

Modelagem da volatilidade condicional dos preços do café arábica

Lucas Pereira Belo^{1†}, Eduardo Campana Barbosa², Paulo César Emiliano², Luciano Gonçalves Batista³

¹Mestrando no Programa de Estatística Aplicada e Biometria, Departamento de Estatística, Universidade Federal de Viçosa (UFV)

²Professor do Departamento de Estatística, Universidade Federal de Viçosa (UFV)

³Doutorando no Programa de Estatística Aplicada e Biometria, Departamento de Estatística, Universidade Federal de Viçosa (UFV)

Resumo: O café arábica (*Coffea arabica*) constitui mais de 60% da produção mundial de café. É valorizado por sua complexidade aromática e sabor adocicado. Este trabalho visa modelar a volatilidade dos preços do café arábica e ajustar um modelo para estimar suas variações. Os dados abrangem os preços mensais por saca de 60 kg de janeiro de 1995 a dezembro de 2023. Inicialmente, a série de preços foi transformada na série do logaritmo dos retornos. O modelo AR(1) com uma componente de cosseno foi utilizado para modelar essa periodicidade e a autocorrelação residual existentes. No entanto, o teste de Box-Pierce, aplicado à série de resíduos quadráticos, ainda indicou heterocedasticidade, devido a este fato, ajustou-se um modelo GARCH(1,1) com uma distribuição Skew t-Student para os resíduos. A escolha desse modelo se deu em função do menor valor do AIC (Akaike Information Criterion). Constatou-se também que os resíduos do modelo GARCH(1,1) não rejeitaram a hipótese de que são ruídos brancos. A projeção intervalar (95% de confiança) realizada para a volatilidade condicional indicou que os preços do café para os próximos seis meses podem cair 12% ou subir 14%.

Palavras-chave: heterocedasticidade; variância condicional; previsão.

Modeling the conditional volatility of arabica coffee prices

Abstract: Arabica coffee (*Coffea arabica*) accounts for more than 60% of the world's coffee production. It is valued for its aromatic complexity and sweet flavor. This work aims to model the volatility of Arabica coffee prices and fit a model to estimate their variations. The data covers monthly prices per 60 kg bag from January 1995 to December 2023. Initially, the price series was transformed into the series of logarithmic returns. The AR(1) model with a cosine component was used to model the existing periodicity and residual autocorrelation. However, the Box-Pierce test, applied to the series of squared residuals, still indicated heteroscedasticity. Therefore, a GARCH(1,1) model with a Skew t-Student distribution for the residuals was fitted. This model was chosen due to the lowest AIC (Akaike Information Criterion) value. It was also found that the residuals of the GARCH(1,1) model can be considered white noise. The interval projection for conditional volatility indicated that coffee prices over the next six months could fall by up to 12% or rise by up to 14%, approximately.

Keywords: heteroscedasticity; conditional variance; forecast.

† Autor correspondente: lucas.p.belo@ufv.br

Manuscrito recebido em: 22/07/2024

Manuscrito revisado em: 25/09/2024

Manuscrito aceito em: 30/09/2024

Introdução

Existem cerca de 104 espécies de café (Sakiyama *et al.* 2015), e o café arábica (*Coffea Arabica*) é uma das espécies mais relevantes economicamente (Bessada *et al.* 2018). Segundo Nagay (1999) as primeiras mudas de café arábica plantadas no Brasil, vieram da Guiana Francesa, tendo sido trazidas por Francisco Mello Palheta no ano de 1727. Este fruto tem suas origens atreladas a porção oriental do continente africano chamada de chifre da África, mais precisamente na Etiópia (NAGAY, 1999).

Conforme mencionado por Mapa (2017) e Foodchain (2018), o Brasil figura como o segundo maior consumidor de café em escala global. As regiões do país responsáveis pela produção de café arábica incluem o Sul, Sudeste, Centro-Oeste e Nordeste (Costa Júnior, 2012), com destaque para Minas Gerais, que detém cerca de 60% da produção nacional de café (FERREIRA e CAVATON, 2024).

O mercado nacional cafeeiro opera de acordo com o comportamento das negociações que ocorrem no âmbito das bolsas de Nova York e de Londres (CONAB, 2019). Na região sul do estado de Minas Gerais, existem algumas cooperativas que compram parte da produção dos pequenos e grandes produtores do estado e negociam as sacas de acordo com a bolsa de Nova York. De acordo com informações do site da cooperativa (COOXUPÉ, 2024), na cidade de Guaxupé, ela representa aproximadamente 15% da produção cafeeira do Brasil.

Devido à oscilação dos preços das sacas de café, apresentamos neste trabalho uma análise estatística que visa modelar a volatilidade condicional da série de preços do café arábica. Essa abordagem nos permite estimar as variações no preço deste produto no mercado financeiro. Assim, melhoramos nossa compreensão das flutuações de preço do café, proporcionando aos produtores maior controle nas negociações e embasamento para tomadas de decisão mais assertivas.

Referencial teórico

Para avaliar os riscos de uma carteira de ativos financeiros, é comum analisar as variações de preços desses ativos. A metodologia de log-retornos gera uma série de retornos que reflete ganhos ou perdas de capital provenientes de investimentos. De acordo com Moretin e Tolo (2006), trabalhar com retornos é preferível por serem dimensionalmente livres e possuírem propriedades estatísticas úteis, como estacionaridade e ergodicidade. Em séries financeiras, é frequente encontrar autocorrelação nos resíduos. Nesse contexto, os Modelos de Heterocedasticidade Condicional Auto-regressiva (ARCH) são comuns, mas apresentam limitações, o que levou Bollerslev (1986) a propor o modelo conhecido como modelo de heterocedasticidade condicional auto-regressiva generalizada de ordem (p,q) – GARCH (p,q) , capaz de capturar variações irregulares na variância das séries.

Série log de retornos

Séries de log de retorno, ou retorno logarítmico, é uma medida utilizada para calcular a variação percentual no preço de um ativo financeiro ao longo do tempo (MORETTIN E TOLOI, 2006). Além disso, um fato importante sobre os retornos logarítmicos é que eles são aditivos. Isso significa que, ao analisar o retorno logarítmico de uma carteira composta por diversos ativos, o retorno logarítmico total da carteira é simplesmente a soma dos retornos logarítmicos de cada ativo individualmente.

Para calcular a série log de retorno, é necessário definir o retorno simples (R_t), que é uma medida que expressa a variação percentual de um investimento em relação ao seu valor inicial em um determinado período. Suponha que em uma empresa não seja pago os dividendos no intervalo $(t-1, t)$, então o retorno simples é definido como:

$$R_t = \frac{P_t - P_{t-1}}{P_{t-1}} = \frac{\Delta P_t}{P_{t-1}}$$

em que,

- P_t é o preço do ativo no tempo t ;
- P_{t-1} é o preço do ativo no tempo anterior a t .

Assim, a série log de retorno (r_t) é definida como:

$$r_t = \log\left(\frac{P_t}{P_{t-1}}\right) = \log(1 + R_t).$$

Modelo autorregressivo-AR(p)

O processo autorregressivo de ordem p ou AR(p) é um modelo estatístico utilizado para descrever e prever valores de uma série temporal com base em seus próprios valores passados (MORETTIN E TOLOI, 2006). O termo "autorregressivo" indica que a variável dependente é regressada em suas próprias defasagens. O modelo AR(p) é representado por:

$$Y_t = \mu + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + \varepsilon_t, \quad \forall t = 1, 2, \dots, n$$

no qual,

- Y_{t-1}, \dots, Y_{t-p} são os p termos anteriores a Y_t nos tempos $t - 1, \dots, t - p$;
- ϕ_1, \dots, ϕ_p , representam os parâmetros;
- μ é a média geral;
- ε_t representa erro aleatório, assumindo que o mesmo seja um ruído branco com média zero e variância σ^2 , independente do tempo t , denotado como $\varepsilon_t \sim \mathcal{RB}(0, \sigma^2)$.

Modelos autorregressivos de heterocedasticidade condicional generalizada

Os modelos autorregressivos de heterocedasticidade condicional generalizada (GARCH) são amplamente utilizados para especificar de forma adequada as distribuições de probabilidade dos resíduos. Assim, esse modelo é aplicado com uma distribuição de probabilidade específica para modelar a volatilidade da série de retornos. Bollerslev (1986) observou que o modelo de heterocedasticidade condicional autorregressiva de ordem r , ARCH(r) não conseguia capturar a alta persistência da volatilidade em séries do sistema financeiro, o que levou à proposta do modelo GARCH(r,s), que inclui um termo de média móvel s . Além disso, segundo Bollerslev, Engle e Nelson (1994) o modelo GARCH, quando utilizado, apresenta em geral melhor poder explicativo, mesmo com um número significativamente maior de parâmetros, tornando-o muito mais utilizado que o modelo ARCH.

Um modelo GARCH (r,s) é definido por:

$$h_t = \alpha_0 + \sum_{i=1}^r \alpha_i X_{t-i}^2 + \sum_{j=1}^s \beta_j h_{t-j}, \quad (1)$$

em que,

- $h_t = \text{Var}(r_t | \tau_{t-1})$, τ_{t-1} representa toda a informação disponível até o instante $t - 1$;
- $X_t = \sqrt{h_t} \varepsilon_t$, retorno no t - ésimo tempo;
- α_0 é o termo de variância constante;
- α_i são os coeficientes dos termos ARCH;

- β_j são os coeficientes dos termos GARCH;
- h_{t-j}^2 é a variância condicional no tempo $t - j$.
- s corresponde à ordem de defasagem das volatilidades passadas;

Devem ser atendidas as condições: ε_t i.i.d. $(0,1)$, $\alpha_0 > 0$, $\alpha_i \geq 0$, $\beta_j \geq 0$, $\sum_{i=1}^q (\alpha_i + \beta_i) < 1$, $q = \max(r,s)$.

Devido a sua simplicidade e eficiência para capturar a volatilidade presente nos dados, o modelo GARCH(1,1) é comumente utilizado no processo de modelagem da volatilidade de séries de retorno, (BROOKS e BURKE, 2003). O modelo pode então ser expresso como:

$$h_t = \alpha_0 + \alpha_1 X_{t-1}^2 + \beta_1 h_{t-1}, \quad (2)$$

em que, $0 \leq \alpha_1, \beta_1 < 1, \alpha_1 + \beta_1 < 1$.

O termo alfa, α , indica quanto o último retorno observado tem de influência sobre a variância condicional hoje, já o termo β , indica quanto a volatilidade do período anterior deve influenciar a volatilidade hoje.

A soma dos coeficientes α e β é comumente chamada de persistência da volatilidade. De acordo com Lamounier (2006) quando a soma dos coeficientes é próxima de um, os efeitos da volatilidade tendem a se prolongar por um período maior de tempo e, quando a soma é próxima de zero, os efeitos da volatilidade são rápidos e a série tende a retornar ao seu comportamento histórico mais rapidamente.

Distribuição skew t-Student

O modelo GARCH(1,1) captura alguns graus de leptocurtose na distribuição dos retornos, conforme apontado por Baillie e Bollerslev (1986). No entanto, ao analisarmos dados diários ou de frequência mais alta, eles observam que a não normalidade dos retornos não é completamente capturada pelo modelo GARCH(1,1). Por isso, são empregadas funções de densidade não normais para capturar a assimetria e a leptocurtose presentes nas séries de retornos. A distribuição skew t-Student é uma alternativa, cuja função densidade de probabilidade é dada pela Equação (3),

$$f_Z(z) = 2t_\nu(z)T_{\nu+1} \left(\lambda_z \sqrt{\frac{1+\nu}{\nu+z^2}} \right), \quad -\infty < z < +\infty, \quad (3)$$

na qual,

- λ_z é o parâmetro de assimetria;
- t_ν é a função densidade de probabilidade de uma distribuição t-Student padrão com ν graus de liberdade
- $T_{\nu+1}$ é a função de distribuição acumulada de uma distribuição t-Student padrão com $\nu + 1$ graus de liberdade.

Mais detalhes aprofundados sobre a distribuição skew t-Student podem ser encontradas em Azzalini e Capitanio (2003).

Metodologia

A série temporal avaliada possui $n = 348$ observações, correspondendo ao preço médio mensal de uma saca de café de 60 kg do tipo 6 bebida dura bica corrida, com preço médio avaliado ao final de cada mês pela cooperativa da Cooxupé. Os dados abrangem o período de janeiro de 1995 a dezembro de 2023 e foram obtidos da seção de preços históricos disponível no portal da cooperativa Cooxupé (<https://www.cooxupe.com.br/>).

Inicialmente, foi calculada a série de log-retornos dos preços do café e logo em seguida foi verificado a Análise das funções de autocorrelação (ACF) e de autocorrelação parcial (PACF) das séries de preços do café sem o log de retornos denotada por y e, com a série log retorno denotada por $y01$. Para verificar a existência de alguma tendência na série log de retornos foi utilizado o teste de Cox Stuart, proposto por (COX E STUART, 1955).

Para verificar a existência de periodicidade foi utilizado o periodograma, que se baseia na decomposição da série temporal em uma série de *Fourier* (BARBOSA et al, 2014). No periodograma no eixo das ordenadas ficam localizadas as $n_1 = N/2$ frequências, calculadas como $f_i = i/n_1$ em que, i é uma sequência de valores de 1 a n_1 . No eixo das abscissas ficam localizadas as intensidades associadas as respectivas frequências, no qual:

$$I(f_i) = \frac{2}{n_i} \left\{ \left[\sum_{t=1}^{n_1} \varepsilon_t \cos \left(\frac{2\pi i}{n-1} \right) t \right]^2 + \left[\sum_{t=1}^{n_1} \varepsilon_t \sin \left(\frac{2\pi i}{n-1} \right) t \right]^2 \right\}. \quad (4)$$

Se comprovado que o valor da estatística do teste G de Fisher $[G = \max[I(f_i)] / \sum_{i=1}^{n_1} I(f_i)]$ é superior ao valor de $Z = 1 - \left(\frac{\alpha}{n_1} \right)^{\frac{1}{(n_1-1)}}$, conclui-se que a componente sazonal com periodicidade $s = 1/F_i$ é significativa (BARBOSA et al. 2014). Morettin e Tolo (2006) e Jenkins e Watts (1968) descrevem e discutem o teste e podem ser consultados a fim de se obter maiores detalhes.

Posteriormente, foi ajustado um modelo $AR(p)$ com uma componente cosseno para modelar a periodicidade encontrada e a autocorrelação residual remanescente na série. Na análise residual foram utilizados os testes de Shapiro Wilk para verificar a normalidade ademais o teste de Box-Pierce foi utilizado para verificar a existência de autocorrelação e heterocedasticidade nos resíduos, Ljung e Box (1978), apresentam a estatística do teste, que é definida por:

$$Q = n(n+2) \sum_{j=1}^m \frac{\hat{r}_j^2}{n-j}, \quad (5)$$

sendo \hat{r}_j a autocorrelação estimada da série no $lag j$; n é a quantidade de observações e; m é o número de lags que estão sendo testados.

Para contornar o problema da variância não constante nos resíduos, indicado pelo teste de Box-Pierce, foi ajustado um modelo $GARCH(p,q)$ com uma distribuição *Skew t-Student*. O modelo escolhido foi aquele que teve o menor valor do AIC (Akaike Information Criterion). Este, proposto por AKAIKE em (1974) é dado por:

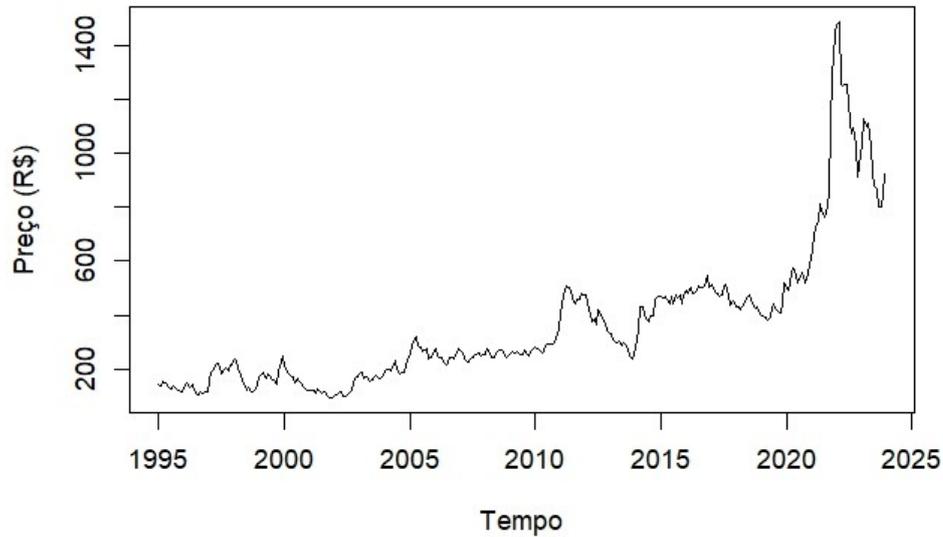
$$AIC = -2\log L(\hat{\theta}) + p \quad (6)$$

sendo $L(\hat{\theta})$ o valor da função de verossimilhança avaliada nos parâmetros $\hat{\theta}$. O termo p representa o número de parâmetros do modelo. As análises estatísticas foram realizadas no *software* livre R (R, 2024) utilizando os pacotes: `lmtest` (significância de coeficientes AR), `randtests` (para realizar o teste Cox Stuart), `descomponer` (Periodograma), `pctest` (teste G de Fisher), `tseries`(modelo AR), `fGarch`(modelo $Garch$).

Resultados e discussão

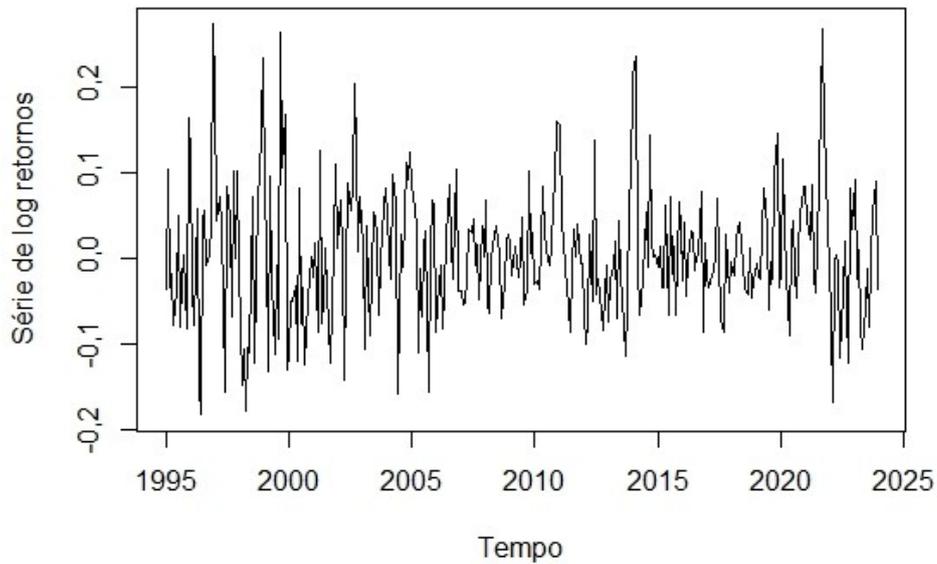
A Figura 1 ilustra a série histórica de preços médios mensais do café comercializado na cooperativa Cooxupé desde janeiro de 1995 até dezembro de 2023. Podemos observar uma tendência de crescimento ao longo dos anos. Já a Figura 2 representa a série log de retornos dos preços do café, destacando o período de 2021 e 2022. Diversas geadas em várias áreas do Brasil, especialmente na região sul de Minas, o aumento do consumo mundial e os impactos causados pela pandemia contribuíram para que a saca de café arábica alcançasse aproximadamente 1500 reais, que foi maior preço de toda a série histórica analisada. Esse aumento abrupto foi o principal fator que motivou a alta volatilidade no período.

Figure 1: Time series of Cooxupé's average monthly profits.



Source: from the authors (2024).

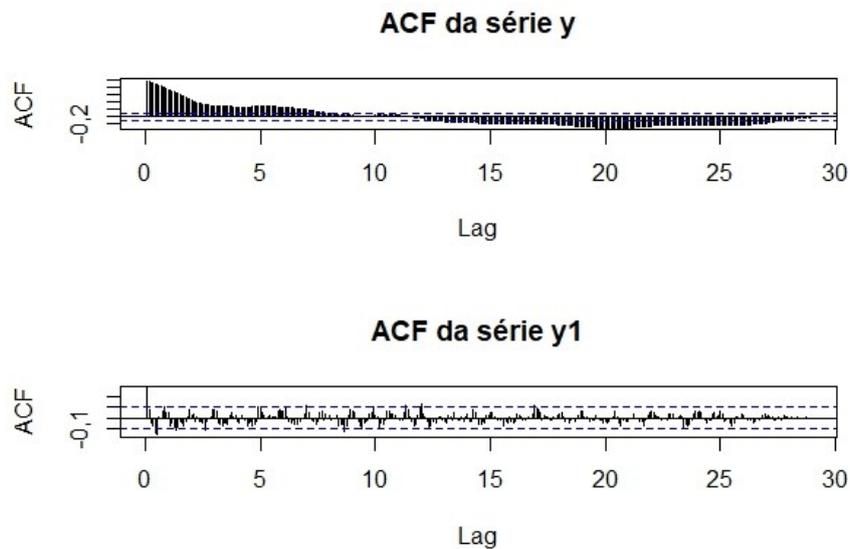
Figure 2: Log return series.



Source: from the authors (2024).

No processo de modelagem da volatilidade da série log retornos, foi plotado o gráfico ACF da série original de preços e da série de retornos. O ACF da série original de preços, foi nomeado por y e da série log retornos, denotada por y_1 , que visa analisar de forma visual possíveis indícios de autocorrelação presente nas séries, como pode ser observado na Figura 3.

Figure 3: Autocorrelation function (ACF) for the y and y1 series.

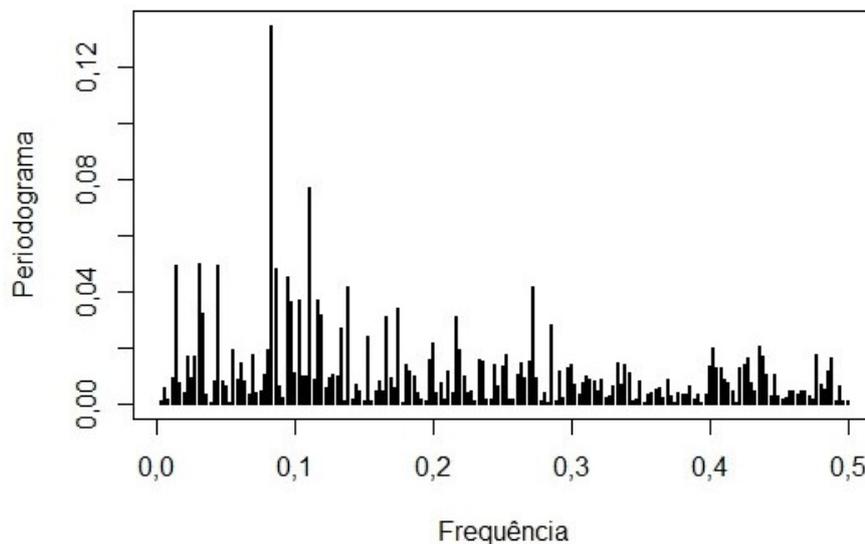


Source: from the authors (2024).

O teste de Cox - Stuart indicou que não existe indícios de tendência e portanto não rejeitou a hipótese nula ao nível de 5% de probabilidade, com um valor p de 49,52%. Por outro lado, o teste G de Fisher foi significativo ao nível de 5% de probabilidade, com um valor p de 0,0853%. O teste G de Fisher indicou que o valor exato da frequência é $f = 0.0833333$. Sendo assim, a frequência angular ($w = f/2\pi$) é representada por, $w = (2 \cdot \pi \cdot 0,0833333) = 0,52$ o que equivale a uma periodicidade de 12 meses.

Na Figura 4 é possível observar que a maior intensidade acontece aproximadamente na frequência $f = 0,08$.

Figure 4: Periodogram of the log return series.



Source: from the authors (2024).

Para escolher o melhor componente para o modelo AR(1), foram ajustados os componentes seno e cosseno. Como pode ser observado nas tabelas 1 e 2, o componente cosseno foi significativo ao nível de 5% de probabilidade. Então, o modelo AR(1) com a componente cosseno foi escolhido para modelar a volatilidade e capturar a periodicidade existente.

Table 1: Estimation of AR(1) and sine components.

	Estimativa	Valor p
AR(1)	0,2774813	6,785e-08 ***
Sen	-0,0108252	0,1249

Source: from the authors (2024).

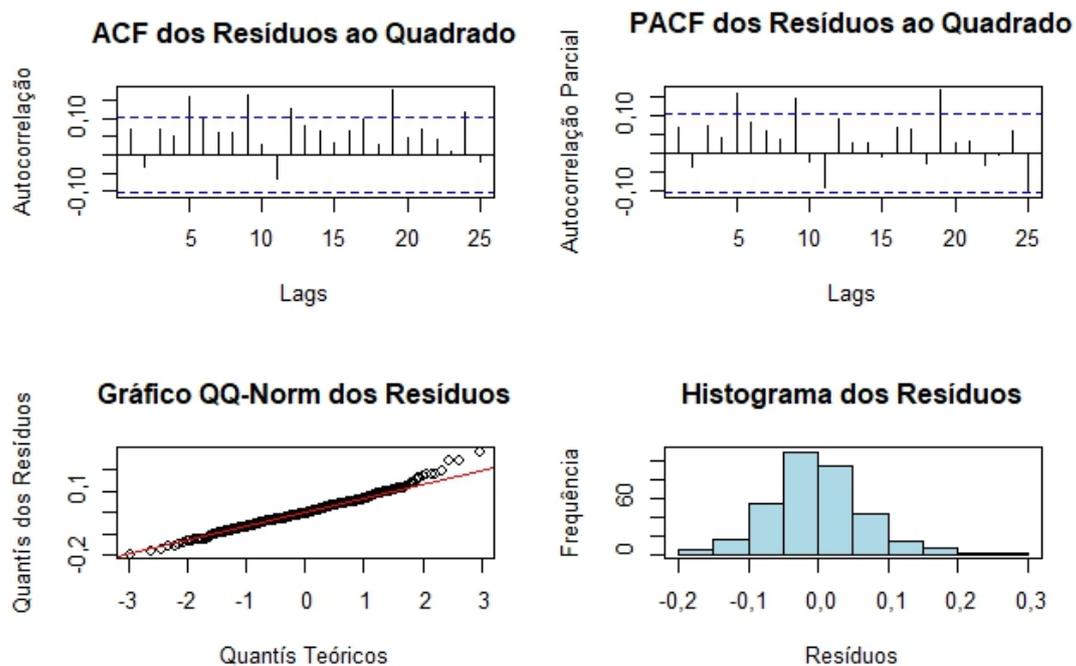
Table 2: Estimation of AR(1) and cosine components.

	Estimativa	Valor p
AR(1)	0,2472137	1,937e-06 ***
Coss	0,0254105	0,0001593 ***

Source: from the authors (2024).

Ao analisar os resíduos da série, Figura 5, observou-se que, visualmente, o quadrado médio dos resíduos indicou a presença de autocorrelação nos resíduos, que foi confirmado pelo teste de Box-Pierce com um valor p de 0,001519. Além disso, o gráfico Q-Q Plot apresenta oscilações nos extremos quando analisado seu ajuste.

Figure 5: Residue analysis graphs.



Source: from the authors (2024).

Para modelar a autocorrelação nos resíduos foi ajustado um modelo $GARCH(1,1)$ juntamente com alguma distribuição. Foram testadas as seguintes distribuições: Normal ou gaussiana (norm), proposta por Gaus (1816). A skew normal (snorm), abordada com cunho teórico e propriedades em Azzaline e Valle (1986) e com aplicações em Azzalini (2005). A distribuição generalizada de valores extremos (gve), cuja definição é abordada em Katz, Parlange e Naveau (2002). A skew t-Student (sstd) já apresentada anteriormente e a t-Student, que foi publicada por William Sealy Gosset com o pseudo nome student em 1908. A escolhida foi a skew t-Student, que representou o menor valor de AIC = -2,514545 e o maior valor do log de verossimilhança $\hat{l} = 442,5308$. Como pode ser observado na Tabela 3.

Table 3: Selection of the distribution that best fits the residuals.

Distribuição	log de verossimilhança	AIC
sstd	442,5308	-2,514545
std	440,8204	-2,510462
norm	438,2852	-2,501639
snorm	442,4382	-2,514013
gve	442,5224	-2,505558

Source: from the authors (2024).

Os parâmetros estimados foram: $\hat{\alpha}_1 = 0,04523$, $\hat{\beta}_1 = 0,9393$, $\hat{\nu} = 10$, $\hat{\lambda} = 1,159$ que foram significativos para 5% de significância, como indicado na Tabela 4.

Table 4: Estimated parameters for the GARCH(1,1) model.

	Estimativa	Erro padrão	valor t	Pr(> t)
ω	7.248e-05	6.526e-05	1.111	0.26670
α_1	4.523e-02	2.099e-02	2.155	0.03113 *
β_1	9.393e-01	2.586e-02	36.324	< 2e-16 ***
λ	1.159e+00	9.414e-02	12.308	< 2e-16 ***
ν	1.000e+01	3.837	2.606	0.00916 **

Source: from the authors (2024).

Portanto, o modelo final foi:

$$Y_t = 0.2774813Y_{t-1} + 0.0254105 \cdot \cos(0.52t) + X_t$$

em que, $X_t \sim \text{GARCH}(1,1)$ do tipo $X_t = \sqrt{h_t}\varepsilon_t$. No qual, $h_t = 0.04523X_{t-1}^2 + 0.9393h_{t-1}$, com $\varepsilon_t \sim \text{skew-t}(10, 1, 1.159)$.

O teste Ljung-Box foi aplicado aos resíduos padronizados e ao quadrado dos resíduos padronizados, e foram obtidos os resultados, como pode ser observado na Tabela 5.

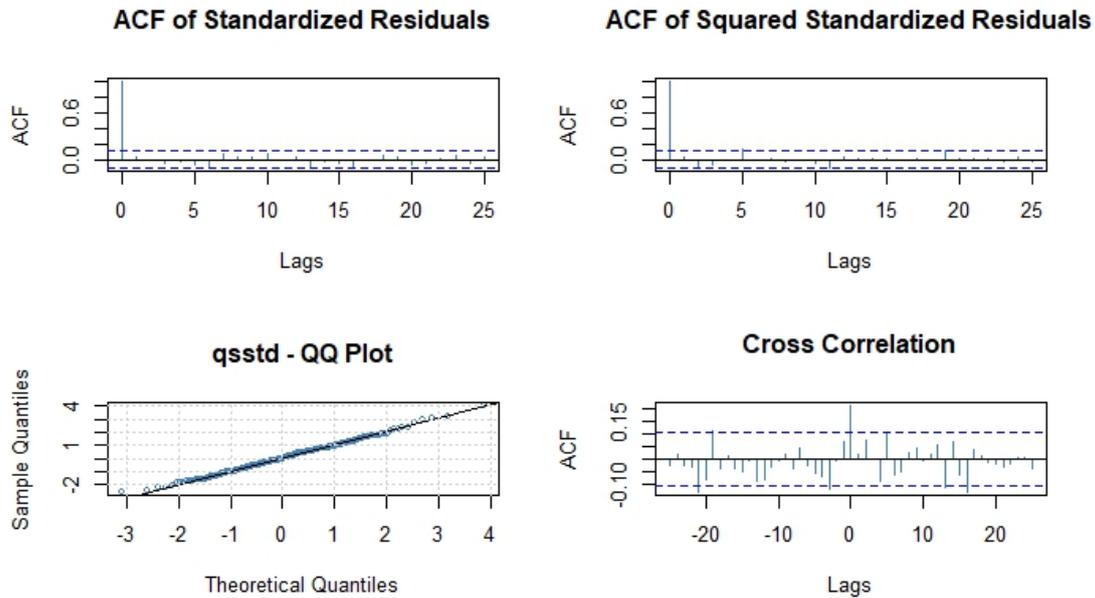
Table 5: Result of the Ljung-Box test applied to the residuals and squared residuals.

	Resíduos padronizados	Quadrados dos resíduos padronizados
Q(10)	10,892 (0,366)	11,928 (0,289)
Q(15)	17,174 (0,308)	16,854 (0,327)
Q(30)	23,112 (0,283)	22,248 (0,327)

Source: from the authors (2024).

Em parênteses, temos os p-valores associados aos resultados do teste de Ljung-Box para os lags (10, 15, 30). Como os valores são maiores que 0.05, não há evidência de autocorrelação significativa nos quadrados dos resíduos, indicando que o modelo captura bem a heterocedasticidade. Estes resultados indicam a não existência de autocorrelação nos resíduos. Note que o problema de autocorrelação foi contido pelo modelo ajustado, assim como indicou o teste Ljung-Box e como pode ser observado no ACF da Figura 6. Nota-se também que o gráfico do QQ plot apresentou um melhor ajuste quando comparado ao modelo sem correção da autocorrelação Figura 5.

Figure 6: Graphs of the residual analysis of the GARCH (1,1) model.



Source: from the authors (2024).

A Tabela 6 apresenta uma projeção intervalar da variabilidade esperada do preço médio mensal da *commodity* para os próximos 6 meses, que indicou que há possibilidade de queda no preço médio do café arábica em até 12% e subida de até 14%.

Table 6: Projeção intervalar da variabilidade esperada.

Previsão média	Erro médio	Desvio padrão	Intervalo inferior	Intervalo superior
0	0,06584302	0,06584302	-0,1214386	0,1400276
0	0,06588406	0,06588406	-0,1215143	0,1401149
0	0,06592444	0,06592444	-0,1215888	0,1402008
0	0,06596418	0,06596418	-0,1216621	0,1402853
0	0,06600327	0,06600327	-0,1217342	0,1403684
0	0,06604174	0,06604174	-0,1218052	0,1404502

Source: from the authors (2024).

Conclusões

O modelo ajustado conseguiu captar a periodicidade e a autocorrelação existente na série de log-retornos dos preços do café arábica, além da leptocurtose e curtose presentes nos resíduos. As previsões para os seis meses iniciais de 2024 indicam uma possibilidade de crescimento de até 14% ou queda de até 12% na volatilidade dos preços. A previsão mostrou-se satisfatória nos três primeiros meses do ano; porém, a volatilidade extrapolou os 14% no mês de abril. Esse fato se justifica porque o preço do café depende de fatores além da produção nacional. A variação não capturada ocorreu devido à queda abrupta da produção de café no Vietnã (segundo maior produtor de café arábica do mundo), causada por uma forte seca que atingiu o país.

Agradecimentos

Os autores agradecem a Capes, CNPq e a Universidade Federal de Viçosa que deram suporte financeiro para realização deste artigo.

References

- ACHIM, Z; HOTHORN, T.; Diagnostic Checking in Regression Relationships. **R News** 2(3), 7-10. 2002. Disponível em: <https://CRAN.R-project.org/doc/Rnews/>.
- AKAIKE, H.; A new look at the statistical model identification. **IEEE transactions on automatic control**, v. 19, n. 6, p. 716-723, 1974.
- AZZALINI, A.; The skew-normal distribution and related multivariate families. **Scandinavian journal of statistics**, v. 32, n. 2, p. 159-188, 2005.
- AZZALINI, A.; VALLE, A. D.; The multivariate skew-normal distribution. **Biometrika**, v. 83, n. 4, p. 715-726, 1996.
- AZZALINI, A.; CAPITANIO, A.; Distributions generated by perturbation of symmetry with emphasis on a multivariate skew t-distribution. **Journal of the Royal Statistical Society Series B: Statistical Methodology**, v. 65, n. 2, p. 367-389, 2003.
- BAILLIE, R. T.; BOLLERSLEV, T. The message in daily exchange rates: a conditional-variance tale. **Journal of Business and Economic Statistics**, v. 7, n. 3, p. 297-305, 1986.
- BARBOSA, E. C.; SÁFADI, T.; SILVA, C. H. O.; MANUELI, R. C. (2014). Box & Jenkins methodology: an application in raw milk data from the state of Minas Gerais. *Inst. Laticínios Cândido Tostes, Juiz de Fora*, v. 69, n. 2, p. 129-139. 2014
- BOLLERSLEV, T. Generalized autoregressive conditional heteroskedasticity. **Journal of Econometrics**, n. 31, p. 307-327, 1986.
- BOLLERSLEV T. A conditionally heteroskedastic time series model for speculative prices and rates of return. **Review of Economics and Statistics**, v. 69, p. 542-547. 1987.
- BOLLERSLEV, T.; ENGLE, R. F.; NELSON, D. B. Modelos ARCH. **Manual de econometria**, v. 4, p. 2959-3038, 1994.
- BROOKS, C.; BURKE, S. P. Information criteria for GARCH model selection. **The European journal of finance**, v. 9, n. 6, p. 557-580, 2003.
- CASELLA, G.; BERGER, R. L. **Statistical Inference**. Duxbury press, 2002.
- CAEIRO, F.; MATHEUS, A.; **randtests: Testing Randomness in R**. R package version 1.0.2, disponível em: <https://CRAN.R-project.org/package=randtests>.
- CONAB. Análise Mensal: Café. Maio, 2019. Brasília: Conab, 2019 a
- COSTA, C. H. G.; ANDRADE, F. T.; de CASTRO JÚNIOR, L. G. **ANÁLISE DA VIABILIDADE ECONÔMICO-FINANCEIRA DA CAFEICULTURA: UM ESTUDO NAS PRINCIPAIS REGIÕES PRODUTORAS DE CAFÉ DO BRASIL**. ABCustos, [S. l.], v. 7, n. 1, p. 30-52, 2012. DOI: 10.47179/abcustos.v7i1.141. Disponível em: <https://revista.abcustos.org.br/abcustos/article/view/141>. Acesso em: 19 jun. 2024.
- COOXUPÉ. 2024. Disponível em: <https://www.cooxupe.com.br/noticias/cooxupe-em-minas-gerais-e-modelo-de-cooperativismo-no-mundo/>. Acesso em: 06 jun. 2024.
- COX, D. R.; STUART, A. Some quick sign tests for trend in location and dispersion. **Biometrika**, v. 42, n. 1/2, p. 80-95, 1955.
- FERREIRA, L. T.; CAVATON, F. T. **Safra dos Cafés do Brasil foi estimada em 58,08 milhões de sacas para este ano de 2024**. Embrapa, 2024. Disponível em: <https://www.embrapa.br/busca-de-noticias/-/noticia/86520314/artigo—safra-dos-cafes-do-brasil-foi-estimada-em-5808-milhoes-de-sacas-para-este-ano-de-2024>. Acesso em: 10 abr. 2024.
- GAUSS, C. F.; **Bestimmung der genauigkeit der beobachtungen**. **Zeitschrift Astronomi** 1816, 1: 185-197.

- GODOI, L. G. A. **Distribuição t-assimétrica univariada: propriedades e inferência**. 2007. Tese de doutorado. Universidade de São Paulo.
- JENKINS, G. M.; WATTS, D. G. *Spectral Analysis and Its Applications*, **Holden-Day**, San Francisco, 1968.
- KATZ, R. W.; PARLANGE, M. B.; NAVEAU, P. Statistics of extremes in hydrology. **Advances in water resources**, v. 25, n. 8-12, p. 1287-1304, 2002.
- MCLEOD, A. I.; Test short time series for periodicity based on periodograms. 2016. Disponível em: <https://rdocumentation.org/packages/ptest/versions/1.0-8>.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2. ed. São Paulo: E.Blücher, 538 p. 2006.
- NAGAY, J. H. C. **Café no Brasil: dois séculos de história**. UNICAMP, Formação Econômica, Campinas,(3), p. 17-23, 1999.
- LAMOUNIER, W. M. Análise da volatilidade dos preços no mercado spot de cafés do Brasil. **Organizações Rurais e Agroindustriais/Rural and Agro-Industrial Organizations**, v. 8, n. 2, p. 160-175, 2006.
- LJUNG, G. M.; BOX, G. E. On a measure of lack of fit in time series models. **Biometrika**, 174 v. 65, n. 2, p. 297-303, 1978.
- ICO. a HISTÓRIA DO CAFÉ. Disponível em: https://www.ico.org/pt/coffee_storyp.asp. Acesso em: 12 mar. 2024.
- Parra, F.; **descomponer: Seasonal Adjustment by Frequency Analysis**. R package version 1.6. 2021. Disponível em: <https://CRAN.R-project.org/package=descomponer>.
- SAKIYAMA, N. S. O café arábica. In: SAKIYAMA, N. S.; MARTINEZ, H. E. P.; TOMAZ, M. A.; BORÉM, A. **Café arábica: do plantio à colheita**. Viçosa: UFV, 2015. p. 316.
- TRAPLETTI, A.; HORNIK, K.; **tseries: Time Series Analysis and Computational Finance** R package version 0.10-56. 2024. Disponível em: <https://CRAN.R-project.org/package=tseries>.
- WUERTZ, D.; CHALABI, Y.; SETZ, T.; MAECHLER, M.; BOSHPAKOV, G. N.; **fGarch: Rmetrics - Autoregressive Conditional Heteroskedastic Modelling**. R package version 4033.92, 2024. Disponível em: <https://CRAN.R-project.org/package=fGarch>.