diversificadas é essencial para suavização de riscos frente à heterogeneidade dos impactos e à assimetria de informação sobre os diversos ativos disponíveis em mercado.

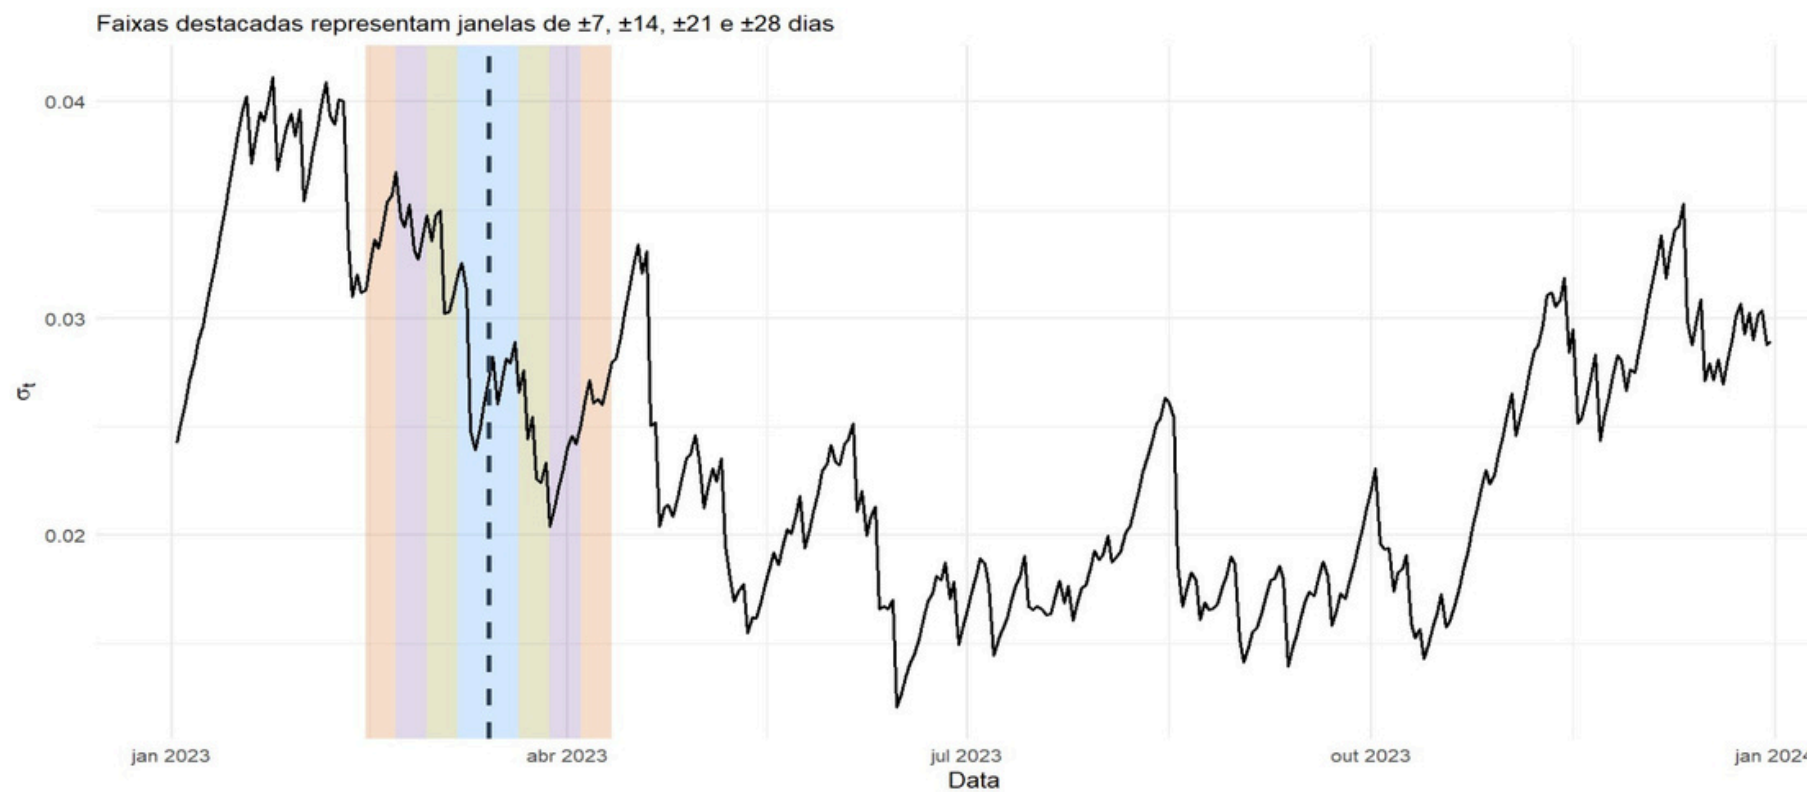
⁴É importante ressaltar que a escolha da orientação das seguintes páginas (onde estão os gráficos 10, 11 e 12) como ‘paisagem’ se deu por conta de melhor visibilidade dos dados e suas variações devido ao período temporal extenso observado.

Gráfico 10 — Dinâmica da volatilidade condicional para o BTC/USD (2023)



Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Gráfico 11 — Dinâmica da volatilidade condicional para o ETH/USD (2023)



Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023).

Gráfico 12 — Dinâmica da volatilidade condicional para o SOL/USD (2023)



Fonte: Elaboração própria a partir de dados do Yahoo Finance (2023)

5. CONSIDERAÇÕES FINAIS

Este estudo examinou os efeitos do lançamento do LLM GPT-4, que ocorreu em março de 2023, sobre a volatilidade condicional de três criptoativos significativos no ecossistema digital: Bitcoin, Ethereum e Solana. A pesquisa foi realizada utilizando modelos da família ARCH/GARCH. Além disso, a investigação foi organizada em torno de janelas de observação diferentes, a fim de possibilitar a comparação entre os períodos antes e depois do evento.

Os resultados obtidos indicam que, no caso do Bitcoin, verificou-se aumento da volatilidade em janelas curtas, com variações de +7,76% (7 dias), +8,94% (14 dias) e +6,24% (21 dias), seguido de reversão em horizonte mais longo, com queda de -3,11% (28 dias), o que sugere um impacto temporário, mas passageiro. Em relação ao Ethereum, observou-se uma diminuição considerável da volatilidade após o evento, com reduções de -15,21% (14 dias), -21,51% (21 dias) e -21,51% (28 dias), sugerindo um comportamento diferente e possivelmente estabilizador

em resposta ao choque analisado. Já no caso da Solana, identificou-se padrão semelhante ao do Bitcoin, com elevação inicial da volatilidade de +10,09% (7 dias) e +3,83% (14 dias), seguida de reversão em janelas mais longas, com quedas de -3,95% (21 dias) e -10,37% (28 dias).

Assim, chega-se à conclusão de que o evento teve um impacto heterogêneo nos ativos analisados, corroborando a hipótese de que eventos significativos do mundo tecnológico, especialmente da inteligência artificial, podem influenciar o mercado de criptoativos, mesmo que de forma não uniforme entre as diversas moedas. De modo geral, os resultados indicam que o impacto foi mais significativo no curto prazo, com efeitos que diminuíram ou se inverteram no médio e longo prazo. Isso ajuda a entender a dinâmica da volatilidade em um cenário caracterizado pelo chamado tech boom de 2023 (BityBank, 2024).

REFERÊNCIAS

- ARNOLD, Jeffrey B. **ggthemes: Extra Themes, Scales and Geoms for 'ggplot2'**. R package version 5.1.0. Disponível em: <https://CRAN.R-project.org/package=ggthemes>. Acesso em: 14 jan. 2025.
- AUGUIE, Baptiste. **gridExtra: Miscellaneous Functions for "Grid" Graphics**. R package version 2.3. Disponível em: <https://CRAN.R-project.org/package=gridExtra>. Acesso em: 27 fev. 2025.
- BITYBANK. **Criptomoedas, IA e Big Data: entenda a relação!** BityBank Blog, 24 jul. 2024. Disponível em: <https://www.bity.com.br/blog/criptomoedas-ia-e-big-data/>. Acesso em: 09 jan. 2025.
- BOLLERSLEV, T. **Generalized Autoregressive Conditional Heteroskedasticity**. *Journal of Econometrics*, v. 31, p. 307–327, 1986. Acesso em: 18 mar. 2025.
- BROWN, S. J.; WARNER, J. B. **Using daily stock returns: The case of event studies**. *Journal of Financial Economics*, v. 14, n. 1, p. 3–31, 1985. Acesso em: 13 dez. 2025.
- CONT, Rama. **Empirical properties of asset returns: stylized facts and statistical issues**. *em: Quantitative Finance*, v. 1, n. 2, p. 223–236, 2001. Disponível <https://doi.org/10.1080/713665670>. Acesso em: 13 dez. 2025.
- CLARKE, Jonathan et al. **Fake news, investor attention, and market reaction**. *Information Systems Research*, v. 32, n. 1, p. 35–52, 2020. Acesso em: 13 dez. 2025.
- DAHL, David B. et al. **xtable: Export Tables to LaTeX or HTML**. R package version 1.8-4. Disponível em: <https://CRAN.R-project.org/package=xtable>. Acesso em: 02 set. 2025.
- ENGLE, R. F. **Autoregressive Conditional Heteroscedasticity with Estimates of the Variance of United Kingdom Inflation**. *Econometrica*, v. 50, n. 4, p. 987–1007, 1982. Acesso em: 21 jan. 2025.
- FAMA, Eugene F. **Efficient capital markets: A review of theory and empirical work**. *The Journal of Finance*, v. 25, n. 2, p. 383–417, 1970. Acesso em: 13 dez. 2025.
- GALANOS, Alexios. **rugarch: Univariate GARCH models**. R package version 1.5-4. Disponível em: <https://CRAN.R-project.org/package=rugarch>. Acesso em: 11 fev. 2025.
- GLOSTEN, L. R.; JAGANNATHAN, R.; RUNKLE, D. E. **On the Relation 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. Acesso em: 30 jun. 2025.
- GRAVES, Spencer. **FinTS: Companion to Tsay (2005) Analysis of Financial Time Series**. R package version 0.4-9. Disponível em: <https://CRAN.R-project.org/package=FinTS>. Acesso em: 07 fev. 2025.

GROLEMUND, Garrett; WICKHAM, Hadley. **Dates and Times Made Easy with {lubridate}**. Disponível em: <https://CRAN.R-project.org/package=lubridate>. Acesso em: 19 fev. 2025.

HONG, Harrison; STEIN, Jeremy C. **A unified theory of underreaction, momentum trading, and overreaction in asset markets**. The Journal of Finance, v. 54, n. 6, p. 2143-2184, 1999. Acesso em: 13 dez. 2025.

HYNDMAN, Rob et al. **{forecast}: Forecasting functions for time series and linear models**. R package version 8.24.0. Disponível em: <https://CRAN.R-project.org/package=forecast>. Acesso em: 05 mar. 2025.

HYNDMAN, Rob; KHANDAKAR, Yeasmin. **Automatic time series forecasting: the forecast package for {R}**. Disponível em: <https://CRAN.R-project.org/package=forecast>. Acesso em: 05 mar. 2025.

KASSAMBARA, Alboukadel. **ggpubr: 'ggplot2' Based Publication Ready Plots**. R package version 0.6.2. Disponível em: <https://CRAN.R-project.org/package=ggpubr>. Acesso em: 12 jan. 2025.

KOGAN, Shimon; MOSKOWITZ, Tobias J.; NIESSNER, Marina. **Social media and financial news manipulation**. Available at SSRN 3237763, 2021. Acesso em: 13 dez. 2025.

KOMSTA, Lukasz; NOVOMESTKY, Frederick. **moments: Moments, Cumulants, Skewness, Kurtosis and Related Tests**. R package version 0.14.1. Disponível em: <https://CRAN.R-project.org/package=moments>. Acesso em: 28 out. 2025.

LJUNG, G. M.; BOX, G. E. P. **On a measure of lack of fit in time series models**. Biometrika, v. 65, n. 2, p. 297–303, 1978. Disponível em: <https://www.jstor.org/stable/2335207>. Acesso em: 16 mai. 2025.

NELSON, D. B. **Conditional Heteroskedasticity in Asset Returns: A New Approach**. Econometrica, v. 59, n. 2, p. 347–370, 1991. Acesso em: 04 mar. 2025.

2024
OPENAI. **Hello GPT-4o**. OpenAI, 13 maio. Disponível em: <https://openai.com/index/hello-gpt-4o/>. Acesso em: 13 dez. 2025.

PEDERSEN, Thomas Lin. **patchwork: The Composer of Plots**. R package version 1.3.2. Disponível em: <https://CRAN.R-project.org/package=patchwork>. Acesso em: 22 ago. 2025.

PERLIN, Marcelo. **BatchGetSymbols: Downloads and Organizes Financial Data for Multiple Tickers**. R package version 2.6.4. Disponível em: <https://CRAN.R-project.org/package=BatchGetSymbols>. Acesso em: 10 jan. 2025.

TRAPLETTI, Adrian; HORNIK, Kurt. **tseries: Time Series Analysis and Computational Finance**. R package version 0.10-58. Disponível em: <https://CRAN.R-project.org/package=tseries>. Acesso em: 03 jun. 2025.

WICKHAM, Hadley et al. **Welcome to the {tidyverse}**. Disponível em: <https://CRAN.R-project.org/package=tidyverse>. Acesso em: 25 jan. 2025.

YILDIRIM, H.; BEKUN, F. V. **Predicting volatility of bitcoin returns with ARCH, GARCH and EGARCH models.** Future Business Journal, v. 9, n. 75, 2023. DOI: 10.1186/s43093-023-00255-8. Acesso em: 14 jun. 2025. ZHU, Hao. **kableExtra: Construct Complex Table with 'kable' and Pipe Syntax.** R package version 1.4.0. Disponível em: <https://CRAN.R-project.org/package=kableExtra>. Acesso em: 06 nov. 2025.