

Identificação do Movimento Linear da Série Temporal do Volume Mensal de Transações da Criptomoeda Ethereum por meio do Modelo SARIMA[☆]

Identification of Linear Movement in the Time Series of Ethereum Cryptocurrency Monthly Transaction Volume through the SARIMA Model

Richard de Freitas Pinto^{1,†}, Viviane Leite Dias de Mattos², Luiz Ricardo Nakamura²

¹Universidade Federal do Rio Grande, PPGMC - Rio Grande, RS, Brasil

²Universidade Federal do Rio Grande, IMEF - Rio Grande, RS, Brasil

³Universidade Federal de Lavras, Departamento de Estatística - Lavras, MG, Brasil

[†]**Autor correspondente:** rfp2004@hotmail.com

Resumo

Esse trabalho apresenta a modelagem do volume mensal de transações da criptomoeda Ethereum por meio da metodologia de Box-Jenkins, envolvendo as etapas: análise exploratória, identificação, estimação e validação, algumas das quais executadas com a utilização de diferentes técnicas. O modelo encontrado pela modelagem SARIMA (Modelo autoregressivo integrado de médias móveis sazonal) conseguiu descrever o comportamento linear dos dados de forma satisfatória, mas não foi suficiente para descrever o comportamento da série, composta por movimento linear e não linear, sendo melhor representada por um modelo híbrido.

Palavras-chave

Série Temporal • Ethereum • SARIMA

Abstract

This work presents the modeling of the monthly volume of transactions of the Ethereum cryptocurrency through the Box-Jenkins methodology, involving the steps: exploratory analysis, identification, guarantee and validation, some of which performed using different techniques. The model found by the SARIMA modeling (Integrated autoregressive model of seasonal moving averages) was able to demonstrate the linear behavior of the data in a satisfactory way, but it was not enough to describe the behavior of the series, composed of linear and non-linear movement, being better represented by a hybrid model.

Keywords

Time Series • Ethereum • SARIMA

[☆]Este artigo é uma versão estendida do trabalho apresentado no XXV ENMC Encontro Nacional de Modelagem Computacional, XIII ECTM Encontro de Ciência e Tecnologia de Materiais, 9a MCSul Conferência Sul em Modelagem Computacional e IX SEMENGO Seminário e Workshop em Engenharia Oceânica, ocorrido em modo *webinar*, de 19 a 21 de outubro de 2022

1 Introdução

As criptomoedas, surgidas em 2009, são moedas virtuais que podem ser utilizadas em negociações e comercializadas entre usuários em sites de trocas. Como não estão vinculadas a nenhum país, precisam ser registradas e validadas individualmente em *blockchains*. Porém, são afetadas pelo mercado de ações, pois tem efeito direto sobre o comportamento dos investidores e, por consequência, na dinâmica dos preços. Pode-se considerar que as variações dos preços das ações, que estão sob a lei da oferta e procura, dependem das atitudes dos próprios investidores [1].

Dentro deste contexto, torna-se bastante pertinente conhecer o comportamento dos preços dos ativos financeiros, bem como a sua participação no mercado analisada em termos de volume comercializado, identificando o mecanismo gerador de seus dados por meio de sua modelagem, o que possibilita a previsão de valores futuros. Isto é extremamente importante para operadores do mercado de ações. Analisar o volume de transações mensais de ativos financeiros e realizar previsões para tentar identificar momentos de maior demanda é importante porque o alto valor no volume de transações em um mês significa alta demanda e influencia os valores da moeda[1]. O mercado se baseia na obtenção de lucro, razão pela qual os investidores têm interesse em prever as flutuações eventuais do preço das ações.

Existem várias técnicas de análise de séries temporais, entre as quais as técnicas econométricas e as estatísticas, que podem ser utilizadas para descrever dados passados. Estes dados podem apresentar comportamento linear, comportamento não linear ou ambos. Entre os modelos que identificam comportamentos lineares obtidos por meio de técnicas estatísticas, têm sido bastante utilizados aqueles oriundos da Metodologia de Box-Jenkins: os modelos autoregressivos integrados de médias móveis (ARIMA) e sua extensão na presença de sazonalidade, os modelos autoregressivos integrados de médias móveis sazonal (SARIMA).

De acordo com [2], uma característica marcante das séries financeiras é que elas, em geral, são não serialmente correlacionadas, mas dependentes. Esta propriedade faz com que modelos não lineares consigam descrever melhor o seu comportamento do que os lineares. Entretanto, quando houver algum tipo de autocorrelação, modelos híbridos são especialmente indicados. Usa-se um modelo linear para remover a autocorrelação antes da aplicação do modelo não linear.

Muitos estudos já desenvolvidos evidenciam a superioridade da acurácia das previsões obtidas com modelos híbridos, independentemente das técnicas ou métodos utilizados na hibridização, tais como em [3],[4] e [5], entre outros.

Este trabalho é a primeira etapa de um estudo que avalia o comportamento das transações da criptomoeda Ethereum, mais especificamente, o comportamento linear do seu volume de transações mensais por meio da metodologia de Box-Jenkins.

2 Materiais e Métodos

O modelo autorregressivo integrado e de médias móveis (ARIMA), que pode, segundo [2], apresentar ou não sazonalidade (SARIMA), pode ser analisado por uma metodologia bastante comum na utilização de modelos paramétricos, conhecida como abordagem de Box-Jenkins [6].

Este modelo considera dois tipos de componentes: os termos autoregressivos (AR) e os termos de médias móveis (MA), sendo identificado como ARMA (p, q). Neste caso, p representa a quantidade de termos autoregressivos e q representa a quantidade de termos de médias móveis em um modelo ARMA(p, q), podendo ser representado pela Eq. (1):

$$X_t - \mu = \phi_1(X_{t-1} - \mu) + \dots + \phi_p(X_{t-p} - \mu) + \epsilon_t - \theta_1\epsilon_{t-1} - \dots - \theta_q\epsilon_{t-q}, \quad (1)$$

onde: X_t é t-ésimo valor observado ($t = 1, 2, \dots, T$), T é a quantidade de observações, μ é a média do processo, i é a defasagem do processo autorregressivo ($i = 1, 2, \dots, p$), j é a defasagem do processo de médias móveis ($j = 1, 2, \dots, q$), ϕ_i é o coeficiente associado ao i-ésimo termo autorregressivos e θ_j é o coeficiente associado ao j-ésimo termo de médias móveis e $\epsilon_t \sim RB(0, \sigma^2)$ é o t-ésimo erro.

Essa função pode ser reescrita conforme Eq.(2):

$$\phi(B)\tilde{X}_t = \theta(B)\epsilon_t, \quad (2)$$

onde: $\tilde{X}_t = X_t - \mu$, $\phi_p(\cdot)$ e $\theta_q(\cdot)$ são polinômios de p e q, respectivamente, e $B(B^k X_t = X_{t-k})$ é o operador defasagem.

Quando $\mu = 0$, o modelo pode ser escrito conforme Eq.(3):

$$X_t = \theta_0 + \phi_1 X_{t-1} + \dots + \phi_p X_{t-p} + \epsilon_t - \theta_1 \epsilon_{t-1} - \dots - \theta_q \epsilon_{t-q}, \quad (3)$$

onde $\theta_0 = \mu(1 - \phi_1 - \dots - \phi_p)$.

Quando a série não for estacionária, é possível transformá-la por meio de diferenciações para adquirir esta propriedade. Se considerarmos d como a quantidade de diferenciações necessárias, teremos que um processo $\{X_t, t \in Z\}$ seguindo um modelo ARIMA(p, d, q) se $\Delta^d X_t$ seguir um modelo ARMA(p, q), ou seja:

$$\phi(B)\Delta^d X_t = \theta(B)\epsilon_t. \quad (4)$$

Quando a série apresenta sazonalidade é necessário ajustar a série original a um modelo ARIMA sazonal (SARIMA), que contém uma parte não sazonal com parâmetros (p, d, q) e uma parte sazonal com parâmetros (P, D, Q), conforme Eq. (5) [7]:

$$\phi_p(B)\phi_P(B^s)\Delta^d\Delta_s^D X_t = \theta_q(B)\theta_Q(B^s)\epsilon_t, \quad (5)$$

sendo: $\phi_p(B)$ é o operador autoregressivo de ordem p da parte não sazonal; $\phi_P(B^s)$ é operador autoregressivo P da parte sazonal; Δ é o operador da diferença; d é o número de diferenciação usados na parte não sazonal; D é o número de diferenciações usadas pela parte sazonal; X_t é o t -ésimo valor observado; $\theta_q(B)$ é o operador de médias móveis de ordem q da parte não sazonal; $\theta_Q(B^s)$ é o operador de médias móveis de ordem p da parte sazonal e s é o número de períodos da parte sazonal.

O modelo SARIMA tem sido utilizados em diversos estudos, com aplicações em diferentes áreas do conhecimento, obtendo bons resultados. Na modelagem da demanda de energia elétrica de Santa Catarina obteve um MAPE de 3,07% [8], enquanto na modelagem da demanda mensal de energia elétrica residencial no Rio grande do Sul, para cenários com pandemia e sem pandemia, obteve resultados do MAPE de, respectivamente, 2,391% e 4,323% [9]. Na modelagem do índice econômico utilizado na indústria de construção obteve um MAPE de 2,419% [10], enquanto o modelo encontrado para prever casos de COVID-19 nos EUA também foi considerado satisfatório [11].

Os dados analisados, obtidos em [12], se referem ao volume mensal negociado em dólares da criptomoeda Ethereum, no período de agosto de 2015 a abril de 2022, utilizada a transformação logarítmica para diminuir a variabilidade. Inicialmente foi feita uma análise exploratória dos dados com utilização de algumas técnicas gráficas e analíticas.

Na análise subsequente, com a identificação da presença de sazonalidade, a série foi dividida em período de ajuste ou de treinamento, de agosto de 2015 até abril de 2021, e período de validação ou de teste, de maio de 2021 até abril de 2022. Porém, uma análise visual no período de ajuste sugeriu a presença de uma quebra estrutural no início da série, sendo utilizado o teste de Chow [13] para averiguação. A comprovação da presença desta quebra eliminou os dois primeiros anos do período de ajuste.

No novo intervalo associado ao período de ajuste foi avaliada a estacionariedade da parte não sazonal por meio dos testes Dickey-Fuller Aumentado (ADF) [14] e KPSS [15], e da parte sazonal pelos testes HEGY [16] e OSCB [17].

Embora tenham sido construídos os gráficos da função de autocorrelação e da função de autocorrelação parcial, para parte não sazonal e para a parte sazonal, normalmente utilizados para estimar os valores de p, q, P e Q , neste estudo foram avaliadas todas as combinações possíveis desses parâmetros entre zero e quatro, totalizando 625 modelos SARIMA. Foi utilizado o Critério de informação de Bayesiano (BIC) [18] para identificar, entre estes, os dez modelos mais parcimoniosos, que formaram o conjunto de modelos candidatos.

Além disso, foi realizada uma análise dos resíduos para verificar as suposições do modelo teórico utilizado: independência verificada pelo teste Ljung-Box [6], normalidade verificada pelo teste Jarque-Bera [19] e a homocedasticidade verificada pelo teste ARCH [20].

A acurácia da previsão foi avaliada no período de validação ou teste por meio das seguintes medidas: raiz do erro quadrático médio (RMSE), erro absoluto médio (MAE) e o erro percentual absoluto médio (MAPE). Complementa a análise a previsão com os respectivos intervalos de confiança, representados em um gráfico em linhas.

A análise estatística foi realizada por meio do software R [21], utilizando as bibliotecas forecast [22], tseries [23], e1071 [24], FinTS [25], stats [21], ggplot2 [26] e o software Gretl [27]. Na análise inferencial foi adotado o nível de significância de 0,05.

3 Resultados e Discussões

A análise exploratória dos dados encontrou as medidas resumo apresentadas na Tabela 1, onde é possível constatar a presença de uma grande variabilidade evidenciada por um alto valor do coeficiente de variação. O coeficiente de assimetria confirma que a distribuição dos dados apresenta assimetria positiva elevada, existindo uma concentração nos valores menores da série, enquanto o coeficiente de curtose indica que a distribuição é classificada leptocúrtica, possuindo caudas pesadas.

Uma análise de variância não paramétrica, realizada por meio do teste de Friedman, encontrou evidências da presença de sazonalidade na série ($\chi^2 = 45, 205, df = 11, \text{valor-p} = < 0, 01$). Entretanto, o teste de Chow encontra evidências da presença de quebra estrutural ($F = 6,3749, \text{valor-p} = 0,0027$), razão pela qual o período analisado

Tabela 1: Medidas descritivas da série do volume mensal de transações da criptomoeda Ethereum, AGO 2017 - ABR 2021.

Período	Média (US\$)	Mediana (US\$)	Desvio padrão (US\$)	Coefficiente de variação (%)	Assimetria	Curtose
ago2015 – abr2021	$2,180 \times 10^{11}$	$0,665 \times 10^{11}$	$3,112 \times 10^{11}$	142,771	1,979	4,019
ago2017 – abr2021	$2,819 \times 10^{11}$	$2,234 \times 10^{11}$	$2,791 \times 10^{11}$	99,023	1,475	1,773

é reduzido: de agosto de 2017 até abril de 2021, cujas medidas resumo também estão apresentadas na Tabela 1. Observa-se que, embora a intensidade de algumas propriedades tenham sido amenizadas, elas persistem.

Em sequência, após a separação dos últimos 12 meses para a validação, foi avaliada a estacionariedade do período de ajuste. Na análise da parte não sazonal, os testes ADF e o teste KPSS concordam que a série é estacionária em nível em torno da tendência. Entretanto, na parte sazonal os testes HEGY e OCSB discordam, identificando estacionariedade em primeira diferença e ao nível, respectivamente. Em função disso, foram considerados os modelos SARIMA(p,0,q)(P,0,Q)₁₂ e SARIMA(p,0,q)(P,1,Q)₁₂. Os resultados apresentados a seguir se referem ao modelo SARIMA(p,0,q)(P,1,Q)₁₂, que se mostrou superior.

Os gráficos da função de autocorrelação (FAC) e da função de autocorrelação parcial (FACP) da parte não sazonal e da parte sazonal estão apresentados, respectivamente, na Fig.1 e Fig.2. Pode ser observado no gráfico (a) da Fig.1 que a FAC decai lentamente exponencialmente, enquanto no gráfico (b) da mesma figura a FACP tem uma queda brusca na primeira defasagem, sugerindo um modelo AR(1). No gráfico (a) da Fig.2 que a FAC tem um comportamento senoidal decrescente, enquanto no gráfico (b) da mesma figura a FACP tem uma queda brusca a partir da segunda defasagem, sugerindo um modelo AR(2).

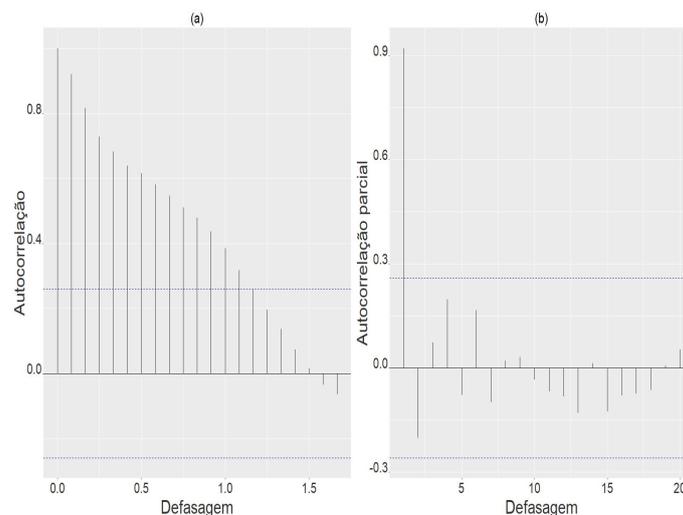


Figura 1: FAC e FACP da parte não sazonal do logaritmo da série do volume de transações mensal da criptomoeda Ethereum, AGO 2017 - ABR 2021.

A análise realizada sugere um modelo SARIMA(1,0,0)(2,1,0)₁₂. Entretanto, considerando a subjetividade da representação gráfica, o conjunto de modelos candidatos foi formado pelos dez modelos mais parcimoniosos entre os 625 modelos analisados.

A Tabela 2 apresenta o conjunto de modelos candidatos com o respectivo critério de informação e os valores p dos testes Ljung-BOX, Jarque-Bera e ARCH aplicados aos seus resíduos, sendo identificado o modelo SARIMA(1,0,0)(0,1,0)₁₂ como mais parcimonioso. Além disso, também é possível observar que todos os modelos candidatos não apresentaram evidências de autocorrelação, não normalidade e heterocedasticidade, cumprindo as suposições do modelo teórico.

A Tabela 3 apresenta as medidas de acurácia da previsão de todos os modelos candidatos, sendo identificado o modelo SARIMA(1,0,1)(2,1,0)₁₂ como o modelo de melhor capacidade preditiva, por apresentar menor RMSE, MAE e MAPE. Chama-se a atenção para o fato que houve concordância entre as três métricas utilizadas. Chama-se também a atenção para o fato de que mesmo havendo concordância entre as três métricas utilizadas, o modelo encontrado não apresentou boa capacidade preditiva, sugerindo que a utilização de apenas um modelo linear não

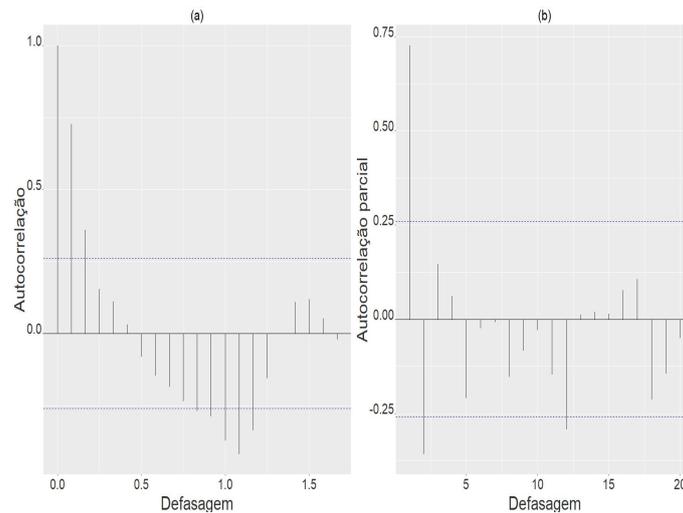


Figura 2: FAC e FACP da parte sazonal do logaritmo da série do volume de transações mensal da criptomoeda Ethereum, AGO 2017 - ABR 2021.

consegue descrever o seu comportamento.

Tabela 2: Critério de informação BIC e os resultados dos testes Ljung-Box, Jarque-Bera e ARCH para os modelos candidatos, AGO 2017 – ABR 2021.

Modelo	BIC	Valor-p		
		Ljung-Box	Jarque-Bera	ARCH
SARIMA(1,0,0)(0,1,0) ₁₂	43,80	0,379	0,959	0,537
SARIMA(1,0,1)(0,1,0) ₁₂	44,19	0,800	0,732	0,814
SARIMA(2,0,0)(0,1,0) ₁₂	45,08	0,645	0,908	0,789
SARIMA(3,0,0)(0,1,0) ₁₂	46,00	0,871	0,516	0,604
SARIMA(1,0,3)(0,1,0) ₁₂	46,52	0,996	0,402	0,050
SARIMA(3,0,0)(0,1,1) ₁₂	47,12	0,510	0,774	0,470
SARIMA(1,0,0)(0,1,1) ₁₂	47,15	0,186	0,918	0,592
SARIMA(1,0,0)(1,1,0) ₁₂	47,26	0,332	0,968	0,586
SARIMA(1,0,1)(2,1,0) ₁₂	47,56	0,403	0,895	0,973
SARIMA(1,0,1)(0,1,1) ₁₂	47,63	0,674	0,847	0,791

Tabela 3: RMSE, MAE e MAPE para os modelos candidatos, MAI 2021 – ABR 2022.

Modelo	RMSE(US\$)	MAE(US\$)	MAPE(%)
SARIMA(1,0,0)(0,1,0) ₁₂	1,09×10 ¹²	8,17×10 ¹¹	187,69
SARIMA(1,0,1)(0,1,0) ₁₂	1,12×10 ¹²	8,38×10 ¹¹	193,06
SARIMA(2,0,0)(0,1,0) ₁₂	1,13×10 ¹²	8,48×10 ¹¹	196,27
SARIMA(3,0,0)(0,1,0) ₁₂	1,13×10 ¹²	8,36×10 ¹¹	194,25
SARIMA(1,0,3)(0,1,0) ₁₂	1,14×10 ¹²	8,13×10 ¹¹	194,22
SARIMA(3,0,0)(0,1,1) ₁₂	1,27×10 ¹²	9,53×10 ¹¹	226,18
SARIMA(1,0,0)(0,1,1) ₁₂	1,19×10 ¹²	8,85×10 ¹¹	210,93
SARIMA(1,0,0)(1,1,0) ₁₂	1,21×10 ¹²	9,13×10 ¹¹	213,99
SARIMA(1,0,1)(2,1,0) ₁₂	0,85×10 ¹² *	5,86×10 ¹¹ *	145,23*
SARIMA(1,0,1)(2,1,1) ₁₂	1,24×10 ¹²	9,29×10 ¹¹	220,87

Obs. (*) indicador para menor valor

A Tabela 4 apresenta os valores observados, os valores previstos e os respectivos intervalos de confiança para

o período de validação do modelo selecionado, onde é possível constatar que os valores observados nos meses de janeiro, fevereiro, março e abril não pertenceram aos respectivos intervalo de confiança. O resultado dessa análise vai ao encontro do resultado encontrado anteriormente, por também identificar que modelo encontrado não apresenta boa capacidade preditiva.

Tabela 4: Valores observados, valores previstos e respectivos intervalos de confiança do modelo SARIMA(1,0,1)(2,1,0)₁₂, MAI 2021 – ABR 2022

Mês	Observado(US\$) (US\$)	Previsto (US\$)	I.C 0.95(US\$)	
			Mínimo	Máximo
Maio	15,10×10 ¹¹	11,22×10 ¹¹	6,17×10 ¹¹	2,04×10 ¹²
Junho	8,13×10 ¹¹	6,00×10 ¹¹	2,56×10 ¹¹	1,40×10 ¹²
Julho	5,91×10 ¹¹	5,73×10 ¹¹	2,33×10 ¹¹	1,40×10 ¹²
Agosto	7,03×10 ¹¹	6,85×10 ¹¹	2,75×10 ¹¹	1,70×10 ¹²
Setembro	6,53×10 ¹¹	8,56×10 ¹¹	3,43×10 ¹¹	2,13×10 ¹²
Outubro	5,74×10 ¹¹	6,65×10 ¹¹	2,66×10 ¹¹	1,66×10 ¹²
Novembro	5,73×10 ¹¹	8,50×10 ¹¹	3,40×10 ¹¹	2,12×10 ¹²
Dezembro	6,21×10 ¹¹	9,37×10 ¹¹	3,75×10 ¹¹	2,34×10 ¹²
Janeiro	4,91×10 ¹¹	16,18×10 ¹¹	6,48×10 ¹¹	4,04×10 ¹²
Fevereiro	4,16×10 ¹¹	15,59×10 ¹¹	6,24×10 ¹¹	3,89×10 ¹²
Março	4,36×10 ¹¹	16,01×10 ¹¹	6,41×10 ¹¹	3,99×10 ¹²
Abril	2,69×10 ¹¹	23,36×10 ¹¹	9,35×10 ¹¹	5,83×10 ¹²

4 Conclusões

A partir do estudo realizado, acerca do volume mensal comercializado da criptomoeda Ethereum, foi constatado que a série analisada necessita de uma modelagem híbrida que consiga captar relações lineares e não lineares. Também constatou-se que a utilização de um modelo linear foi adequada, embora não suficiente, tendo em vista a correlação serial apresentada pelos dados conseguiu ser eliminada, pois as inovações se comportaram como um ruído branco com média zero e variância constante. Após remover esta correlação serial, é possível que um modelo não linear consiga complementar a análise realizada. Neste caso, recomenda-se o modelo autoregressivo heterocedástico condicional (GARCH), que tem obtido bons resultados.

Por outro lado, salientamos que algumas das técnicas utilizadas nesta modelagem apresentaram um bom desempenho, como os gráficos da FAC e da FACP da parte sazonal e da parte não sazonal, que identificaram um modelo muito aproximado ao SARIMA(1,0,1)(2,1,0)₁₂, considerado o de melhor capacidade preditiva para a relação linear.

Vale salientar também que o teste HEGY apresentou melhor desempenho na identificação na quantidade de diferenciações necessárias para a parte sazonal da série se tornar estacionária. Embora os resultados não tenham sido mostrados neste texto, também foram realizadas modelagens considerando que a parte sazonal seria estacionária em nível de acordo com que foi encontrado no teste OCSB. Entretanto, esses modelos apresentaram um desempenho ainda pior.

Para trabalhos futuros, além de melhorar o modelo obtido com a modelagem da relação não linear, sugere-se também utilizar o volume de transações comerciais da criptomoeda Ethereum como uma variável adicional a um modelo de previsão para os valores da sua cotação.

Referências

- [1] L. H. A. Müller, “Caminhos e sentidos da informação no mercado de ações,” *International Review of Economics Finance*, vol. 4, no. 6, pp. 133–164, 2005.
- [2] P. A. Morettin, *Econometria financeira: um curso em séries temporais financeiras*, 3^a ed. São Paulo: Blucher, 2011.
- [3] J. D. V. Henao, V. M. R. Mejia, e C. J. F. Cardona, “Electricity demand forecasting using a SARIMA-multiplicative single neuron hybrid model,” *DYNA*, vol. 80, pp. 4–8, 2013. Disponível em: <http://ref.scielo.org/b84jzw>

- [4] C. Sigauke, “Forecasting medium-term electricity demand in a South African electric power supply system,” *Journal of Energy in Southern Africa*, vol. 28, pp. 54–67, 2017. Disponível em: <https://doi.org/10.17159/2413-3051/2017/v28i4a2428>
- [5] Y. Yang, Y. Chen, Y. Wang, C. Li, e L. Li, “Modelling a combined method based on ANFIS and neural network improved by DE algorithm: A case study for short-term electricity demand forecasting,” *Applied Soft Computing*, vol. 49, pp. 663–675, 2016. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1568494616303891>
- [6] G. E. P. Box e G. M. Jenkins, *Time series analysis : forecasting and control*. San Francisco: Holden-Dayr, 1976.
- [7] P. A. Morettin e C. M. de Castro Toloi, *Análise de séries temporais*, 3ª ed. São Paulo: Blucher, 2018.
- [8] V. L. D. de Mattos, L. R. Nakamura, A. C. Konrath, e A. C. Bornia, “Modeling the commercial electricity demand in Santa Catarina, using the Box-Jenkins methodology,” *International Journal of Development Research*, vol. 11, 2021, artigo no. 22265. Disponível em: <https://doi.org/10.37118/ijdr.22265.06.2021>
- [9] T. P. Pereira, V. L. D. de Mattos, A. C. Konrath, A. Bornia, L. R. Nakamura, e V. Vargas, “Estudo sobre testes de sazonalidade no volume mensal de transações da criptomoeda Ethereum,” em *Anais da 20ª Mostra de Produção Universitária (MPU – FURG)*. Rio Grande, Brasil: Universidade Federal do Rio Grande, 2021.
- [10] P. S. Thomaz e V. L. D. de Mattos, “Predicting the GFCF of the brazilian construction industry: a comparison between holt winters’ and SARIMA models,” *Revista Gestão Industrial*, vol. 15, no. 1, pp. 180–196, 2019. Disponível em: <https://doi.org/10.3895/gi.v15n1.8590>
- [11] I. Tahyudin, R. Wahyudi, e H. Nambo, “SARIMA-LSTM combination for COVID-19 case modeling,” *IJUM Engineering Journal*, vol. 23, no. 2, p. 171–182, 2022. Disponível em: <https://doi.org/10.31436/iiumej.v23i2.2134>
- [12] (2022) Coinmarketcap. Disponível em: <https://coinmarketcap.com/>
- [13] G. C. Chow, “Tests of equality between sets of coefficients in two linear regressions,” *Econometrica*, vol. 28, no. 3, pp. 591–605, 1960. Disponível em: <https://doi.org/10.2307/1910133>
- [14] D. A. Dickey e W. A. Fuller, “Likelihood ratio statistics for autoregressive time series with a unit root,” *Econometrica*, vol. 49, no. 4, pp. 1057–1072, 1981. Disponível em: <https://doi.org/10.2307/1912517>
- [15] D. Kwiatkowski, P. C. Phillips, P. Schmidt, e Y. Shin, “Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?” *Journal of Econometrics*, vol. 54, no. 1, pp. 159–178, 1992. Disponível em: [https://doi.org/10.1016/0304-4076\(92\)90104-Y](https://doi.org/10.1016/0304-4076(92)90104-Y)
- [16] S. Hylleberg, R. Engle, C. Granger, e B. Yoo, “Seasonal integration and cointegration,” *Journal of Econometrics*, vol. 44, no. 1, pp. 215–238, 1990. Disponível em: [https://doi.org/10.1016/0304-4076\(90\)90080-D](https://doi.org/10.1016/0304-4076(90)90080-D)
- [17] D. R. Osborn, A. P. L. Chui, J. P. Smith, e C. R. Birchenhall, “Seasonality and the order of integration for consumption,” *Oxford Bulletin of Economics and Statistics*, vol. 50, no. 4, pp. 361–377, 1988. Disponível em: <https://doi.org/10.1111/j.1468-0084.1988.mp50004002.x>
- [18] G. Schwarz, “Estimating the dimension of a model,” *The Annals of Statistics*, vol. 6, no. 2, pp. 461–464, 1978. Disponível em: <http://www.jstor.org/stable/2958889>
- [19] C. M. Jarque e A. K. Bera, “Efficient tests for normality, homoscedasticity and serial independence of regression residuals,” *Economics Letters*, vol. 6, no. 3, pp. 255–259, 1980. Disponível em: [https://doi.org/10.1016/0165-1765\(80\)90024-5](https://doi.org/10.1016/0165-1765(80)90024-5)
- [20] R. F. Engle, “Autoregressive conditional heteroscedasticity with estimates of the variance of United Kingdom inflation,” *Econometrica*, vol. 50, no. 4, pp. 987–1007, 1982. Disponível em: <https://doi.org/10.2307/1912773>
- [21] R Core Team. (2023) R: a language and environment for statistical computing. viena, austria: R core team. Disponível em: <https://www.r-project.org/>
- [22] R. Hyndman, G. Athanasopoulos, C. Bergmeir, G. Caceres, L. Chhay, K. Kuroptev, M. O’Hara-Wild, F. Petropoulos, S. Razbash, E. Wang, F. Yasmeen, F. Garza, D. Girolimetto, R. Ihaka, D. Reid, D. Shaub, Y. Tang, X. Wang, e Z. Zhou. (2023) forecast: Forecasting functions for time series and linear models. Disponível em: <https://pkg.robjhyndman.com/forecast/>, <https://github.com/robjhyndman/forecast>

- [23] A. Trapletti, K. Hornik, e B. LeBaron. (2023) tseries: Time series analysis and computational finance. Disponível em: <https://CRAN.R-project.org/package=tseries>
- [24] D. Meyer, E. Dimitriadou, K. Hornik, A. Weingessel, F. Leisch, C.-C. Chang, e C.-C. Lin. (2023) e1071: Misc functions of the department of statistics, probability theory group. Disponível em: <https://CRAN.R-project.org/package=e1071>
- [25] G. N. Boshnakov. (2018) Fints: Companion to Tsay analysis of financial time séries. Disponível em: <https://r-forge.r-project.org/projects/fints/>
- [26] H. Wickham, W. Chang, T. L. Pedersen, K. Takahashi, C. Wilke, K. Woo, H. Yutani, e D. Dunnington. (2023) ggplot2: Create elegant data visualisations using the grammar of graphics. Disponível em: <https://ggplot2.tidyverse.org>, <https://github.com/tidyverse/ggplot2>
- [27] The Gretl Team. (2018) Gretl: GNU regression, econometrics and time-series library. Disponível em: <https://gretl.sourceforge.net/pt.html>