

CADERNOS DO IME – Série Estatística

Universidade do Estado do Rio de Janeiro - UERJ
ISSN on-line 2317-4536 / ISSN impresso 1413-9022 - v.58, p.47-68, 2025
DOI: 10.12957/cadest.2025.95070

APLICAÇÃO DE MODELOS DE SÉRIES TEMPORAIS E MACHINE LEARNING PARA A PREVISÃO DO VALOR DE FECHAMENTO DO BITCOIN

Igor Brito dos Santos

Universidade do Estado do Rio de Janeiro -UERJ

igorbrito2708@gmail.com

Igor Mello Vieites

Universidade do Estado do Rio de Janeiro -UERJ

igorvieites@gmail.com

Marcello Montillo Provenza

Universidade do Estado do Rio de Janeiro -UERJ

mprovenza@gmail.com

Jorge Luiz de Jesus Goulart

Universidade do Estado do Rio de Janeiro -UERJ

jorge.goulart@uerj.br

Resumo

Este estudo tem como objetivo avaliar diferentes métodos estatísticos para estimar a previsão do preço de fechamento do Bitcoin um mês à frente. Para evitar quaisquer efeitos que a pandemia de COVID-19 possa ter gerado na série temporal, o período analisado foi entre setembro de 2022 e setembro de 2025, sendo o conjunto de teste o mês de setembro de 2025. O estudo foi realizado usando a linguagem de programação Python em um notebook do Google Colaboratory, e a base de dados foi obtida a partir do uso da biblioteca “yfinance”. Três modelos foram aplicados e, com base nas métricas de previsão, constatou-se que o modelo LSTM apresentou a melhor performance.

Palavras-chave: Bitcoin, Previsão, LSTM.

1. Introdução

Embora seja um fenômeno recente, o conceito de moeda digital surgiu na década de 80, com o objetivo de se desvencilhar das moedas fiduciárias. As criptomoedas são um tipo de moeda digital/virtual descentralizada, ou seja, não existem de forma física e não são controladas por um governo ou bancos centrais. A independência em relação às instituições financeiras permite que as transações sejam realizadas diretamente, eliminando taxas, reduzindo o tempo entre operações e ampliando a acessibilidade, já que qualquer pessoa com conexão à internet pode participar (CRYPTO.COM, 2022).

Apesar de seu conceito ter sido planejado em torno dos anos 80, o surgimento de criptomoedas como conhecidas hoje em dia veio apenas em 2008, impulsionado pela crise financeira nos Estados Unidos. A instabilidade econômica no período trouxe uma grande desconfiança no sistema financeiro tradicional, expondo algumas fragilidades como má gestão de risco, falta de transparência e excesso de especulação (INFOMONEY, 2022).

Nos primeiros anos, a popularização das criptomoedas ocorreu por uma combinação de fatores. Em um primeiro momento, a curiosidade tecnológica atraiu desenvolvedores, entusiastas de segurança digital e pessoas interessadas em sistemas financeiros alternativos. O caráter descentralizado e a promessa de independência frente a bancos e governos despertaram interesse em comunidades online que buscavam maior liberdade econômica. Esse modelo só foi viável graças à tecnologia blockchain, um registro público e imutável que armazena todas as transações de forma criptografada e distribuída entre milhares de computadores. Essa inovação trouxe segurança e transparência, eliminando a necessidade de intermediários e aumentando a confiança de novos usuários (INFOMONEY, 2022).

Entretanto, uma característica se tornou a maior barreira para a entrada de possíveis compradores menos sujeitos ao risco, a volatilidade. Criptomoedas são amplamente conhecidas por mudanças abruptas em seu preço, tanto para as altas quanto para as quedas. Diversos fatores podem afetar os preços dos ativos, como a baixa regulação do mercado; a menor liquidez em comparação a mercados tradicionais; e a forte presença de investidores especulativos. Além disso, acontecimentos externos, como ataques cibernéticos e mudanças na aceitação institucional das criptomoedas, também influenciam diretamente a confiança. Essa combinação de fatores faz com que o mercado

cripto seja extremamente dinâmico e arriscado, atraindo perfis mais arrojados de investidores (VASCONCELLOS, 2019).

Dentre as criptomoedas, destaca-se o Bitcoin. Criado em 2008 por Satoshi Nakamoto, é considerado o primeiro e mais importante ativo do mercado cripto (INFOMONEY, 2022). O Bitcoin consolidou-se como o principal representante desse ecossistema, tanto pelo pioneirismo quanto pelo valor de mercado que concentra. Seu caráter descentralizado, oferta limitada a 21 milhões de unidades e ampla aceitação o tornaram conhecido como o “ouro digital” (MOONPAY, 2025). A combinação de adoção crescente, especulação intensa e escassez programada impulsionou fortes variações em seu preço, atraindo investidores e instituições, mas também evidenciando sua alta volatilidade, um dos principais desafios para quem busca entender ou prever seu comportamento (INFOMONEY, 2022).

Diante desse cenário, a previsão do preço do Bitcoin (USD) torna-se um tema de grande relevância econômica e tecnológica, pois auxilia na tomada de decisões de investimento e no entendimento das dinâmicas de um mercado emergente e altamente sensível a fatores externos. Assim, este artigo tem como objetivo analisar a série temporal dos preços do Bitcoin e comparar diferentes modelos preditivos, desde métodos estatísticos tradicionais até abordagens modernas de machine learning, visando identificar aquele que melhor se ajusta às variações da moeda e oferece previsões mais precisas sobre sua tendência.

2. Revisão de literatura

A volatilidade extrema do Bitcoin é um tema recorrente, sendo descrita como um desafio para modelos econométricos tradicionais (CORDEIRO, ARAÚJO, AVELINO, 2025). Essa característica exige abordagens que consigam capturar comportamentos não lineares e não estacionários, levando pesquisadores a explorar desde modelos clássicos até mais técnicas avançadas (PEREIRA, 2022). Além disso, a literatura destaca a importância da sazonalidade e de fatores exógenos, como o volume de buscas no Google, na compreensão da dinâmica de preços dessa moeda digital (BRAGA, 2023; TORMIN, 2024).

No âmbito dos modelos estatísticos e econométricos, a modelagem da volatilidade e do risco é frequentemente abordada através da família GARCH e do cálculo do Value at Risk (VaR). Estudos indicam que modelos de heterocedasticidade condicional, como

o AR-GARCH, apresentam melhor desempenho quando utilizam distribuições t de Student ou t assimétrica para prever o risco em mercados dinâmicos (CORDEIRO & MÜLLER, 2024). Outras pesquisas reforçam que, embora modelos como o EWMA e o GARCH(1,1) sejam amplamente utilizados, a precisão do VaR pode variar conforme a janela de estimação e as estatísticas descritivas da série de retornos (ALVES, 2023). Esses métodos tradicionais servem como base comparativa para a introdução de técnicas de aprendizado de máquina, que buscam superar limitações na identificação de padrões complexos.

As Redes Neurais Artificiais, especificamente a arquitetura Long Short-Term Memory (LSTM), ganharam destaque pela sua capacidade de lidar com dependências temporais de longo prazo. Trabalhos indicam que a LSTM frequentemente supera modelos tradicionais como o ARIMA e redes neurais convencionais em tarefas de regressão para o preço do Bitcoin (LEITE, 2023). A eficácia dessas redes é atribuída à sua estrutura de células de memória, que filtram informações relevantes através de portões de entrada, saída e esquecimento (BRAGA, 2023; PEREIRA, 2022). Experimentos demonstram que modelos baseados em LSTM podem atingir níveis elevados de acurácia, especialmente quando integrados a bases de dados que refletem o sentimento do mercado ou tendências de busca (SANTOS, 2021).

Além das redes neurais, modelos baseados em árvores de decisão, como o Random Forest (RF), são explorados para prever a direção do movimento dos preços em frequências intradiárias. A literatura aponta que o RF pode oferecer um poder preditivo superior à regressão logística e ao ARIMA em horizontes de tempo curtos, variando de 1 a 60 minutos (POLI, 2023). O uso de dados de alta frequência e a análise da importância de diferentes atributos técnicos permitem que esses modelos de classificação identifiquem momentos de compra e venda com maior precisão (POLI, 2023). Contudo, a eficiência de mercado, mesmo em sua forma fraca, continua sendo um ponto de debate acadêmico, com resultados sugerindo que a previsibilidade pode ser explorada de forma lucrativa sob certas condições (AKYILDIRIM *et al.*, 2022 apud POLI, 2023).

Por fim, a construção de conjuntos de dados enriquecidos surge como uma tendência para fortalecer as estratégias quantitativas. A integração de variáveis sazonais e indicadores macroeconômicos em bases de dados específicas para Bitcoin visa fornecer subsídios para modelos preditivos mais robustos (CORDEIRO, ARAÚJO, AVELINO,

2025). A literatura converge para a ideia de que o sucesso na predição do Bitcoin não depende apenas da escolha do algoritmo, mas também do pré-processamento adequado dos dados e da combinação de métodos que considerem tanto a análise técnica quanto o comportamento do investidor (TORMIN, 2024; BRAGA, 2023).

3. Metodologia

3.1. Coleta e Tratamento dos Dados

A base de dados utilizada neste estudo foi obtida por meio da biblioteca “yfinance” (RANAROUSSI, 2019), uma ferramenta open source que disponibiliza para propósitos educacionais e de pesquisa a série via uma API (Interface de Programação de Aplicações) pública do Yahoo. O conjunto de dados abrange toda série histórica do Bitcoin, mas, visando evitar que os modelos pudessem sofrer influência das flutuações geradas pela pandemia de COVID-19, foi considerado um conjunto de dados entre 1 de setembro de 2022 e 30 de setembro de 2025.

A definição desse recorte temporal justifica-se pela necessidade de isolar efeitos atípicos de volatilidade extrema do período pandêmico, garantindo que os modelos capturem a dinâmica estrutural mais recente do mercado de criptoativos, conforme discutido por Vasconcellos (2019) sobre a sensibilidade desses ativos a fatores externos. Além disso, este estudo preenche uma lacuna na literatura ao comparar o desempenho de métodos estatísticos clássicos (ARIMA) e modelos aditivos (Prophet) frente a arquiteturas de aprendizado profundo (LSTM) no cenário econômico pós-pandemia, caracterizado por uma nova fase de maturação e aceitação do Bitcoin.

Todo processamento dos dados, desde a Análise Exploratória até os processos de modelagem utilizaram a linguagem de programação Python, na IDE (Ambiente de Desenvolvimento Integrado) do Google Colaboratory. A IDE foi escolhida para possibilitar a implementação de algoritmos computacionais avançados para a modelagem, além da maior organização entre cada etapa da análise proposta. Para garantir a robustez da análise, o conjunto de dados foi dividido em treino (compreendendo o período de 1 de setembro de 2022 ao dia 31 de agosto de 2025) e teste (compreendendo o período de 01 de setembro de 2025 ao dia 30 de setembro de 2025).

A divisão dos dados em um único conjunto de treinamento e teste foi adotada seguindo a lógica de *holdout* temporal. Esta escolha justifica-se pela natureza da aplicação prática visada: simular a performance do modelo em um cenário real de previsão de curto

prazo (um mês à frente), onde o modelo é treinado com todo o histórico disponível até o momento da operação. Embora técnicas como a validação cruzada para séries temporais (*time series split*) sejam úteis para avaliar a estabilidade dos modelos em diferentes janelas, optou-se pelo conjunto único de teste para preservar a continuidade da tendência mais recente do mercado de criptoativos, que é altamente dinâmico e sujeito a mudanças de regime. Assim, o mês de setembro de 2025 funciona como um *out-of-sample* rigoroso, garantindo que não houve vazamento de dados (*data leakage*) do futuro para o passado.

3.2. Análise Exploratória

Para iniciar a análise da série temporal foi investigado a presença de normalidade da série temporal, apesar do histograma da série não indicar esta distribuição no dado conjunto, é preciso confirmar essa ideia com dois testes estatísticos não paramétricos, Anderson-Darling e Shapiro-Wilk, onde suas hipóteses nulas são, essencialmente, a aderência dos dados a uma distribuição conhecida (LEOTTI, COSTER, RIBOLDI, 2012). Para isso, utilizou-se da biblioteca “scipy.stats” a função “shapiro” e da biblioteca “statsmodels.stats.diagnostic” a função “normal_ad” (SCIPY, 2025).

A estacionariedade em um processo estocástico pode ser definida em dois princípios, caso a média dos processos seja igual para todos os períodos observados e se a autocovariância é igual entre a mesma diferença temporal. Então, a estacionariedade forte de uma série temporal é quando todas as propriedades estatísticas, incluindo a média, a variância e a autocovariância, são constantes ao longo do tempo (MARQUES, 2022). Para buscar pela presença de tendência na série, foi utilizado o teste estatístico não paramétrico de Mann-Kendall, onde sua hipótese nula consiste na não existência de tendência monotônica (DUARTE, 2021). Foi utilizada a função “mk” da biblioteca “pymannkendall” (TAYLOR & LETHAM, 2018).

Para identificar sazonalidade na série do Bitcoin, utilizou-se o teste estatístico não paramétrico de Kruskal-Wallis, onde sua hipótese nula indica a ausência de sazonalidade (BHATTACHARJEE, 2022; MCCLENAGHAN, 2024). A investigação de sazonalidade foi realizada utilizando a função “kruskal” da biblioteca “scipy.stats” (SCIPY, 2025).

Por fim, realizou-se uma análise das Funções de Autocorrelação (FAC) e Autocorrelação Parcial (FACP), provindas da biblioteca “statsmodels” as funções, respectivas, “plot_acf” e “plot_pacf” (SEABOLD & PERKTOLD, 2010), já que são as principais ferramentas para identificar a estrutura de dependência temporal de uma série

e, conseqüentemente, ajudar a escolher os parâmetros corretos para modelos como o ARIMA.

3.3. Modelos de Previsão

Neste estudo, como o objetivo é investigar o melhor modelo para a previsão do preço do Bitcoin, buscou-se utilizar os seguintes modelos estatísticos e computacionais para apoiar nessa análise:

3.3.1 Autorregressivo Integrado de Médias Móveis (ARIMA)

Estes modelos se baseiam na premissa de que os valores observados anteriormente estão relacionados com o valor atual ou com o valor que se deseja prever. Os modelos ARIMA são capazes de capturar tanto a tendência quanto a sazonalidade dos dados, sem sacrificar a sem sacrificar a capacidade de compreensão do processo (BOX et al., 2015). O modelo ARIMA(p,d,q) é dado por (1):

$$\phi(B)(1 - B)^d y_t = \theta(B)\varepsilon_t \quad (1)$$

onde:

- B é o operador defasagem;
- $\phi(B)$ representa a parte autoregressiva (AR);
- $(1 - B)^d$ representa a parte integrada (I);
- $\theta(B)$ representa a parte de médias móveis (MA);
- ε_t é o termo de erro aleatório (ruído branco).

Para a definição da ordem do modelo ARIMA, utilizou-se o algoritmo *auto-arima*, que realizou buscas iterativas visando a minimização do Critério de Informação de Akaike (AIC). O modelo selecionado foi o ARIMA(1,1,0), que apresentou um AIC de 14.457,75, sendo este o menor valor entre as combinações testadas, o que justifica a escolha por um modelo parcimonioso e evita a sobreajustação (*overfitting*). Embora a Função de Autocorrelação (FAC) apresentasse um decaimento lento, este foi tratado com uma diferenciação simples ($d = 1$), tornando a série estacionária. A ausência de uma diferenciação sazonal ($D = 1$) justifica-se pelo fato de o algoritmo não ter identificado componentes sazonais estocásticos que reduzissem o AIC.

3.3.2 PROPHET

Desenvolvido pelo Facebook, o Prophet é um modelo de previsão de séries temporais que se baseia em um modelo aditivo. Ele é particularmente eficaz em séries temporais que apresentam efeitos sazonais fortes e têm múltiplas temporadas de dados históricos (META PLATFORMS, 2024). O Prophet modela a série temporal como uma soma de componentes (2):

$$y(t) = g(t) + s(t) + h(t) + \varepsilon_t \quad (2)$$

onde:

- $g(t)$ representa a tendência (linear ou logística);
- $s(t)$ representa a sazonalidade (anual, semanal, etc.);
- $h(t)$ representa o efeito de feriados e eventos especiais;
- ε_t é o termo de erro aleatório.

3.3.3 LSTM (*Long Short Term Memory*)

As LSTM são um tipo de Rede Neural Recorrente (RNN) que resolve um problema existente nelas, a necessidade de acessar conteúdos e dados anteriores para prever a um próximo passo, por serem capazes de aprender dependências de longo prazo (JUNIOR, 2019).

As Redes Neurais de Memória de Curto e Longo Prazo (LSTM) oferecem uma abordagem computacional oriunda do campo do deep learning. Como uma arquitetura de rede neural recorrente, a LSTM foi projetada especificamente para aprender e memorizar padrões de longa dependência em dados sequenciais, superando limitações de modelos mais simples. Sua força reside na capacidade de capturar relações não-lineares e complexas através de um mecanismo de “portões” (gates) que controlam o fluxo de informação (JUNIOR, 2019). Essa flexibilidade torna a LSTM uma ferramenta poderosa para séries temporais voláteis e não estacionárias, como as de criptoativos, embora ao custo de uma menor interpretabilidade em comparação com os modelos estatísticos clássicos. A arquitetura LSTM envolve várias fórmulas para seus diferentes “portões” e estados de memória, que regulam o fluxo de informação.

A arquitetura LSTM diferencia-se por sua capacidade de reter informações relevantes por longos períodos, mitigando o problema do gradiente dissipante. Esse processo é gerido por unidades de memória denominadas “gates” (portões), que regulam o fluxo de dados. A Figura 1 apresenta o fluxograma da rede implementada, ilustrando o

processamento desde a entrada dos dados — estruturados em janelas temporais de 60 dias — até a passagem pelas duas camadas LSTM de 50 neurônios cada. Entre essas camadas, destaca-se o uso de Dropout (20%) como técnica de regularização para prevenir o overfitting. Internamente, cada célula utiliza a função de ativação tangente hiperbólica (tanh) para normalizar os valores do estado da célula e da saída, enquanto os portões de esquecimento, entrada e saída determinam a persistência das informações, fator crucial para a modelagem da alta volatilidade do Bitcoin.

A definição dos hiperparâmetros, como o número de neurônios (50) e a taxa de Dropout (20%), foi estabelecida de forma empírica através de testes preliminares de sensibilidade. Observou-se que arquiteturas mais complexas (com mais neurônios) apresentavam sinais de sobreajuste no conjunto de treino, enquanto janelas temporais menores que 60 dias não eram capazes de capturar os padrões de suporte e resistência relevantes para a série do Bitcoin no período analisado. O treinamento foi executado por 25 épocas com um tamanho de lote (*batch size*) de 32, parâmetros que garantiram a estabilidade da função de perda e a convergência do erro quadrático médio antes da aplicação no conjunto de teste.

Figura 1 – Fluxograma da arquitetura da rede neural LSTM implementada.



Fonte: Os autores, 2025

3.4. Métricas de Avaliação

Com o objetivo de entender qual é o melhor modelo dentre os 3 observados, foram escolhidas quatro métricas de acurácia para a validação dos resultados obtidos (MARIO FILHO, 2018), observadas:

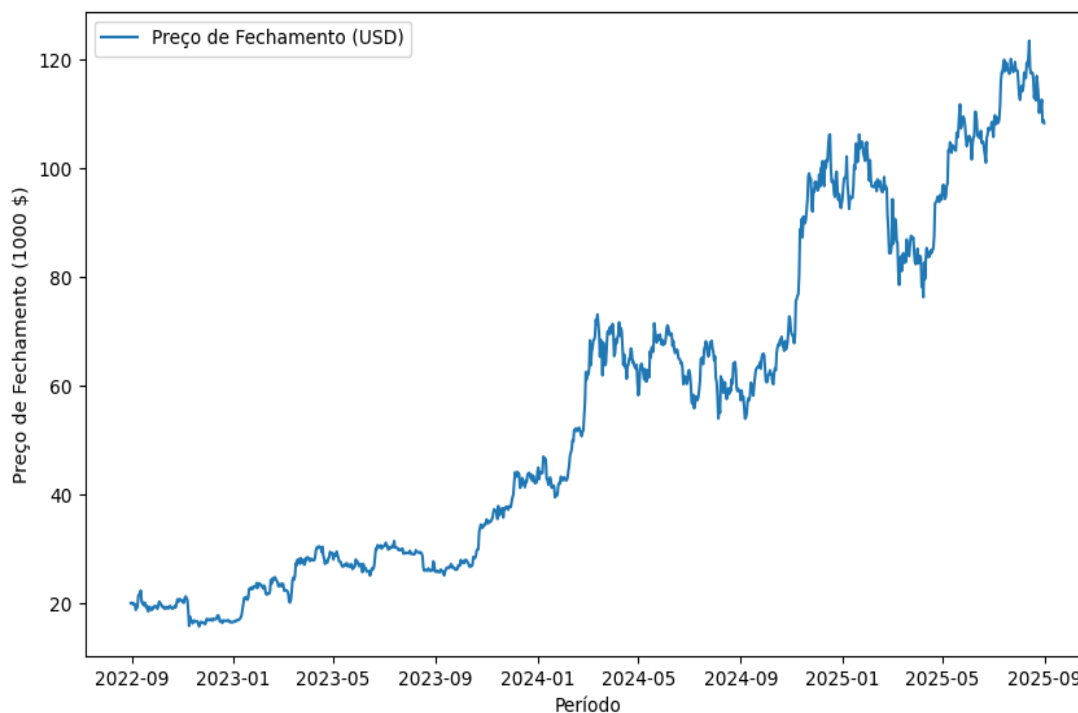
- Raiz do Erro Quadrático Médio (RMSE): Ele mede o desvio padrão dos resíduos (erros de previsão), que são as distâncias entre os pontos de dados e a linha da série temporal.
- Erro Absoluto Médio (MAE): Essa métrica calcula a média dos valores absolutos das diferenças entre as previsões e os valores reais.
- Erro Percentual Absoluto Médio (MAPE): A métrica calcula o erro médio em termos percentuais, permitindo que previsões de diferentes escalas sejam comparadas facilmente.
- Erro Percentual Absoluto Médio Simétrico (SMAPE): Ao dividir o erro pela média dos valores real e previsto, o SMAPE é mais simétrico e lida melhor com erros de superestimação e subestimação, ao contrário do MAPE.

Essas métricas analisadas em conjunto permitem traçar comparações entre os diferentes modelos para decidir qual o mais adequado e que pode fornecer a melhor previsão. A eficácia será validada através da técnica de *hold-out*, comparando as previsões com dados reais não utilizados no treino, sob a ótica das métricas MAE, MSE e RMSE.

4. Resultados e discussão

Na Figura 2, é apresentada uma visualização da distribuição dos dados da série histórica do Bitcoin, compreendida no período de setembro de 2022 até setembro de 2025. É possível observar uma tendência de crescimento do valor ao longo dos anos. O comportamento aparenta repetir um padrão de “lateralização” da série (quando os valores da criptomoeda não têm alterações significativas no preço, com quedas e subidas, com o preço se mantendo, na média, estável), seguido de um crescimento no seu valor. No período mais recente, a criptomoeda não está em seu ápice, atingido ao final do mês de agosto.

Figura 2 – Série temporal do valor de fechamento do preço do Bitcoin de set/2022 até set/2025




Fonte: Os autores, 2025

Nas estatísticas do Quadro 1 e no histograma dos dados (Figura 3), é possível observar que o valor médio é 2 mil dólares maior que o mediano, indicando que os dados possuem uma cauda à direita, o que é corroborado pelo valor de assimetria. Esse alongamento pode ser explicado por um rápido aumento no valor do Bitcoin ao longo do ano de 2024, 113% neste ano.

É possível observar, também, no quadro de estatísticas, um dos motivos do porquê a previsão do valor da criptomoeda é tão cobiçada por especuladores e acionistas, sua volatilidade. Com um desvio padrão de 30 mil dólares, aproximadamente, quase 56% da média da série, juntamente com a amplitude observada no conjunto de dados, de mais de 100 mil dólares em apenas três anos, são a prova mais forte da volatilidade da moeda, juntamente com seu alto risco atribuído.

Figura 3 – Histograma da distribuição dos valores de fechamento do Bitcoin, no período compreendido



Fonte: Os autores, 2025

Quadro 1 – Estatísticas de descrição da série temporal do Bitcoin

Estatística	Valor
Nº de observações	1.097
Média	56.040,08
Desvio Padrão	31.571,24
Valor Mínimo	15.787,28
25º Percentil	27.129,59
50º Percentil	54.841,57
75º Percentil	83.684,98
Valor Máximo	123.344,06
Assimetria	0,44

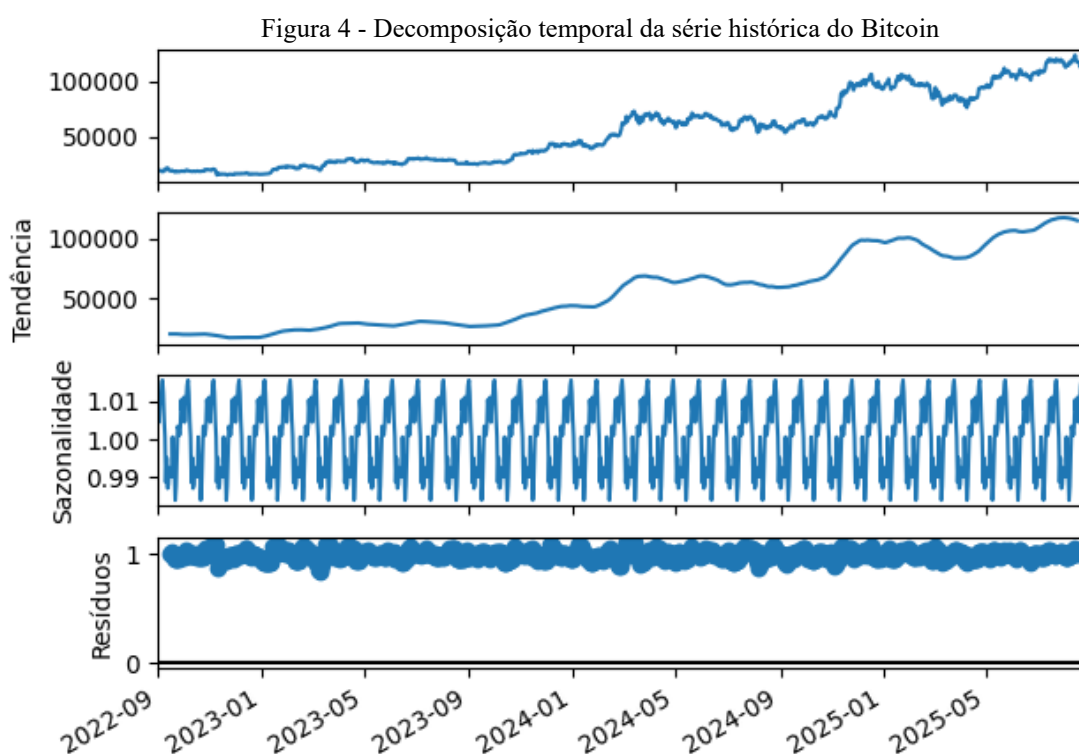
Fonte: Os autores, 2025

Para a avaliação da aderência dos dados à distribuição Normal, usou-se os testes estatísticos Shapiro-Wilk e Anderson-Darling. Ambos p-valores retornaram $p < 0,001$. Com este resultado, ao nível de significância de 5%, existem evidências estatísticas suficientes para rejeitar a hipótese nula. Pode-se dizer que os resíduos não seguem uma distribuição Normal.

A verificação da estacionariedade da série temporal foi conduzida por meio de dois testes não paramétricos. Utilizou-se o teste de Mann-Kendall para avaliar a existência de tendência e o teste de Kruskal-Wallis para investigar a presença de sazonalidade. O teste de Mann-Kendall resultou em um p-valor significativamente baixo ($p < 0,001$), o que levou à rejeição da hipótese nula (ausência de tendência) a um nível de significância de 5%.

Em contrapartida, a análise de sazonalidade pelo teste de Kruskal-Wallis não apresentou significância estatística. Os p-valores obtidos, tanto para a sazonalidade semanal ($p = 0,67$) quanto para a mensal ($p = 0,75$), foram superiores ao nível de 5%. Desta forma, falha-se em rejeitar a hipótese nula (medianas iguais entre os períodos), indicando a ausência de efeitos sazonais relevantes.

Estas conclusões são corroboradas pela decomposição temporal da série (Figura 4). A análise gráfica demonstra que o componente de tendência é a principal força de variação nos dados, enquanto o componente sazonal apresenta uma variação insignificante (índice multiplicativo variante próximo de 1,0, no intervalo $[0,99; 1,01]$). A presença de uma tendência clara, aliada à ausência de sazonalidade, permite classificar a série histórica como não estacionária.




Fonte: Os autores, 2025

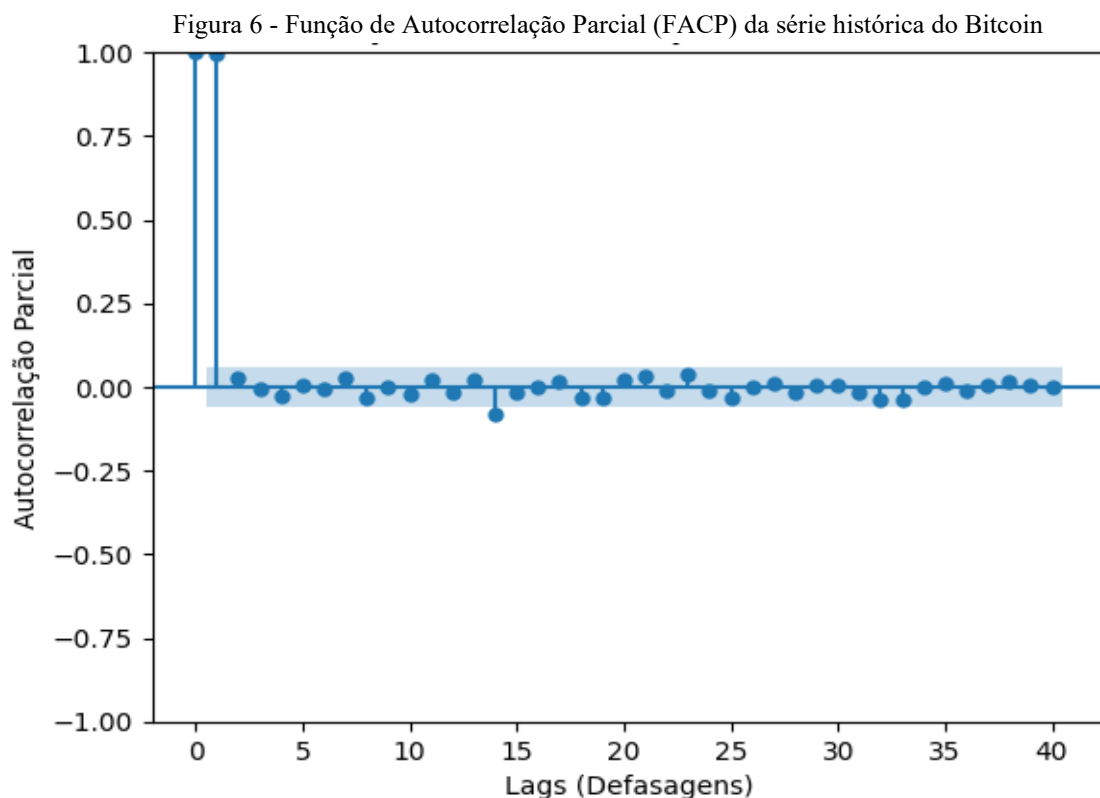
A análise dos correlogramas da FAC e da FACP é fundamental. O gráfico da FAC (Figura 5) demonstra um comportamento clássico de não estacionariedade: um decaimento lento e gradual dos coeficientes ao longo das defasagens (lags). Esta estrutura persistente indica que a série não é estacionária na média, o que pode ser reflexo de uma forte tendência ou de um processo do tipo Passeio Aleatório (Random Walk). Em contrapartida, o gráfico da FACP (Figura 6) exhibe um truncamento no primeiro lag (lag = 1), com os valores subsequentes cortando abruptamente para dentro dos limites de confiança. Este padrão é a assinatura de um processo Autoregressivo de ordem 1, AR(1).

A interpretação conjunta desses padrões é a principal ferramenta para a identificação do modelo: a FAC de decaimento lento sugere a necessidade de uma diferenciação ($d = 1$) para tornar a série estacionária, enquanto a FACP que corta após o primeiro lag sugere um componente autoregressivo de ordem 1 ($p = 1$). Essas observações, portanto, fornecem forte evidência inicial para a adequação de um modelo ARIMA(1,1,0).

Figura 5 - Função de Autocorrelação (FAC) da série histórica do Bitcoin



Fonte: Os autores, 2025



Fonte: Os autores, 2025

Para fins comparativos, foram implementados dois modelos de prognóstico de maior complexidade: Prophet (Facebook) e Long Short-Term Memory (LSTM). O Prophet foi escolhido por sua arquitetura aditiva, projetada para decompor tendências e sazonalidades de forma robusta sem exigir a prévia estacionarização manual dos dados. O LSTM, uma arquitetura de Rede Neural Recorrente (RNN), foi selecionado por sua capacidade de aprender e modelar dependências temporais não lineares de curto e longo prazo. A definição da arquitetura de rede e o ajuste dos hiperparâmetros de ambos os modelos foram essenciais para otimizar o desempenho preditivo, estando suas configurações detalhadas nos Quadros 2 (LSTM) e 3 (Prophet).

Quadro 2 – Estrutura e hiperparâmetros do modelo LSTM

Camada	Tipo de Camada	Neurônios / Parâmetros	Função de Ativação	Saída (<i>Output Shape</i>)	Observações
1	LSTM	50 neurônios (10.400 parâmetros)	<i>tanh</i>	(None, 60, 50)	Retorna sequência para próxima camada
2	LSTM	50 neurônios (20.200 parâmetros)	<i>tanh</i>	(None, 50)	—

3	Dense	1 neurônio (51 parâmetros)	Linear	(None, 1)	Saída final do modelo
---	-------	----------------------------	--------	-----------	-----------------------

Fonte: Os autores, 2025

O processo de treinamento do modelo LSTM foi configurado para um máximo de 50 épocas, utilizando um tamanho de lote (batch size) de 16 e o otimizador Adam para minimizar a função de perda do Erro Quadrático Médio (MSE). Para monitorar a convergência e evitar o sobreajuste, utilizou-se uma divisão de validação de 10% dos dados de treino, combinada com um critério de Parada Antecipada (Early Stopping) com tolerância de 10 épocas. Adicionalmente, foram aplicadas camadas dropout com taxa de 0,2 entre as camadas LSTM como técnica de regularização. A arquitetura de rede resultante deste processo totalizou 30.651 parâmetros treináveis.

Quadro 3 – Estrutura e hiperparâmetros do modelo Prophet

Parâmetro	Valor Utilizado	Descrição
Growth	Linear	Tipo de crescimento da tendência
Changepoint Prior Scale	0,5	Controla a flexibilidade das mudanças de tendência
Seasonality Prior Scale	0,01	Controla a amplitude da sazonalidade
Seasonality Mode	Aditivo	Combina tendência e sazonalidade de forma linear

Fonte: Os autores, 2025

O modelo Prophet foi implementado utilizando uma configuração de crescimento linear e modo de sazonalidade aditivo, abordagem selecionada para capturar as variações estruturais observadas na tendência da série temporal.

A aplicação do ARIMA, juntamente com os modelos Prophet e LSTM, possibilita a comparação de diferentes abordagens de previsão, incluindo métodos estatísticos clássicos, modelos aditivos de tendência e sazonalidade, e redes neurais recorrentes. Essa análise permite avaliar o desempenho de cada modelo na captura da dinâmica temporal da série. As métricas resultantes estão apresentadas no Quadro 4 abaixo, oferecendo uma base quantitativa para a comparação entre os modelos.

Quadro 4 – Métricas de acurácia dos modelos no conjunto de teste

MODELOS	MAPE (%)	SMAPE(%)	MAE (USD)	RMSE (USD)
ARIMA	4,28	4,40	4.895,95	5.494,02
LSTM	1,63	1,64	1.841,10	2.256,03
PROPHET	2,04	2,04	2.308,20	2.651,26

Fonte: Os autores, 2025


Os resultados apresentados no Quadro 4 evidenciam diferenças significativas no desempenho dos três modelos de previsão analisados. O modelo LSTM apresentou os menores valores em todas as métricas de erro: MAPE (1,63%), SMAPE (1,64%), MAE (1.841,10) e RMSE (2.256,03). O LSTM demonstrou alta capacidade de generalização e precisão na captura da dinâmica não linear da série temporal. Essa performance reforça o potencial das redes neurais recorrentes para modelar padrões complexos e relações de dependência de longo prazo, especialmente em séries financeiras como a do preço do Bitcoin.

O modelo Prophet obteve desempenho intermediário: MAPE e SMAPE (2,04%), MAE (2.308,20) e RMSE (2.651,26). O modelo indica boa capacidade de ajuste e previsão, sobretudo para capturar tendências e sazonalidades de curto prazo. Sua estrutura aditiva e a flexibilidade no tratamento de mudanças de tendência explicam a consistência dos resultados, embora o modelo não alcance a precisão observada na LSTM.

O modelo ARIMA apresentou os maiores valores de erro: MAPE (4,28%), SMAPE (4,40%), MAE (4.895,95) e RMSE (5.494,02), refletindo limitações na modelagem de padrões não lineares e na adaptação a variações mais abruptas presentes na série temporal. Apesar disso, o ARIMA ainda se mostrou eficiente em capturar a tendência principal do período, servindo como uma base comparativa sólida frente aos demais métodos mais complexos.

A Figura 6 apresenta uma análise comparativa detalhada, focando no horizonte de previsão de setembro de 2025. O gráfico justapõe os valores reais observados do preço de fechamento do Bitcoin (USD) com as previsões geradas por cada modelo. Este recorte temporal específico permite uma avaliação visual precisa da aderência e da acurácia de cada prognóstico frente à dinâmica real do mercado no período analisado.

Figura 6: Comparação dos modelos preditivos para o Bitcoin (USD)



Fonte: Os autores, 2025

Por fim, os resultados apontam para a superioridade da abordagem baseada em aprendizado profundo (LSTM) em relação às metodologias tradicionais e semi-paramétricas, especialmente em contextos onde a série temporal apresenta comportamento não estacionário e alta volatilidade.

5. Considerações finais

O presente trabalho teve como objetivo analisar e comparar o desempenho preditivo dos modelos ARIMA, Prophet e LSTM aplicados ao preço de fechamento do Bitcoin (USD). A análise exploratória da série temporal revelou um comportamento não estacionário, volátil e com forte tendência (confirmada pelo teste de Mann-Kendall), embora sem sazonalidade significativa (Kruskal-Wallis). Estes achados justificam a seleção de metodologias capazes de lidar tanto com estruturas lineares quanto com dinâmicas não lineares complexas.

A comparação quantitativa demonstrou a superioridade da rede neural LSTM em todas as métricas de erro, refletindo sua capacidade de capturar dependências complexas de longo prazo. O Prophet obteve um desempenho intermediário, modelando a tendência com eficácia, enquanto o ARIMA, embora menos preciso, funcionou como uma base de comparação robusta para os componentes lineares. Estes achados reforçam o potencial

das redes neurais recorrentes para prognósticos em ativos voláteis, mas também validam a relevância de modelos como ARIMA e Prophet por sua maior interpretabilidade e menor custo computacional. Assim, este estudo contribui com subsídios empíricos para a seleção de modelos de previsão em contextos financeiros dinâmicos.

A eficácia do trabalho é validada através de uma abordagem comparativa multi-métrica, utilizando indicadores de erro absoluto e quadrático (MAE, MSE e RMSE) para mensurar a precisão das previsões em um conjunto de teste totalmente inédito para os modelos (setembro de 2025). Além disso, a robustez é garantida pelo contraste entre modelos de naturezas distintas — um estatístico clássico (ARIMA), um aditivo estrutural (Prophet) e uma rede neural de aprendizado profundo (LSTM) — permitindo verificar se o desempenho superior da LSTM é consistente ou se há viés de sobreajuste (*overfitting*).

Como trabalhos futuros, recomenda-se ampliar o escopo da análise com a inclusão de variáveis exógenas (volume de negociação, indicadores macroeconômicos, etc.) e de sentimento (como o índice de medo e ganância). Sugere-se também a exploração de outras arquiteturas, como redes GRU, modelos econométricos focados na volatilidade (GARCH) e outras técnicas de aprendizado de máquina, como a Máquina de Vetores de Suporte (SVM).

Referências

ALVES, M. S.. Aplicação e comparação de modelos de heterocedasticidade condicional: um estudo utilizando o Bitcoin. 2023. 64 f. **Monografia** (Bacharelado em Ciências Econômicas) – Centro Sócio Econômico, Universidade Federal de Santa Catarina, Florianópolis, 2023.

BHATTACHARJEE, A. Kruskal-Wallis Test: a powerful tool for detecting seasonality in time series data using Python. **Medium**, [S. l.], 2022. Disponível em: <https://medium.com/@avijit.bhattacharjee1996/kruskal-wallis-test-a-powerful-tool-for-detecting-seasonality-in-time-series-data-using-python-d827ef23d29e>. Acesso em: 6 out. 2025.

BOX, G. E.; JENKINS, G. M.; REINSEL, G. C.; LJUNG, G. M. **Time series analysis: forecasting and control**. 5. ed. Hoboken: John Wiley & Sons, 2015.

BRAGA, R. V. Redes Neurais LSTM e Google Trends aplicados para previsão de Séries Temporais do Mercado Financeiro no contexto de Criptomoedas. 2023. 64 f. **Monografia** (Bacharelado em Sistemas de Informação) – Instituto de Ciências Exatas e Aplicadas, Universidade Federal de Ouro Preto, João Monlevade, 2023.

CORDEIRO, D. F. S.; MÜLLER, F. M. **Previsão de Risco para Bitcoin e Ethereum: Uma Comparação Usando Função Score**. [S. l.], fev. 2024.

CORDEIRO, J. J. R.; ARAÚJO, A. H. Magalhães de; AVELINO, Guilherme A. DataCoin: Dataset Sazonal para Estratégias Quantitativas com Bitcoin. In: VII DATASET SHOWCASE WORKSHOP (DSW), 2025, Fortaleza. **Anais [...]**. Fortaleza: [s. n.], 2025. p. 43-45.

CRYPTO.COM. **In-depth article: the history of money-from-fiat-to-crypto-currency**. [S. 1.], 2022. Disponível em: <https://crypto.com/pt-br/university/in-depth-article-the-history-of-moneyfrom-fiat-to-crypto-currency>. Acesso em: 8 out. 2025.

DUARTE, J. O teste de Mann-Kendall. **Medium**, [S. 1.], 2021. Disponível em: <https://medium.com/@duarte.jr105/o-teste-de-mann-kendall-28ff71e731c6>. Acesso em: 8 out. 2025.

INFOMONEY. **Guia sobre Bitcoin: conheça a origem da primeira criptomoeda do mundo**. [S. 1.], 2022. Disponível em: <https://www.infomoney.com.br/guias/o-que-e-bitcoin/#:~:text=e%20da%20procura,-.Quando%20surgiu%20o%20Bitcoin,de%20pessoas%20interessadas%20em%20criptografia>. Acesso em: 6 nov. 2025.

JUNIOR, J. Redes Neurais Recorrentes LSTM. **Medium**, [S. 1.], 2021. Disponível em: <https://medium.com/@web2ajax/redes-neurais-recorrentes-lstm-b90b720dc3f6>. Acesso em: 10 out. 2025.

LEITE, R. S. M. M. Predição da cotação Real/Bitcoin usando a rede neural Long Short Term Memory (LSTM). 2023. 64 f. **Monografia** (Bacharelado em Ciência da Computação) – Instituto de Biotecnologia, Universidade Federal de Catalão, Catalão, 2023.

LEOTTI, V. B.; COSTER, R.; RIBOLDI, J. Normalidade de variáveis: métodos de verificação e comparação de alguns testes não paramétricos por simulação. **Revista HCPA**, Porto Alegre, v. 32, n. 2, p. 227–234, 2012. Disponível em: <https://lume.ufrgs.br/handle/10183/158102>. Acesso em: 8 out. 2025.

MARIO FILHO. **As Métricas Mais Populares para Avaliar Modelos de Machine Learning**. [S. 1.], 2018. Disponível em: <https://mariofilho.com/as-metricas-mais-populares-para-avaliar-modelos-de-machine-learning/>. Acesso em: 12 out. 2025.

MARQUES, P. Estacionariedade em séries temporais: conceitos e aplicação em Python. **Análise Macro**, [S. 1.], 2022. Disponível em: https://analisemacro.com.br/data-science/python/estacionariedade_series_temporais. Acesso em: 11 out. 2025.

MCCLLENAGHAN, Elliot. The Kruskal-Wallis Test. **Technology Networks**, [S. 1.], 2024. Disponível em: <https://www.technologynetworks.com/informatics/articles/the-kruskal-wallis-test-370025>. Acesso em: 6 nov. 2025.

META PLATFORMS, INC. **Prophet: Quick Start**. [S. 1.], 2024. Disponível em: https://facebook.github.io/prophet/docs/quick_start.html. Acesso em: 6 out. 2025.

MOONPAY. **O Bitcoin é "ouro digital"? O valor do Bitcoin**. [S. 1.], 2025. Disponível em: <https://www.moonpay.com/pt-br/learn/bitcoin/bitcoin-digital-gold>. Acesso em: 6 out. 2025.

PEREIRA, J. V. Aplicando redes neurais na predição de valores da moeda Bitcoin. 2022. **Monografia** (Bacharelado em Sistemas de Informação) – Faculdade de Computação, Universidade Federal de Uberlândia, Monte Carmelo, 2022.

POLI, P. C. R. Previsibilidade da Direção do Preço Intradiário do Bitcoin com Modelos de Random Forest. 2023. **Dissertação** (Mestrado em Ciências) – Faculdade de Economia, Administração, Contabilidade e Atuária, Universidade de São Paulo, São Paulo, 2023.

RANAROSSI, R. **YFinance Documentation**. [S. 1.], 2019. Disponível em: <https://ranaroussi.github.io/yfinance/#yfinance-documentation>. Acesso em: 6 nov. 2025.

SANTOS, C. P. Utilização de redes neurais artificiais para a predição do preço do Bitcoin através de séries temporais. 2021. **Monografia** (Bacharelado em Sistemas de Informação) – Faculdade de Tecnologia, Universidade Estadual de Campinas, Limeira, 2021.

SCIPY. **SciPy documentation**. [S. l.], 2025. Disponível em: <https://docs.scipy.org/doc/scipy/>. Acesso em: 13 out. 2025.

SEABOLD, S.; PERKTOLD, J. statsmodels: Econometric and Statistical Modeling with Python. **In: PROCEEDINGS OF THE 9TH PYTHON IN SCIENCE CONFERENCE**, 2010, [S. l.]. [S. l.: s. n.], 2010. Disponível em: <http://conference.scipy.org/proceedings/scipy2010/pdfs/seabold.pdf>. Acesso em: 10 out. 2025.

TAYLOR, S. J.; LETHAM, B. Prophet: forecasting at scale. **The Journal of Open Source Software**, [S. l.], v. 3, n. 27, p. 571, 2018. DOI: 10.21105/joss.01556. Disponível em: <https://joss.theoj.org/papers/10.21105/joss.01556>. Acesso em: 6 out. 2025.

TORMIN, W. P. Previsão de retornos do Bitcoin: uma abordagem comparativa entre modelos ARIMA e LSTM integrados com dados de tendências do Google. 2024. **Monografia** (Bacharelado em Economia) – Instituto Brasileiro de Ensino, Desenvolvimento e Pesquisa (IDP), Brasília, 2024.

VASCONCELLOS, M. A. *et al.* Séries temporais e previsão de variáveis econômicas: um estudo empírico. **Revista Econômica do Nordeste**, Fortaleza, v. 53, n. 2, p. 9–25, 2022. Disponível em: <https://www.scielo.br/j/ecos/a/TWMCNj944HvrSbbsn88jnHD/?format=html&lang=pt>. Acesso em: 11 out. 2025.

APPLICATION OF TIME SERIES AND MACHINE LEARNING MODELS FOR FORECASTING BITCOIN'S CLOSING PRICE

Abstract

This study aims to evaluate different statistical methods for forecasting Bitcoin's closing price one month ahead. To avoid any effects the COVID-19 pandemic might have had on the time series, the analyzed period spanned from September 2022 to September 2025, with September 2025 serving as the test set. The study was conducted using the Python programming language in a Google Colaboratory notebook, and the dataset was obtained using the “yfinance” library. Three models were applied, and based on the forecasting metrics, the LSTM model was found to have the best performance.

Key-words: *Bitcoin, Forecasting, LSTM.*