

## Utilizando o modelo APARCH para a modelagem da volatilidade dos preços da soja.

Lucas Pereira Belo<sup>1</sup>  
Eduardo Campana Barbosa<sup>1</sup>  
Paulo César Emiliano<sup>1</sup>

<sup>1</sup>Universidade Federal de Viçosa, Departamento de Estatística, lucas.p.belo@ufv.br.

### INTRODUÇÃO

A soja é um dos principais produtos agrícolas do Brasil, sendo o segundo item mais exportado do país. Além da utilização do grão como alimento, a soja pode ser utilizada na produção de diversos outros produtos, dentre eles: Chocolate, temperos prontos, massas, alguns derivados de carne, mistura para bebidas, entre outros. O que reforça a importância deste produto para a economia brasileira.

### OBJETIVOS

Este trabalho tem por objetivo modelar a média e a variância condicional da série logarítmica dos retornos de preços da soja, ajustando um modelo que capture as variações ao longo do tempo. Além de permitir identificar períodos de maior e menor risco, estudos voltados para este tema, permitem uma melhor orientação na tomada de decisões no mercado.

### METODOLOGIA

Os dados avaliados referem-se aos preços semanais por 450 sacas de 50 kg de soja e contemplam o período de 30 de janeiro de 2011 até 07 de janeiro de 2024. A análise inicial ocorreu fazendo a série de log retornos, que é definida por Morettin e Toloi (2006) da seguinte forma:

**Definição 1:** Seja  $P_t$  o preço de um ativo em um instante  $t$ . Por conveniência supõe-se que não são pagos dividendos no intervalo  $(t, t-1)$ , definiu-se então o retorno simples como sendo a razão entre a variação dos preços do ativo no intervalo  $(t, t-1)$  dividido pelo preço no instante  $t-1$ , este valor denotaremos de  $R_t$ . O log retorno de um ativo é então definido como sendo:  $r_t = \log\left(\frac{P_t}{P_{t-1}}\right) = \log(1 + R_t)$ .

Em seguida, verificou-se o ACF(Autocorrelation Function) e PACF(Partial Autocorrelation Function) das séries log retorno dos preços da soja. Para verificar a existência de tendência e periodicidade determinística nos dados, foram aplicados os testes de Cox-Stuart e G de Fisher. Posteriormente, ajustou-se um modelo ARMA(p,q) para modelar a média condicional da série.

**Definição 2:** Os autores Morettin e Toloi (2006) apresentam o processo autorregressivo e de médias móveis, ARMA(p,q) é da seguinte forma:  $\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \dots + \phi_p \tilde{Z}_{t-p} + \varepsilon_t - \theta_1 \varepsilon_{t-1} - \dots - \theta_q \varepsilon_{t-q}$ . Sendo que um modelo frequentemente utilizado é o ARMA(1,1), onde  $p = q = 1$ , daí a equação anterior se reduz a,  $\tilde{Z}_t = \phi_1 \tilde{Z}_{t-1} + \varepsilon_t - \theta_1 \varepsilon_{t-1}$ , em que,  $\varepsilon_t \sim RB(0, \sigma^2)$ . O termo  $\phi$  é o parâmetro associado ao termo autorregressivo do modelo,  $\theta$  é o termo associado a média móvel.

Na análise residual foram utilizados os testes de Shapiro Wilk para verificar a normalidade, o teste de Box-Pierce (LJUNG e BOX, 1978) para verificar a existência de autocorrelação e heterocedasticidade nos resíduos. Com o intuito de modelar a volatilidade existente nos resíduos, ajustou-se um modelo autorregressivo de heteroscedasticidade condicional generalizada, conhecido como modelo GARCH(r,s), cuja definição pode ser encontrada em (MORETTIN E TOLOI, 2006). A alternativa proposta no estudo foi o modelo APARCH.

**Definição 3:** O modelo (Asymmetric Power ARCH) que é uma extensão dos modelos GARCH (Generalized Autoregressive Conditional Heteroskedasticity) apresentado por Ding, Granger e Engle (1993). Os autores apresentam o modelo que tem a seguinte forma:

$$\sigma_t^\delta = \omega + \sum_{i=1}^p \alpha_i \cdot (|\varepsilon_{t-1}| - \gamma_i \cdot \varepsilon_{t-1})^\delta + \sum_{j=1}^p \beta_j \cdot \sigma_{t-1}^\delta,$$

em que  $\omega, \alpha, \varepsilon, \gamma, \beta, \delta$ , são parâmetros a serem estimados pelo modelo. O modelo pressupõe as seguintes condições:  $\omega > 0$ ,  $0 < \sum \alpha_i < 1$ ,  $0 < \sum \beta_j < 1$  e  $\sum \alpha_i + \sum \beta_j < 1$ . A escolha dos modelos durante todo o processo foi baseada no

suficientes para rejeitar as hipóteses nulas de ausência de tendência e de periodicidade determinística nos dados respectivamente. Assim, foi ajustado um modelo ARMA(1,1), com um parâmetro autorregressivo e um de médias móveis, cujas estimativas dos parâmetros foram:  $\hat{\phi} = -0,8679$ ,  $\hat{\theta} = 0,8081$ , para modelar a média condicional da série de log-retornos (todos estes significativos a 5% de probabilidade). Para os resíduos, foi ajustado um modelo GARCH(1,1), que captura a variância condicional, assumindo uma distribuição de erro generalizada enviesada (Skewed Generalized Error Distribution-SGED) para os resíduos. Os parâmetros estimados (todos estes significativos a 5% de probabilidade) foram:  $\hat{\alpha}_1 = 0,1764$ ,  $\hat{\beta}_1 = 0,6754$ ,  $\hat{\gamma} = 0,8733$  (parâmetro de assimetria dos resíduos),  $\hat{\nu} = 1,7054$  (está relacionado à curtose da distribuição).

Embora o modelo tenha capturado parte da heterocedasticidade, o teste de Ljung-Box aplicado aos resíduos quadráticos mostrou um valor-p de 6,63% até a 10ª defasagem, sugerindo potencial refinamento. Como alternativa, ajustou-se um modelo APARCH(1,1) ajustado para variância da série, juntamente com um ARMA(1,1) para a média e uma distribuição de erro skew generalizada para os resíduos. Os parâmetros estimados, foram:  $\hat{\phi}^1 = -0,5023$ ,  $\hat{\theta}_1 = 0,4090$ ,  $\hat{\alpha}_1 = 0,1436$ ,  $\hat{\beta}_1 = 0,6258$ ,  $\hat{\gamma} = -0,1113$ ,  $\hat{\gamma} = 0,8826$ ,  $\hat{\nu} = 1,6916$ ,  $\hat{\delta} = 3,4552$ . A especificação final do modelo é então dada por:

$$Z_t = -0,5023Z_{t-1} + \varepsilon_t - 0,4090\varepsilon_{t-1},$$

$$\sigma_t^{3,3552} = 0,1436 \cdot (|\varepsilon_{t-1}| - 0,1113 \cdot \varepsilon_{t-1})^{3,3552} + 0,6258 \cdot \sigma_{t-1}^{3,3552},$$

com  $\varepsilon_t \sim \text{SGED} - (0,8826, 1,6916)$ .

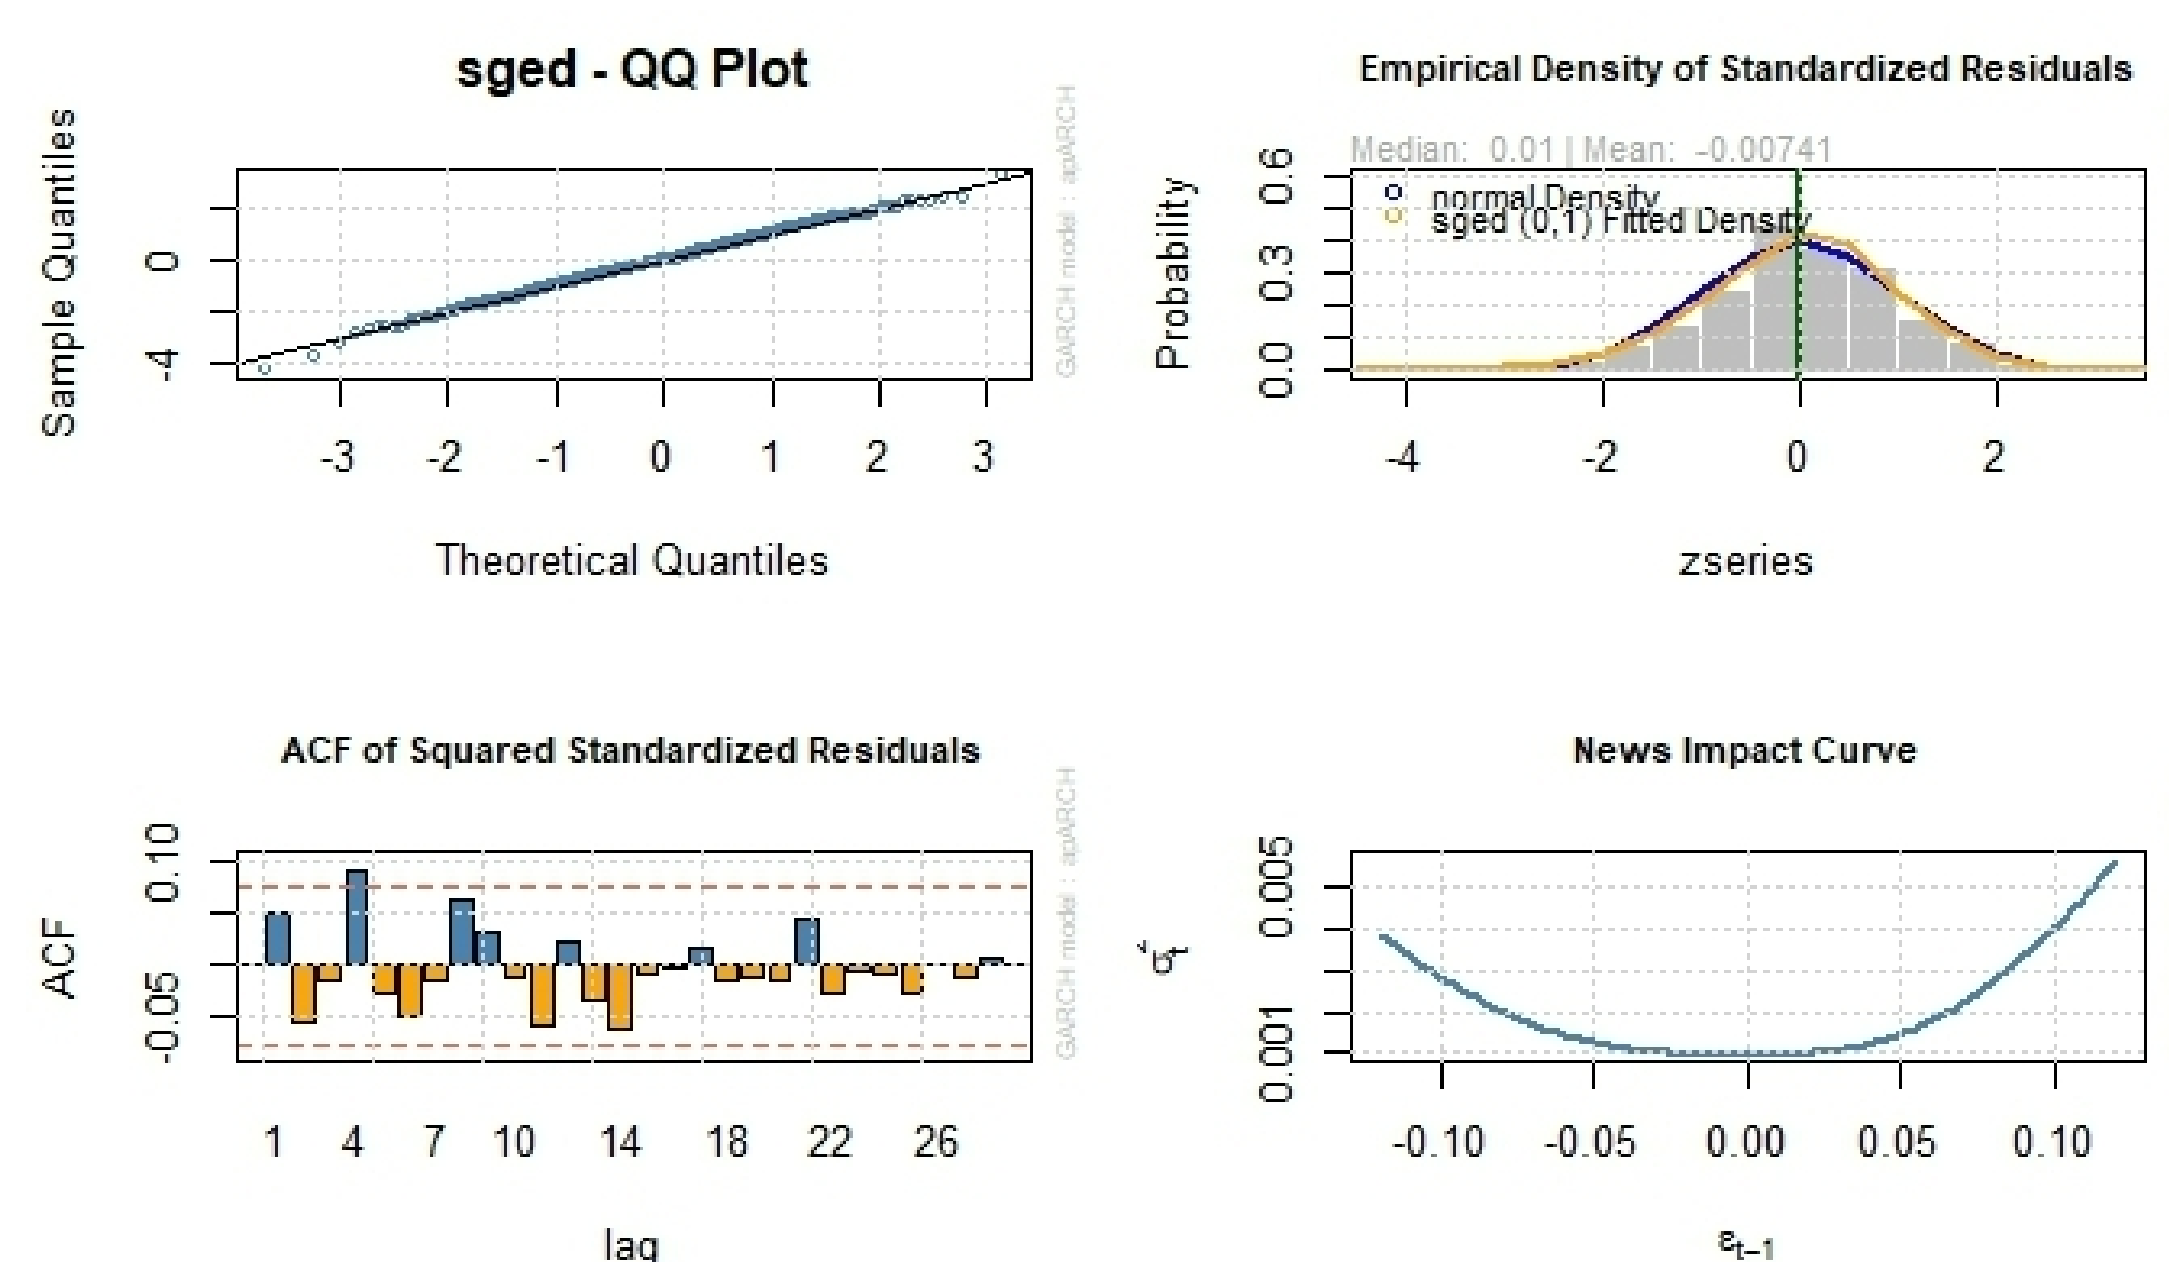


Figura 3: Gráfico da análise de resíduos do modelo APARCH(1,1)

### CONCLUSÃO


O modelo APARCH apresentou um ajuste superior ao GARCH, com funções log-verossimilhança ajustadas,  $\widehat{l}_{GARCH} = 1371.768$ ,  $\widehat{l}_{APARCH} = 1373.79$  além de melhores resultados na mitigação da heterocedasticidade, evidenciados pelo teste de Ljung-Box, que indicou um p-valor  $> 0,0920$  para a 9ª defasagem. Além disso, não foram evidenciados efeitos de alavancagem significativos nos dados.

### REFERÊNCIAS BIBLIOGRÁFICAS

- DING, Z.; GRANGER, C.W; ENGLE, R.F Uma propriedade de memória longa de retornos do mercado de ações e um novo modelo. **Revista de Finanças Empíricas**, v.1,n.1, págs. 83-106, 1993.
- 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.
- MORETTIN, P. A.; TOLOI, C. M. C. **Análise de séries temporais**. 2. ed. São Paulo: E.Blücher, 538 p. 2006.
- NELSON, D. B.; Conditional heteroskedasticity in asset returns: A new approach. **Econometrica: Journal of the econometric society**, p. 347-370, 1991.

### AGRADECIMENTOS

Os autores agradecem a Capes, ao programa de pós graduação em estatística aplicada e biometria e a Universidade Federal de Viçosa que deram suporte financeiro para realização deste trabalho.



### RESULTADOS E DISCUSSÕES

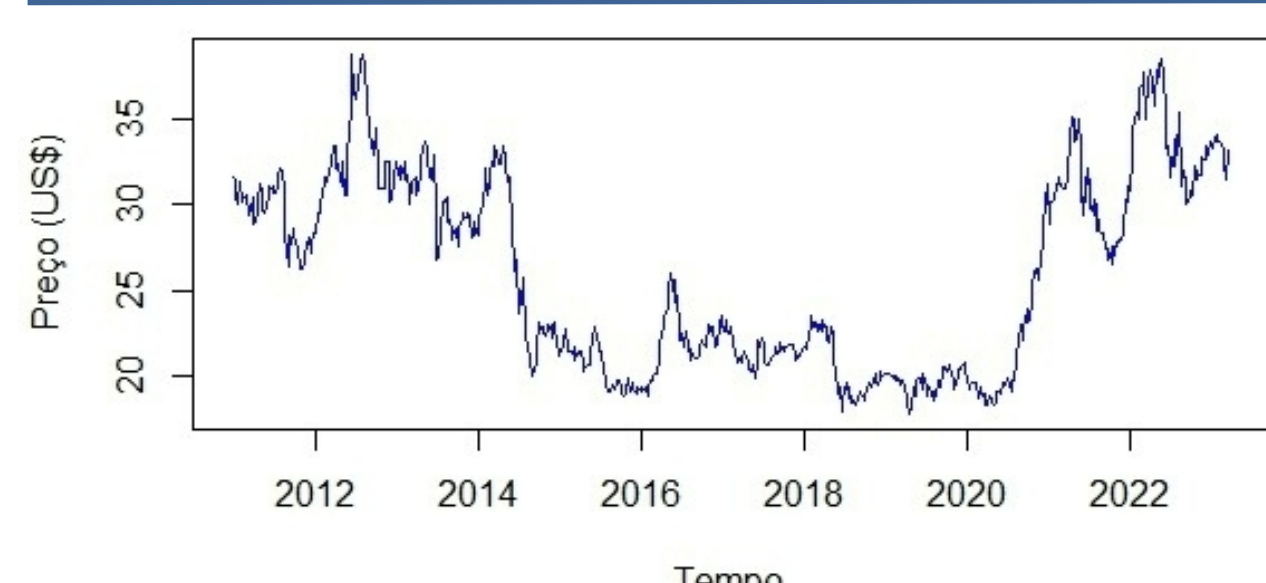


Figura 1: Série histórica de preços

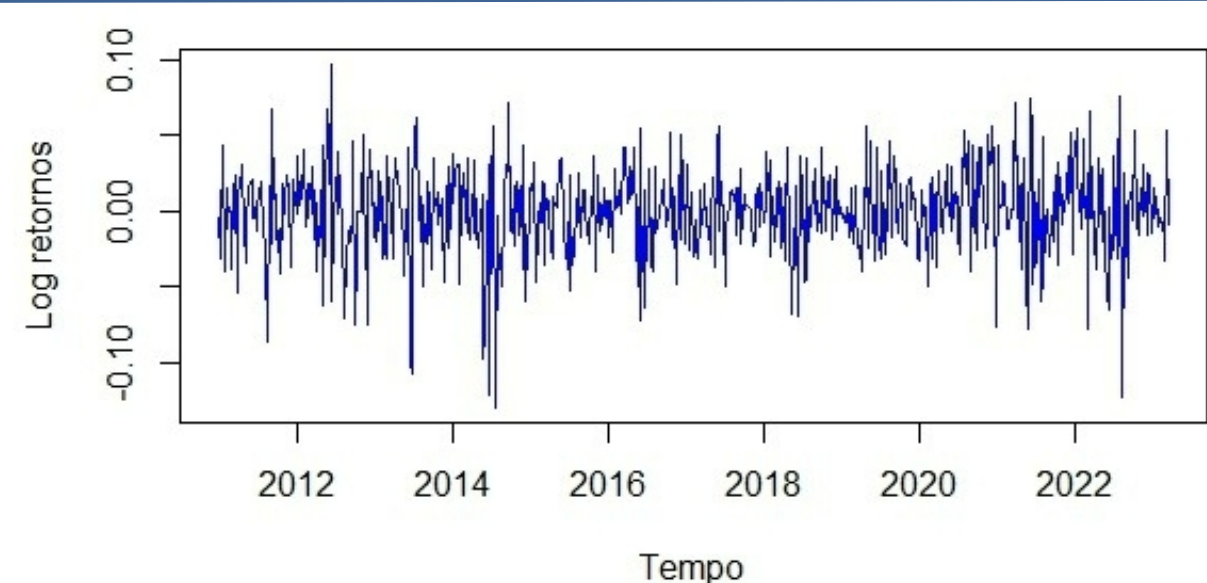


Figura 2: Série log retorno dos preços

Os testes de Cox-Stuart e G de Fisher apresentaram valores p de 28,66% e 91,88%, respectivamente, indicando que, ao nível de significância de 5%, não há evidências