

José Wanderlei Francisco de Sousa Rocha
Orientador: Me. Júlio Vítor Monteiro Marques

**Uso de Aprendizado de Máquina no Apoio a
Tomada de Decisões em Investimentos de
*Bitcoins***

Picos - PI
26 de junho de 2025

José Wanderlei Francisco de Sousa Rocha
Orientador: Me. Júlio Vítor Monteiro Marques

Uso de Aprendizado de Máquina no Apoio a Tomada de Decisões em Investimentos de *Bitcoins*

Monografia submetida ao Curso de Bacharelado em Sistemas de Informação como requisito obrigatório para obtenção de grau de Bacharel em Sistemas de Informação.

Universidade Federal do Piauí
Campus Senador Heuvídio Nunes de Barros
Bacharelado em Sistemas de Informação

Picos - PI
26 de junho de 2025

FICHA CATALOGRÁFICA
Serviço de Processamento Técnico da Universidade Federal do Piauí
Biblioteca José Albano de Macêdo

R672u Rocha, José Wanderlei Francisco de Sousa.

 Uso de aprendizado de máquina no apoio a tomada de decisões em investimentos de bitcoins / José Wanderlei Francisco de Sousa Rocha – 2025.

 49 f.

 1 Arquivo em PDF.

 Indexado no catálogo *online* da biblioteca José Albano de Macêdo-CSHNB Aberto a pesquisadores, com restrições da Biblioteca.

 Trabalho de Conclusão de Curso (Graduação) – Universidade Federal do Piauí, Curso de Bacharelado em Sistemas de Informação, Picos, 2025. “Orientador: Me. Júlio Vítor Monteiro Marques”.

 1. Sistemas informacionais. 2. Segurança na internet. 3. Investimento - bitcoins. I. Rocha, José Wanderlei Francisco de Sousa. II. Marques, Júlio Vítor Monteiro. III. Título.

CDD 005.7

Elaborada por Maria Letícia Cristina Alcântara Gomes
Bibliotecária CRB nº 03/1835

USO DE APRENDIZADO DE MÁQUINA NO APOIO A TOMADA DE DECISÕES EM INVESTIMENTOS DE BITCOINS

JOSÉ WANDERLEI FRANCISCO DE SOUSA ROCHA

Monografia aprovada como exigência parcial para obtenção do grau de Bacharel em Sistemas de Informação.

Data de Aprovação

Picos – PI, 26 de JUNHO de 2025

Documento assinado digitalmente
 JULIO VITOR MONTEIRO MARQUES
Data: 05/07/2025 16:15:01-0300
Verifique em <https://validar.iti.gov.br>

Prof. Júlio Vitor Monteiro Marques

Documento assinado digitalmente
 LEONARDO PEREIRA DE SOUSA
Data: 06/07/2025 16:04:15-0300
Verifique em <https://validar.iti.gov.br>

Prof. Leonardo Pereira de Sousa

Documento assinado digitalmente
 FRANK CESAR LOPES VERAS
Data: 07/07/2025 13:52:41-0300
Verifique em <https://validar.iti.gov.br>

Prof. Frank Cesár Lopes Verás

Agradecimentos

Primeiramente gostaria de agradecer a Deus, por me proporcionar a força e a perseverança necessária para enfrentar as adversidades ao longo da minha vida acadêmica. Sua presença e proteção constante me sustentaram, principalmente nos momentos mais difíceis, me ajudando a alcançar meus objetivos. Deuteronômio 32:4 - Ele é a Rocha, as suas obras são perfeitas, e todos os seus caminhos são justos. É Deus fiel, que não comete erros; justo e reto ele é.

Agradeço aos meus pais, Lusinete Maria de Sousa Rocha e José Wanderlei da Rocha, por todo o amor, conselhos e educação que me proporcionam até hoje. As minhas irmãs, Thyara Vivianne de Souza Rocha e Cinthya Vivianne de Souza Rocha Correia por todo o cuidado e alegrias proporcionadas, me fazendo sorrir nos momentos em que estive tão preocupado. Agradeço a todos por suas contribuições que não podem ser descritas em uma única página, mas sou grato principalmente por me guiarem pelo caminho correto e terem me ajudado a moldar meu caráter e índole, me fazendo ser quem sou hoje.

Ao meu orientador Júlio Vítor Monteiro Marques, por todo o apoio e dedicação durante o período de orientação do meu trabalho, sanando minhas dúvidas sempre que surgiam. Sou muito grato por compartilhar seu tempo e conhecimento tão precioso para esta conclusão. Sua orientação foi crucial para a conclusão deste trabalho.

Agradeço também as pessoas incríveis que conheci durante minha graduação, tanto dentro quanto fora de sala de aula, e que hoje posso chamar de amigos. Principalmente Vinícius Sousa, obrigado por todo apoio e companhia nos mais diversos momentos. E por último, agradeço a todos que de forma direta ou indireta contribuíram para minha vida acadêmica, a vocês meus sinceros agradecimentos.

*Por vezes sentimos que aquilo que fazemos não é senão uma gota de água no mar. Mas
o mar seria menor se lhe faltasse uma gota.*

Madre Teresa de Calcuta

Resumo

A digitalização global tem transformado o ambiente financeiro, favorecendo o surgimento de mercados como o das criptomoedas. Entre elas, o *Bitcoin* (BTC) se destaca por seu alto potencial de retorno e baixa correlação com ativos tradicionais, tornando-se uma alternativa atrativa para diversificação de portfólios. Contudo, sua natureza volátil impõe desafios à tomada de decisão, especialmente por investidores menos experientes. Métodos tradicionais, como análise técnica e fundamentalista, exigem elevado conhecimento, reforçando a necessidade de soluções mais acessíveis. Este trabalho avaliou o uso do modelo LSTM para prever simultaneamente variáveis financeiras do *Bitcoin*, incluindo preço de fechamento, abertura, alta, baixa e preço médio, visando apoiar decisões de compra e venda. A metodologia envolveu a estruturação de uma base de dados com janelas deslizantes de seis dias, abrangendo o período de 2021 a 2025, enriquecida com atributos derivados, como variações percentuais internas. O modelo foi avaliado pelas métricas MAE, MSE, RMSE, MAPE e R^2 . Os resultados revelaram alto desempenho preditivo ($R^2 > 0,94$), especialmente para a variável Alta do Dia. Apesar da precisão em contextos estáveis, foram observadas limitações em capturar com agilidade mudanças bruscas. A integração entre LSTM, atributos derivados e um volume ampliado de dados revelou-se eficaz na previsão de múltiplas variáveis do *Bitcoin*, contribuindo para decisões mais informadas em mercados voláteis.

Palavras-chaves: Aprendizado de Máquina, *Bitcoin*, LSTM, Previsão de Preços, Séries Temporais.

Abstract

Global digitalization has transformed the financial environment, favoring the emergence of markets such as cryptocurrencies. Among them, Bitcoin (BTC) stands out for its high return potential and low correlation with traditional assets, making it an attractive alternative for portfolio diversification. However, its volatile nature poses challenges for decision-making, especially by less experienced investors. Traditional methods, such as technical and fundamental analysis, require a great deal of knowledge, reinforcing the need for more accessible solutions. This work evaluated the use of the LSTM model to simultaneously predict financial variables of Bitcoin, including closing price, opening, high, low and average price, in order to support buy and sell decisions. The methodology involved structuring a database with six-day sliding windows, covering the period from 2021 to 2025, enriched with derived attributes such as internal percentage variations. The model was evaluated using the MAE, MSE, RMSE, MAPE and R^2 metrics. The results showed high predictive performance ($R^2 > 0.94$), especially for the High of the Day variable. Despite the accuracy in stable contexts, limitations were observed in capturing sudden changes with agility. The integration of LSTM, derived attributes and an expanded volume of data proved to be effective in predicting multiple *Bitcoin* variables, contributing to more informed decisions in volatile markets.

Keywords: Machine Learning, Bitcoin, LSTM, Price Prediction, Time Series.

Lista de ilustrações

Figura 1 – Divisão dos sistemas de recomendação.	16
Figura 2 – Estrutura expandida de uma RNN.	20
Figura 3 – Fluxo de informações em uma célula LSTM.	22
Figura 4 – Fluxograma das etapas do trabalho.	29
Figura 5 – Probabilidade Quantílica (Q-Q) do Preço de Fechamento.	32
Figura 6 – Comparação da distribuição do atributo Fechamento antes e depois da aplicação do método IQR.	33
Figura 7 – Curva de aprendizado do modelo durante o treinamento.	36
Figura 8 – Valores reais vs. previstos da variável Fechamento no conjunto de teste.	38
Figura 9 – Valores reais vs. previstos da variável Abertura no conjunto de teste.	38
Figura 10 – Valores reais vs. previstos da variável Alta do dia no conjunto de teste.	39
Figura 11 – Valores reais vs. previstos da variável Baixa do dia no conjunto de teste.	39
Figura 12 – Valores reais vs. previstos da variável Preço Médio no conjunto de teste.	40

Lista de tabelas

Tabela 1 – Trabalhos relacionados.	28
Tabela 2 – Descrição das colunas da base de dados original.	30
Tabela 3 – Amostras iniciais da base de dados.	30
Tabela 4 – Estatísticas descritivas das variáveis numéricas.	31
Tabela 5 – Descrição dos novos atributos da base de dados.	31
Tabela 6 – Resultados das métricas para cada variável prevista no conjunto de teste.	37
Tabela 7 – Erro médio e desvio padrão por variável prevista no conjunto de teste.	41
Tabela 8 – Amostras finais utilizadas na validação autorregressiva iterativa.	41
Tabela 9 – Métricas de desempenho na validação autorregressiva iterativa.	42
Tabela 10 – Valores previstos na validação autorregressiva iterativa.	42

Lista de abreviaturas e siglas

ACF	AutoCorrelation Function
ANN	Artificial Neural Network
ARIMA	AutoRegressive Integrated Moving Average
ARMA	AutoRegressive Moving Average
BC	Baseada em Conteúdo
BTC	Bitcoin
CNN	Convolutional Neural Network
FC	Filtragem Colaborativa
FWLS	Feature-Weighted Linear Stacking
GRU	Gated Recurrent Unit
IA	Inteligência Artificial
IQR	InterQuartile Range
LSTM	Long Short-Term Memory
MAE	Mean Absolute Error
MD5	Message Digest 5
NN	Neural Network
PACF	Partial AutoCorrelation Function
ReLU	Rectified Linear Unit
RMSE	Root Mean Square Error
RNN	Recurrent Neural Network
RSI	Relative Strength Index
SHA-256	Secure Hash Algorithm 256-bit
SVM	Support Vector Machine
USD	United States Dollar

Sumário

1	Introdução	12
1.1	Objetivos	13
2	Referencial Teórico	14
2.1	Mercado de Criptomoedas	14
2.2	Sistemas de Recomendação	15
2.3	Séries Temporais	17
2.3.1	Aprendizado de Máquina	18
2.3.2	Modelos de Predições de Séries Temporais	18
2.3.2.1	Modelo ARIMA	19
2.3.2.2	Redes Neurais Recorrentes	20
2.3.3	Métricas de Avaliação	21
3	Trabalhos Relacionados	25
4	Metodologia	29
4.1	Descrição da Base de Dados	29
4.2	Pré-processamento dos Dados	30
4.3	Análise Exploratória dos Dados	32
4.4	Transformação dos Dados	33
4.5	Divisão dos Dados em Conjuntos	34
4.6	Configuração e Treinamento do Modelo	34
5	Resultados	36
5.1	Previsões das Variáveis Monetárias	36
5.2	Validação Autorregressiva Iterativa	41
5.3	Discussões	42
6	Conclusão	44
	Referências	45

1 Introdução

A digitalização em escala global abrange não apenas os setores de engenharia, arquitetura e construção, tradicionalmente associados ao ambiente construído, mas também, se estende ao ambiente financeiro moderno (MANZOOR; OTHMAN; POMARES, 2021; ALIU et al., 2024). Esta ainda desempenha um papel crucial no desenvolvimento de praticamente todas as áreas da economia, permitindo o surgimento de novos mercados, formas de comunicação e abordagens para organizar e gerenciar a produção de bens e a oferta de serviços (ZAIETS; YESKOV, 2021). As criptomoedas foram consideradas uma tecnologia emergente de moeda eletrônica descentralizada, com potencial para transformar o ambiente econômico e os sistemas de troca financeira (ROUHANI; ABEDIN, 2020).

O avanço tecnológico e a pandemia de COVID-19 impulsionaram o interesse por investimentos alternativos, como as criptomoedas, que se tornaram opções atrativas aos investidores para diversificar seus portfólios. Dentre elas, o *Bitcoin* (BTC), a criptomoeda mais antiga e popular, disponível desde 2009, destacou-se por sua característica de retorno significativo, alcançando uma capitalização de mercado de US\$ 824 bilhões de dólares em setembro de 2021 (BAIG, 2022; NAKAMOTO, 2008). Além disso, a baixa correlação do *Bitcoin* com ativos tradicionais, como ações globais, títulos e moedas fortes, aliada aos seus altos retornos médios e elevada volatilidade, tanto em períodos de estabilidade quanto de instabilidade financeira, faz dele uma ferramenta eficaz para diversificação de portfólio (BAUR; HONG; LEE, 2018).

Existe uma crescente demanda por ativos digitais, mas, os investidores enfrentam desafios devido à quantidade de criptomoedas diferentes, as singularidades tecnológicas e o mercado em constante evolução. Sendo as principais barreiras de entrada neste mercado a falta de conhecimento dos consumidores de varejo e o alto risco junto a volatilidade para investidores institucionais (BRUHN; ERNST, 2022). A complexidade do mercado de criptomoedas decorre, principalmente, do fato de seu valor não estar atrelado a ativos tangíveis, fundamentos de uma empresa ou a economia de um país, mas sim a um algoritmo (CORBET et al., 2019). Por isso, os investidores deste mercado precisam recorrer a ferramentas adequadas para lidar com as variações de volatilidade (MBA; PINDZA; KOUMBA, 2018; MBA; MWAMBI, 2020).

Um sistema de recomendação é um *software* projetado para recomendar aos usuários os itens mais adequados às suas necessidades em um contexto (RICCI; ROKACH; SHAPIRA, 2010). Esse tipo de sistema tem a função de filtrar informações para destacar as mais úteis, alcançando seu principal objetivo: a satisfação do usuário (SHARAF et al., 2022). No entanto, há poucos sistemas de recomendação voltados para oferecer orientações sobre investimentos e economia, além de esses sistemas, em geral, apresentarem baixa eficácia e alta complexidade (KANAUJIA et al., 2016). A interpretação da movimentação

das criptomoedas é desafiadora devido à volatilidade do mercado e à necessidade de processar grandes volumes de dados em tempo real. Desta forma, torna-se essencial explorar a viabilidade do uso de métodos de aprendizado de máquina para aprimorar recomendações de compra e venda de ativos digitais.

A natureza volátil e imprevisível do mercado de criptomoedas impõe desafios significativos àqueles que desejam investir nesse setor. As análises tradicionais, como a técnica e a fundamentalista, embora amplamente utilizadas, exigem alto nível de conhecimento e experiência, sendo pouco acessíveis a investidores iniciantes. Nesse contexto, cresce o interesse por abordagens capazes de lidar com grandes volumes de dados e padrões complexos. Destacam-se as Redes Neurais Recorrentes (RNNs, *Recurrent Neural Network*), projetadas para dados sequenciais; entre elas, o modelo *Long Short-Term Memory* (LSTM), que permite modelar dependências temporais de longo prazo. Este trabalho propõe explorar o potencial do LSTM na previsão do comportamento do *Bitcoin*, oferecendo uma alternativa robusta, adaptável e precisa para um mercado em constante transformação.

1.1 Objetivos

O objetivo geral deste trabalho é avaliar a viabilidade do uso de algoritmos de aprendizado de máquina para prever o comportamento de preços do *Bitcoin*, auxiliando os investidores em suas decisões de compra e venda no mercado de criptomoedas.

Para alcançar o objetivo geral, foram definidos os seguintes objetivos específicos:

- Estruturar uma base de dados com as variações históricas do *Bitcoin*, incluindo as variáveis previstas e auxiliares.
- Implementar uma Rede Neural Recorrente, utilizando o modelo LSTM, para prever o comportamento do *Bitcoin* com base nos dados históricos.
- Avaliar o desempenho do modelo preditivo por meio das métricas de regressão.

Os demais capítulos deste trabalho estão organizados da seguinte forma: o Capítulo 2 apresenta o referencial teórico, abordando os conceitos e bases para o estudo; o Capítulo 3 discute trabalhos relacionados, destacando pesquisas previamente realizadas na área; o Capítulo 4 descreve a metodologia utilizada; no Capítulo 5 são apresentados e analisados os resultados obtidos; e por fim, o Capítulo 6 conclui o estudo, bem como sugestões para trabalhos futuros.

2 Referencial Teórico

Este capítulo busca expor conceitos importantes para compreensão da proposta do trabalho, oferecendo uma base teórica que contextualiza a metodologia adotada. Serão abordados os seguintes assuntos: Mercado de Criptomoedas, Sistemas de Recomendação, Séries Temporais, Aprendizado de Máquina, Modelos de Predições de Séries Temporais, Modelo ARIMA, Redes Neurais Recorrentes e Métricas de Avaliação. Esses tópicos fornecem um panorama sobre o contexto econômico das criptomoedas, os desafios da tomada de decisão no mercado e as abordagens computacionais, como modelos de predição de séries temporais, utilizadas para auxiliar investidores.

2.1 Mercado de Criptomoedas

O dinheiro possui quatro funções básicas: primeiramente como um meio de troca, sendo usado em transações para trocar bens e serviços; em segundo lugar, funciona como padrão de pagamento diferido, possibilitando a liquidação de dívidas futuras; em terceiro lugar, atua como reserva de riqueza, facilitando o acúmulo de riqueza ao passar do tempo desde que mantenha sua estabilidade e, por último, serve como uma unidade de conta para medir o valor de bens e serviços, em uma economia ([Corporate Finance Institute, 2025](#)). As criptomoedas compartilham essas mesmas funções do dinheiro tradicional, mas se diferenciam por serem ativos exclusivamente digitais, sem a necessidade de uma representação física.

Uma criptomoeda é uma moeda virtual protegida por criptografia, utilizando algoritmos como SHA-256 e MD-5, para garantir a segurança em transações financeiras, tornando-as praticamente impossíveis de serem falsificadas ou duplicadas ([BILLIG; GRZYBOVSKI, 2022](#)). O mercado de criptomoedas se diferencia do sistema financeiro tradicional por eliminar a necessidade de intermediários, como bancos e governos. Esse modelo descentralizado permite transações independentes, sem a intermediação de instituições financeiras centralizadas ([PAREKH et al., 2022](#)). Uma grande quantidade de criptomoedas são estruturadas em redes descentralizadas que usam a tecnologia blockchain ([BILLIG; GRZYBOVSKI, 2022](#)).

O blockchain, pode ser entendido de forma simples, como um livro-razão digital que registra as transações realizadas para facilitar o rastreamento e a proteção de ativos digitais. Essas transações são armazenadas em blocos interligados por mecanismos de *hash*, garantindo a imutabilidade dos registros e permitindo um compartilhamento seguro mesmo em ambientes não confiáveis ([HUYNH-THE et al., 2023](#)). As carteiras de criptomoedas são objetos digitais utilizadas para armazenar as credenciais digitais das participações em moeda, garantindo a segurança do usuário por meio de um par de chaves criptográficas: a

chave pública, que funciona como um endereço para receber transações, e a chave privada, que concede acesso aos ativos e autoriza movimentações (GURI, 2018). Para realizar uma transação no blockchain, o usuário deve assinar digitalmente a operação, comprovando a posse das moedas antes de transferi-las (SURATKAR; SHIROLE; BHIRUD, 2020). Com a crescente complexidade do mercado de criptomoedas, surgiram desafios na tomada de decisão dos investidores. Nesse contexto, os sistemas de recomendação podem auxiliar usuários a identificar oportunidades de compra e venda de ativos digitais.

2.2 Sistemas de Recomendação

Grandes volumes de dados exigem mecanismos eficientes de filtragens, pois os serviços de busca tradicionais não são capazes de personalizar os resultados conforme os interesses individuais. Para superar tal limitação, os sistemas de recomendação foram desenvolvidos para fornecer o serviço de sugestões personalizadas (CUI et al., 2020). Esses sistemas analisam dados coletados sobre as escolhas e comportamentos individuais para prever a relevância de novos itens. Para isso, processam grandes volumes de informações, identificam padrões e geram sugestões personalizadas, tornando-se fundamentais na otimização do consumo de conteúdo digital (MILANO; TADDEO; FLORIDI, 2020).

Inicialmente, os sistemas de recomendação ganharam destaque em plataformas de entretenimento, comércio eletrônico e redes sociais, sendo amplamente utilizados em serviços como Netflix¹, Spotify², Amazon³ e Facebook⁴. No entanto, sua aplicação se expandiu para diversos setores, incluindo o mercado financeiro, onde auxiliam na sugestão de investimentos e novos produtos, e até mesmo em governos, sendo utilizados na personalização de anúncios em eleições e no aprimoramento da relação com o público (BEHESHTI et al., 2020). Há três classificações possíveis para um sistema de recomendação com base na filtragem de informações realizada por eles. Sendo elas, a Filtragem Colaborativa (FC), Baseada em Conteúdo (BC) e Híbrida (SHARAF et al., 2022). A Figura 1 apresenta as possíveis classificações para um sistema de recomendação.

Segundo Cui et al. (2020) a FC é uma técnica de recomendação que avalia a preferência de um usuário conforme seus registros de comportamento e, com base nisso, sugere as recomendações segundo as preferências de outros usuários com interesses semelhantes, sem depender de informações específicas sobre os itens, como descrições ou metadados, o que permite recomendar uma ampla variedade de objetos, como livros, filmes e outros. Os algoritmos usados na FC podem ser divididos em duas categorias principais: baseados em memória e baseados em modelos (BRESE; HECKERMAN; KADIE, 2013). Segundo Nguyen et al. (2020), para algoritmos baseados em memória, é possível utilizar parte

¹ <https://www.netflix.com>

² <https://www.spotify.com>

³ <https://www.amazon.com>

⁴ <https://www.facebook.com>

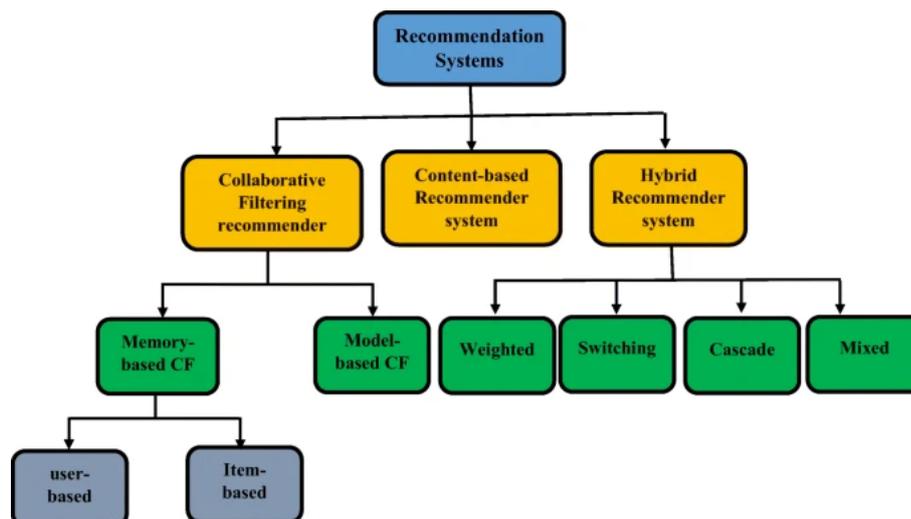


Figura 1 – Divisão dos sistemas de recomendação.

ou todo um banco de dados de itens já avaliados por usuários para gerar previsões. Esse método identifica grupos de usuários com preferências semelhantes e estima as preferências de um novo usuário com base nas avaliações feitas por seus vizinhos mais próximos. Já os algoritmos baseados em modelo possibilitam que o sistema aprenda a partir de um modelo previamente definido, permitindo a identificação de padrões nos dados de treinamento.

O sistema de recomendação de abordagem BC utiliza as características dos itens para criar recomendações personalizadas, analisando o perfil do usuário e seu histórico de preferências (ATTARDE; SINGH, 2017). Esse sistema mede a similaridade entre os itens com base em suas características e utiliza aprendizado de máquina para construir perfis de usuários e gerar sugestões relevantes (RICCI; ROKACH; SHAPIRA, 2010). Ao contrário da FC, o BC não sofre com o problema de inicialização a frio e pode ser mais eficaz ao ter informações detalhadas sobre os itens (NAWARA; KASHEF, 2020). Por outro lado, os sistemas de recomendação baseados em conteúdo enfrentam desafios como análise limitada de conteúdo, dispersão e reciprocidade (JAIN et al., 2015).

Os sistemas de recomendação híbridos combinam diferentes abordagens de recomendação, como a FC e o BC, para melhorar a precisão e a eficácia dos resultados (WALEK; FAJMON, 2023). Essa integração permite contornar limitações específicas de cada técnica de recomendação aplicada isoladamente, aproveitando as forças de cada abordagem para aprimorar suas recomendações. Essa categoria de sistemas de recomendação também tem se mostrado compatível com técnicas de Inteligência Artificial (IA), ampliando seu potencial de personalização e precisão de recomendações (BISWAS; LIU, 2022; KIRAN; KUMAR; BHASKER, 2020). Existem diversas estratégias de hibridização, como ponderação, comutação e a *Feature-Weighted Linear Stacking* (FWLS, empilhamento linear ponderado por recursos), permitindo que o sistema se adapte dinamicamente às necessidades dos usuários e melhore continuamente as recomendações com base no desempenho dos modelos aplicados (BURKE, 2002).

2.3 Séries Temporais

Uma série temporal é um conjunto de amostras ordenadas cronologicamente de uma variável com valor real que contém diversos registros ao longo do tempo (FERNANDEZ et al., 2020). Dados de séries temporais são organizados de forma sequencial e de cada amostra pode influenciar as subsequentes, apresentando padrões e tendências que descrevem a evolução de diferentes sistemas e processos (JIANG et al., 2024; WANG et al., 2024; ZHANG et al., 2024a). A análise de séries temporais é amplamente empregada em diversos domínios, como: medicina, ciências ambientais e economia (SHUMWAY; STOFFER, 2017).

As séries temporais podem ser classificadas em três categorias conforme suas características estruturais: a) Univariada representa a evolução de uma única variável ao longo do tempo, sendo definida como uma sequência ordenada de amostras indexadas no tempo. As medições geralmente ocorrem em intervalos regulares; b) Multivariada compreende múltiplas variáveis interdependentes que progridem simultaneamente, esse tipo de série pode ser visto como um conjunto de séries univariadas correlacionadas; c) Multivariadas múltiplas referem-se à análise simultânea de diversas séries temporais multivariadas, aplicada em cenários complexos. Estudar esses conjuntos envolve examinar cada um de forma independente e explorar suas relações (ZHANG et al., 2024b).

O objetivo da análise das séries temporais é estimar o valor da variável observada em um momento futuro, com base em amostras disponíveis até um certo momento (HAN et al., 2021). Embora seja desafiadora, a previsão é uma etapa essencial da análise de séries temporais. O desempenho e a precisão das técnicas preditivas são fortemente influenciados pelos tipos de dados da série temporal e pelo contexto em que os dados foram gerados. Além disso, fatores relacionados ao domínio dos dados, como sazonalidade, oscilações econômicas, eventos inesperados e até mudanças internas na organização responsável por estes dados podem impactar a qualidade das previsões (SIAMI-NAMINI; TAVAKOLI; NAMIN, 2019).

A principal limitação dos métodos tradicionais de previsão de séries temporais reside na dificuldade de realizar previsões em múltiplas etapas no futuro, apesar de serem eficazes para etapas únicas. Isso ocorre devido à necessidade de considerar fatores como o acúmulo de erros e a degradação progressiva do desempenho preditivo (BAO; XIONG; HU, 2014). A volatilidade é outro fator que dificulta a previsão do mercado de criptomoedas, sendo influenciada por fatores como volume de negociação, popularidade do ativo, sentimentos em redes sociais e até regulamentações específicas de cada país, o que adiciona camadas de incerteza ao processo preditivo (SOVBETOV, 2018; ANGELA; SUN, 2020).

2.3.1 Aprendizado de Máquina

Técnicas de aprendizado de máquina e aprendizado profundo têm se destacado na análise de dados com IA, elevando os processos analíticos ao construir modelos guiados pelos próprios dados, em vez de depender exclusivamente de modelos predefinidos (SIAMINAMI; TAVAKOLI; NAMIN, 2019). Originado do reconhecimento de padrões e da IA, o aprendizado de máquina é um subcampo da ciência da computação (MOHAMMED; KHAN; BASHIER, 2016). O aprendizado de máquina é uma área de estudo que permite aos computadores aprenderem automaticamente a partir de dados, sem depender exclusivamente de programações explícitas (SIMON, 2013). Sendo sua principal tarefa criar um modelo razoável e em sequência fazê-lo aprender com dados históricos e experiências para realizar tarefas específicas, destacando-se pela capacidade de aprendizado em contraste com sistemas especialistas tradicionais (WANG; ZHANG, 2023).

Há quatro abordagens de aprendizado de máquina, classificadas com base no processo de aprendizagem, sendo elas: aprendizado supervisionado, não supervisionado, semi-supervisionado e por reforço (PORTUGAL; ALENCAR; COWAN, 2018). No treinamento do aprendizado supervisionado, as amostras de treinamento são inicialmente rotuladas, permitindo que o modelo aprenda o relacionamento de mapeamento entre os atributos dos dados e seus rótulos, produzindo assim uma função completa para ser usada em instâncias não observadas (WANG; ZHANG, 2023). Os métodos de aprendizado não supervisionado identificam estruturas e padrões diretamente nos dados, sem a necessidade de rótulos previamente definidos (RODRIGUEZ-NIEVA; SCHEURER, 2019). Tais métodos são utilizados principalmente em tarefas descritivas onde não se têm informação sobre a saída disponível (ROCHA et al., 2022).

Quando as informações completas de rótulos nem sempre estão disponíveis, o aprendizado semi-supervisionado oferece uma estrutura poderosa para aproveitar dados não rotulados quando os rótulos são limitados ou custosos de obter (OLIVER et al., 2018). A abordagem mais recente de aprendizado de máquina é útil quando sabemos o que buscamos, mas não como alcançá-lo. O método envolve testar várias soluções para identificar quais permitem atingir o resultado desejado. O aprendizado por reforço pode ser descrito como um agente que toma decisões em um ambiente, onde ele aprende a responder ao ambiente em uma dinâmica de tentativa e erro para maximizar suas recompensas (ROCHA et al., 2022; FRANÇOIS-LAVET et al., 2018).

2.3.2 Modelos de Predições de Séries Temporais

A análise de séries temporais tem como objetivo principal identificar padrões nos dados históricos e utilizá-los para prever valores futuros, fornecendo suporte à tomada de decisões (LIU et al., 2021). No entanto, não há uma única técnica que se destaque como a melhor para todos os cenários, pois a eficácia dos modelos varia conforme a natureza

dos dados e o contexto do problema (ZHANG; KLINE, 2007). Dessa forma, a escolha da abordagem mais adequada depende das características específicas de cada conjunto de dados e do objetivo da previsão (ENSAFI et al., 2022). A presente seção apresenta algumas técnicas para realizar a previsão de séries temporais existentes, como o modelo ARIMA e as RNNs.

2.3.2.1 Modelo ARIMA

O modelo *AutoRegressive Integrated Moving Average* (ARIMA, autorregressivo integrado de médias móveis) é reconhecido como um dos modelos mais populares para modelagem e previsão de séries temporais (CHEN; WANG; KUO, 2007; SINGH et al., 2020). Ele representa uma abordagem estocástica para identificar padrões de comportamento em séries temporais, mas possui limitações na captura de relações não lineares, tornando-se menos adequado para problemas complexos. Além disso, o modelo ARIMA tradicional (p, d, q) é projetado para lidar com tendências, mas não incorpora diretamente a sazonalidade dos dados (KAUR; PARMAR; SINGH, 2023). Antes de aplicar o ARIMA, é essencial verificar se a série temporal é estacionária, ou seja, se suas propriedades estatísticas, como média e variância, permanecem constantes ao longo do tempo (SATRIO et al., 2021).

O modelo ARIMA é uma expansão do modelo *AutoRegressive Moving Average* (ARMA, média móvel autoregressiva), feito para lidar com séries temporais não estacionárias ao aplicar diferenciação para eliminar tendências e sazonalidades (KONTOPOULOU et al., 2023). A transformação de séries temporais não estacionárias em estacionárias é feita por meio da diferenciação de ponto finito, separando o sinal, representado por as informações úteis e padrões previsíveis, do ruído, composto por elementos aleatórios ou imprevisíveis que não seguem um padrão claro (BOX et al., 2015). O ARIMA separa o sinal de tempo do ruído para então criar suas previsões sobre pontos futuros (RUNDO et al., 2019).

Há três componentes estruturais deste modelo (SIAMI-NAMINI; TAVAKOLI; NAMIN, 2018). O primeiro é a autorregressão, que estabelece uma relação entre os valores atuais da série temporal e suas observações passadas, utilizando um número específico de defasagens definido pelo parâmetro p . O segundo componente, a integração, refere-se ao número de diferenciações necessárias para transformar uma série temporal não estacionária em estacionária, sendo representado pelo parâmetro d . Por fim, a média móvel captura a dependência entre os valores observados e os erros das previsões anteriores, sendo regulada pelo parâmetro q .

Segundo Kaur, Parmar e Singh (2023) a modelagem ARIMA segue quatro etapas essenciais. A identificação consiste na análise das funções de autocorrelação (ACF, *Auto-Correlation Function*) e autocorrelação parcial (PACF, *Partial AutoCorrelation Function*) para determinar os valores adequados dos parâmetros (p, d, q), garantindo que a série seja estacionária e bem ajustada ao modelo. Em seguida, a estimação dos parâmetros é realizada por métodos estatísticos, como máxima verossimilhança e mínimos quadrados,

para ajustar os coeficientes do modelo. Após a estimativa, ocorre a verificação, na qual são aplicados testes diagnósticos para avaliar a adequação do modelo, analisando os resíduos quanto à aleatoriedade e homocedasticidade. Por fim, a etapa de previsão utiliza a estrutura do modelo ajustado para projetar valores futuros da série temporal, muitas vezes complementada por intervalos de confiança que indicam a incerteza das previsões.

2.3.2.2 Redes Neurais Recorrentes

Uma Rede Neural Recorrente é um tipo de Rede Neural (NN, *Neural Network*) com desempenho significativo para dados sequenciais (SINGH et al., 2021). RNNs são a arquitetura de NN mais comum de ser utilizada em problemas de previsão de sequência, embora também tenham ganhado popularidade para processamento de linguagem natural (HEWAMALAGE; BERGMEIR; BANDARA, 2021). Elas se diferenciam das redes neurais artificiais (ANNs) por possuírem retroalimentação contínua para armazenar a ordem e as dependências temporais presentes nos dados sequenciais (SCHÄFER; ZIMMERMANN, 2006). A principal vantagem das RNNs é sua capacidade de modelar sequências temporais de comprimento variável, o que proporciona maior flexibilidade na análise de dados sequenciais, como no processamento de fala e geração de texto (BAKTHA; TRIPATHY, 2017). A mesma unidade recorrente é replicada para cada passo temporal, mantendo pesos e vieses compartilhados. Essa estrutura permite que as informações processadas em etapas anteriores influenciem as etapas seguintes por meio de conexões internas (HEWAMALAGE; BERGMEIR; BANDARA, 2021). A Figura 2 apresenta uma RNN em seu formato estendido.

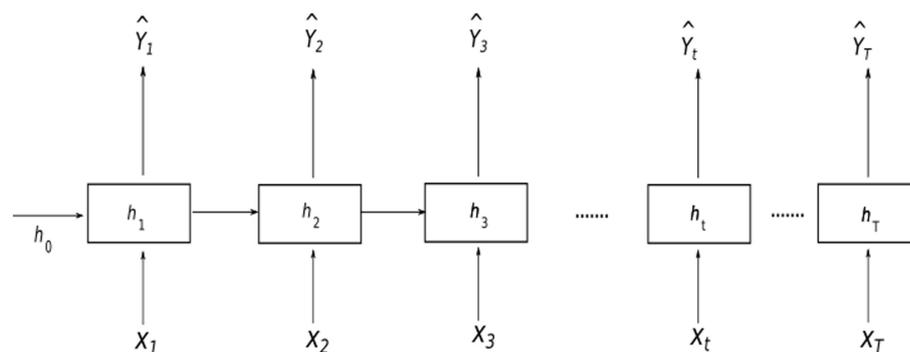


Figura 2 – Estrutura expandida de uma RNN.

Ao realizar seu treinamento, uma RNN pode lidar com problemas de gradiente explosivo e de desaparecimento (PASCANU; MIKOLOV; BENGIO, 2013). Este problema surge quando os gradientes, ao serem retropropagados durante o treinamento, diminuem exponencialmente, desaparecendo ou crescendo descontroladamente. Isso ocorre devido à multiplicação sequencial de matrizes na retropropagação, causando instabilidade no aprendizado, especialmente em RNNs ou Redes Neurais Profundas ao lidar com dependências de longo prazo (CENI, 2025). O desaparecimento e explosão do gradiente compromete o

desempenho da RNN padrão, tornando-a incapaz de aprender dependências a longo prazo e produzindo uma baixa precisão de validação e precisão. Como resposta a essas limitações, arquiteturas como *Long Short-Term Memory* (LSTM, Memória de Longo e Curto Prazo) e *Gated Recurrent Unit* (GRU, Unidade Recorrente com Portões) foram projetadas para mitigar esse problema, permitindo um aprendizado mais eficiente de dependências longas e proporcionando maior precisão preditiva (NOH, 2021).

Uma rede LSTM possui, em cada célula, dois componentes principais: o estado oculto e o estado interno. O estado oculto funciona como uma memória de curto prazo, sendo responsável pela saída da célula em cada passo temporal. Já o estado interno atua como uma memória de longo prazo, permitindo o armazenamento e a propagação de informações relevantes ao longo da sequência (HEWAMALAGE; BERGMEIR; BANDARA, 2021). Além disso, o funcionamento das LSTMs depende de três portões fundamentais que controlam como as informações são atualizadas e preservadas ao longo do tempo.

A Porta de Entrada avalia o input atual combinado ao estado oculto anterior, decidindo quanto dessa nova informação será incorporada ao estado interno. A Porta de Esquecimento define, também com uma função logística, qual parte do estado interno deve ser descartada, eliminando dados irrelevantes ou desatualizados. Por fim, a Porta de Saída determina qual fração do estado interno será transformada – geralmente via \tanh – e usada como saída, isto é, o novo estado oculto transmitido à próxima célula. Juntas, essas portas permitem à LSTM mitigar o desaparecimento do gradiente, retendo informações úteis por longos períodos e favorecendo um aprendizado mais robusto em tarefas com dados sequenciais (BAKTHA; TRIPATHY, 2017). As portas de entrada, esquecimento e saída, são representadas pelos termos I_t , F_t e O_t respectivamente.

Durante esse processo, a célula recebe como entrada o vetor x_t , bem como os estados anteriores h_{t-1} (oculto) e C_{t-1} (interno). Com base nessas entradas, os portões intermediários f_t (esquecimento), i_t (entrada), g_t (estado candidato) e o_t (saída) são responsáveis por regular as atualizações internas, combinando ativações *sigmoid* e *tanh*. O resultado desse processamento são os novos estados C_t e h_t , que serão utilizados nas próximas iterações da sequência (ZHOU et al., 2019). A Figura 3 ilustra a estrutura interna de uma célula LSTM e seus componentes operacionais.

2.3.3 Métricas de Avaliação

Na avaliação de modelos aplicados à previsão de séries temporais, são utilizadas métricas específicas para quantificar a precisão das estimativas. Essas métricas consideram o erro residual, calculado como a diferença entre o valor observado e o valor previsto (KUMARI; SINGH, 2023). Dentre as mais utilizadas estão o *Mean Absolute Error* (MAE, Erro Médio Absoluto), o *Mean Squared Error* (MSE, Erro Quadrático Médio), *Root Mean Squared Error* (RMSE, Raiz do Erro Quadrático Médio), *Mean Absolute Percentage Error* (MAPE, Erro Percentual Absoluto Médio), e o R-squared (R^2 , R-quadrado).

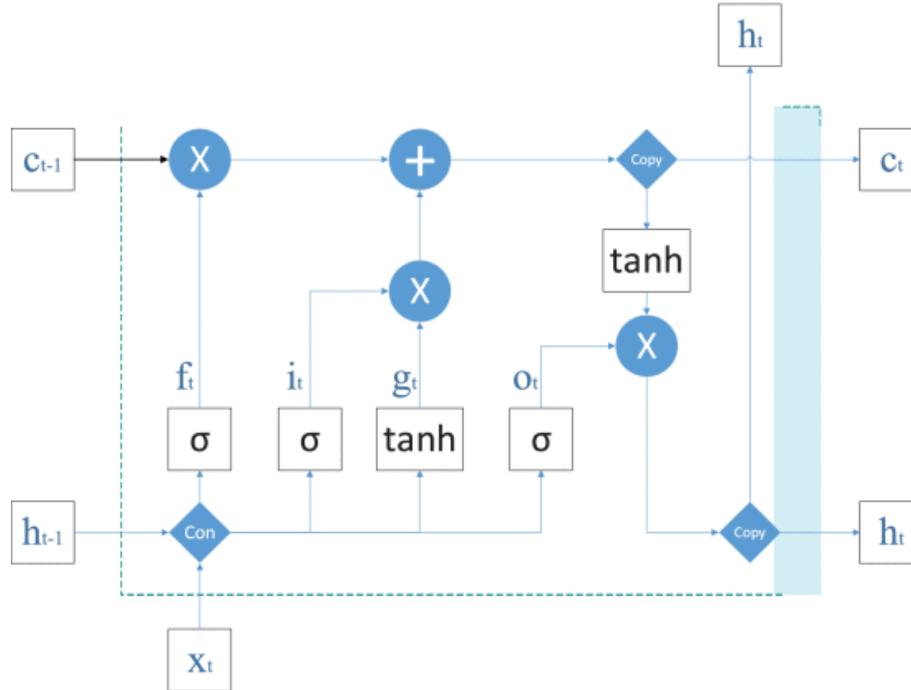


Figura 3 – Fluxo de informações em uma célula LSTM.

O MAE, representa a média das diferenças absolutas entre os valores previstos e os valores reais observados. Ele indica o quão distante, em média, as previsões do modelo estão dos valores reais. Quanto menor for o MAE, melhor será o desempenho do modelo, sendo que um valor igual a zero indica alta precisão nas previsões (ALBELADI; ZAFAR; MUEEN, 2023). A Equação 2.1 apresenta a fórmula para calcular o MAE.

$$\text{MAE} = \frac{1}{n} \sum_{i=1}^n |\hat{y}_i - y_i| \quad (2.1)$$

Onde:

- n é o número de observações
- \hat{y}_i é o valor previsto
- y_i é o valor observado

O MSE, avalia o grau de dispersão entre os valores previstos e os valores observados. Essa avaliação é feita por meio do cálculo da média quadrática das diferenças entre esses valores. Essa métrica evidencia o quanto as previsões se desviam dos resultados observados, penalizando mais fortemente erros maiores. Quanto menor o MSE, mais próximo o modelo está de reproduzir os dados reais (FAISAL et al., 2022). Para calcular o MSE é utilizado a Equação 2.2.

$$\text{MSE} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2 \quad (2.2)$$

Onde:

- n é o número de observações
- \hat{y}_i é o valor previsto
- y_i é o valor observado

O RMSE, é uma métrica que representa o desvio médio entre os valores previstos e os valores observados. É obtida aplicando a raiz quadrada sobre o MSE, o que permite manter a unidade original dos dados enquanto preserva a penalização de erros maiores. Quando o RMSE apresenta valores significativamente superiores ao MAE, isso pode indicar a presença de grandes desvios em algumas previsões (ALBELADI; ZAFAR; MUEEN, 2023). A Equação 2.3 apresenta a fórmula para calcular o RMSE.

$$\text{RMSE} = \sqrt{\frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2} \quad (2.3)$$

Onde:

- n é o número de observações
- \hat{y}_i é o valor previsto
- y_i é o valor observado

O MAPE, é utilizado comumente na avaliação de modelos de previsão. Ele é obtido a partir da média dos erros percentuais absolutos entre os valores previstos e os valores reais, normalizados pelo valor real. Facilita a comparação entre diferentes escalas de séries temporais, já que expressa o erro em porcentagem (FAISAL et al., 2022). Para calcular o MAPE é utilizada a Equação 2.4.

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.4)$$

Onde:

- n é o número de observações
- y_i é o valor observado
- \hat{y}_i é o valor previsto

O R-quadrado (R^2 , R-squared), ou coeficiente de determinação, é uma métrica utilizada para avaliar a precisão das previsões em modelos de regressão. Seu intervalo de valores varia entre 0 e 1, sendo que quanto mais próximo de 1, melhor é o desempenho do modelo. Um valor de 0 indica que o modelo não explica a variação nos dados, sendo equivalente a prever pela média dos valores. Em geral, quanto maior o valor de R^2 , melhor

o ajuste do modelo aos dados observados, refletindo uma maior capacidade de previsão (CAI et al., 2020). A Equação 2.5 apresenta a fórmula para calcular o R^2 .

$$R^2 = 1 - \frac{\sum_{i=1}^n (y_i - \hat{y}_i)^2}{\sum_{i=1}^n (y_i - \bar{y})^2} \quad (2.5)$$

Onde:

- y_i é o valor observado
- \hat{y}_i é o valor previsto
- \bar{y} é a média dos valores observados

3 Trabalhos Relacionados

Este capítulo apresenta os trabalhos relacionados identificados na literatura que possuem um contexto ou abordagem semelhante ao deste projeto. Diversos estudos na literatura analisam o desempenho de modelos de predição treinados com séries temporais sobre o cenário financeiro. A descrição detalhada dos trabalhos é feita com base em sua classificação. Os trabalhos foram classificados em dois grupos principais conforme o ativo financeiro a ser previsto.

A primeira classificação lida com estudos que focaram na previsão de ações. O trabalho de [Niu et al. \(2020\)](#) propôs uma metodologia que combina seleção de características em duas etapas e correção de erros para previsão do preço de ações. A metodologia proposta pelos autores consistiu inicialmente na seleção de características utilizando o RReliefF, um método baseado em filtro, seguido por um modelo wrapper-based multiobjetivo com Grey Wolf optimizer, Cuckoo search e Extreme Learning Machine (ELM). O modelo proposto inclui três unidades recorrentes: LSTM, GRU e Convolutional LSTM. Após as previsões, um modelo de correção de erros foi aplicado utilizando decomposição empírica com ruído adaptativo e regressão Lasso. Os dados usados foram coletados do Choice EastMoney, abrangendo os índices SZCI, SZFI e DJIA, com dados de 12, 16 e 17 anos, respectivamente. As variáveis analisadas incluíram preço de abertura, fechamento, máximos, mínimos, variação de preço e volume de transações. O conjunto de dados foi dividido em 80% para treinamento e 20% para teste. O modelo proposto alcançou um *MAE* de 3,24, *RMSE* de 5,78 e *MAPE* de 2,66% para índice DJIA.

Em busca de novas abordagens para a previsão de séries temporais financeiras, tradicionalmente realizadas por modelos lineares como o ARIMA, eficazes para previsões de curto prazo ou sazonalidades, o estudo de [Pirani et al. \(2022\)](#) avaliou o desempenho de modelos de RNNs, como LSTM, GRU e BiLSTM. Esse estudo permitiu considerar a direção de processamento, unidirecional e bidirecional, e a complexidade das arquiteturas, em relação ao número de portas, como fatores impactantes no desempenho dos modelos. O conjunto de dados utilizado foi coletado do Yahoo Finance, contendo o preço de fechamento das ações IBM, SNOWMAN, HDFC e BHEL, entre 1985 e 2018, totalizando 8.963 amostras, sendo os dados divididos em 80% para treinamento e 20% para teste. O modelo GRU obteve o melhor desempenho, com *RMSE* de 1,85 para a IBM, e média de *RMSE* de 3,19 considerando todas as ações.

No trabalho de [Pan, Tang e Wang \(2024\)](#) é proposto um modelo híbrido denominado MULTI-GARCH-LSTM, que combina modelos GARCH (EGARCH, GJR-GARCH e APARCH) com redes neurais LSTM, visando prever os preços futuros de contratos de ouro na Bolsa de Xangai. O modelo foi avaliado com dados da Shanghai Futures Exchange (SHFE) entre 2013 e 2023, com 2.608 amostras diárias contendo preço de abertura e fecha-

mento, máximo e mínimo, volume e variações no preço. Após a normalização e remoção de valores ausentes, 80% dos dados foram usados para treinamento e 20% para teste. As características de volatilidade extraídas dos modelos GARCH foram incorporadas como entrada na LSTM, permitindo que a rede aprendesse tanto as dependências temporais quanto os padrões de volatilidade. A metodologia proposta pelos autores se sobressaiu com MSE de 19,23, $RMSE$ de 4,38, MAE de 3,65 e $MAPE$ de 0,88%.

A segunda classificação lida com pesquisas que realizaram previsões para criptomoe-das. No trabalho de [Mudassir et al. \(2020\)](#) é investigado a previsão do preço do *Bitcoin* utilizando um conjunto de dados com observações diárias do preço entre 2013 e 2019. Foram utilizados recursos derivados de indicadores técnicos, como SMA, EMA, RSI, STD e VAR, calculados em janelas de 1, 7, 30 e 90 dias, coletados por meio de *web scraping* no site BitInfoCharts. Foram avaliados quatro modelos: ANN, SANN, SVM e LSTM, com o desempenho de regressão medido pelas métricas MAE, RMSE e MAPE. No pré-processamento, dados faltantes foram imputados usando interpolação linear ou valor mais frequente. Outliers foram removidos utilizando o método Isolation Forest, e as variáveis foram escalonadas conforme o modelo utilizado. Nos modelos de NN foram aplicados o *robust scaling* seguido de *minmax scaling*. A dimensionalidade foi tratada por meio da seleção de atributos relevantes. Para a regressão, foram avaliados diferentes horizontes de previsão: fim do dia, 7, 30 e 90 dias. O modelo LSTM obteve um MAPE de 3,61% para o fim do dia, 3,83% para 7 dias e 5,41% para 90 dias.

O estudo de [Agarwal et al. \(2021\)](#) utilizou aprendizado de máquina para prever as tendências de preços de *Bitcoin*, *Ethereum* e *Litecoin*. Algoritmos de regressão como Random Forest Regressor, Gradient Boosting Regressor, Extratrees Regressor, Bayesian Ridge e Elastic Net foram comparados. O conjunto de dados, obtido do Kaggle, possui mais de 200.000 amostras diárias, incluindo atributos como preço de abertura, fechamento, máximos, mínimos e volume de negociação. Após a verificação e remoção de dados ausentes, duplicados e incompletos, os modelos são treinados. A metodologia proposta pelos autores, que comparou diferentes modelos de aprendizado de máquina, mostrou que o Extratrees Regressor obteve o melhor desempenho, com MSE de 1.608.384,06 para *Bitcoin*, 9.051,93 para *Ethereum* e 1.542,22 para *Litecoin*.

O estudo de [Kang, Lee e Lim \(2022\)](#) propôs um modelo híbrido que combina uma Rede Neural Convolutiva Unidimensional (1DCNN) com uma unidade recorrente empilhada de portas (GRU) para prever os preços de criptomoe-das. O modelo foi avaliado com *Bitcoin*, *Ethereum* e *Ripple*, usando dados do Bitstamp e Kaggle. O conjunto de dados do *Bitcoin* contém 4,8 milhões de amostras de preço de fechamento a cada minuto, de 2012 a 2021, enquanto os dados de *Ethereum* e *Ripple* têm 396.403 amostras, referentes ao ano de 2021. Após normalização e limpeza, as séries temporais contendo o preço e data foram usadas para treinamento. O modelo foi treinado com uma semana de dados históricos, divididos em 80% para treinamento e 20% para teste. A metodologia proposta

pelos autores foi comparada aos modelos como ARIMA, RNNs(GRU, LSTM), Facebook Prophet, CNN-LSTM e XGBoost. O modelo proposto obteve os seguintes resultados: RMSE de 43,93 para *Bitcoin*, 3,51 para *Ethereum* e 0,00128 para *Ripple*.

Embora a literatura sobre previsão de ativos financeiros foque em variáveis isoladas, como o preço de fechamento, poucos estudos abordam a previsão simultânea de múltiplas variáveis financeiras. Estudos como os de [Mudassir et al. \(2020\)](#) demonstram a eficácia de modelos como o LSTM na previsão do preço de fechamento do *Bitcoin*, avaliando seu desempenho em diferentes horizontes de tempo. Além disso, trabalhos como os de [Niu et al. \(2020\)](#) e [Pan, Tang e Wang \(2024\)](#) exploram abordagens híbridas, combinando LSTM com outros modelos para melhorar a previsão. Este trabalho avança ao utilizar uma abordagem de janela deslizante como entrada para o modelo LSTM, permitindo a previsão simultânea de diversas variáveis financeiras de escalas semelhantes. O modelo é alimentado com dados dos últimos seis dias, o que visa estabilizar e melhorar a previsão em diferentes momentos do mercado de *Bitcoin*. A inclusão de novos atributos enriquece as informações disponíveis, aprimorando a captura dos padrões e a acuracidade das previsões.

Com base nos trabalhos relacionados, observa-se que a previsão de ativos financeiros, especialmente criptomoedas, tem como foco a previsão do preço de fechamento. É comum comparar desempenhos entre modelos de aprendizado de máquina ou usar abordagens híbridas, combinando modelos estatísticos com algoritmos de aprendizado de máquina ou a combinação de modelos de aprendizado de máquina distintos. Este trabalho se diferencia ao prever simultaneamente cinco variáveis monetárias: preço de fechamento, abertura, alta do dia, baixa do dia e preço médio, oferecendo mais informações para a decisão dos investidores. Além disso, usa-se uma janela com dados de seis dias no treinamento, visando maior estabilidade nas previsões. Por fim, avalia-se o desempenho do modelo com dados não utilizados no treinamento.

Na Tabela 1 são apresentadas as contribuições de trabalhos relacionados a este estudo. Os trabalhos foram selecionados com base em cinco critérios: ativos financeiros, variável alvo, atributos previstos, modelos de previsão e resultados. A coluna 'Variável alvo' lista os ativos financeiros previstos em cada trabalho, destacando em negrito o ativo com a melhor previsão de acordo com os resultados. Em 'Atributos previstos', são apresentadas as variáveis dos ativos financeiros utilizadas para treinar os modelos de previsão. Na coluna 'Resultados', são apresentados os valores das métricas de avaliação utilizadas em cada estudo, referentes ao ativo que obteve o melhor desempenho.

Tabela 1 – Trabalhos relacionados.

Trabalho	Ativos financeiros	Variável alvo	Atributos previstos	Modelos de previsão	Resultados
(MUDASSIR et al., 2020)	Criptomoedas	<i>Bitcoin</i>	Preço de fechamento	LSTM	MAE de 22,05, RMSE de 36,12 e MAPE de 3,83%
(NIU et al., 2020)	Ações	SZCI, SZFI, DJIA	Preço de abertura, fechamento, máximo, mínimo	Modelo Proposto(LSTM + GRU + LSTM convolucional)	MAE de 3,24, RMSE de 5,78 e MAPE de 2,66%
(AGARWAL et al., 2021)	Criptomoedas	<i>Bitcoin</i> , <i>Ethereum</i> e <i>Litecoin</i>	Preço, Capitalização de Mercado, Participação de Mercado	Extratrees Regressor	MSE de 1.542,22 para <i>Litecoin</i> .
(KANG; LEE; LIM, 2022)	Criptomoedas	<i>Bitcoin</i> , <i>Ethereum</i> e <i>Ripple</i>	Preço de fechamento	Modelo proposto(1DCNN + GRU)	RMSE de 0,00128 para <i>Ripple</i>
(PIRANI et al., 2022)	Ações	IBM , SNOWMAN , HDFC , BHEL	Preço de fechamento	GRU	RMSE de 1,85
(PAN; TANG; WANG, 2024)	Ações	Contratos futuros de ouro	Preço de abertura, fechamento, máximo, mínimo	Modelo proposto(MULTI-GARCH-LSTM)	MSE de 19,23, RMSE de 4,38; MAE de 3,65 e MAPE de 0,88%
Este trabalho	Criptomoedas	<i>Bitcoin</i>	Preço de Fechamento, abertura, máximo, mínimo, médio	LSTM	MAE de 1,927, MSE de 7,828, RMSE de 2,798, MAPE de 2,16%

4 Metodologia

O desenvolvimento deste trabalho seguiu seis etapas principais: coleta e descrição da base de dados (Seção 4.1), tratamento e transformação dos dados (Seção 4.2), análise exploratória das variáveis (Seção 4.3), estruturação da nova base no formato janela deslizante (Seção 4.4), divisão dos dados e normalização (Seção 4.5), e modelagem preditiva com LSTM e validação autorregressiva iterativa (Seção 4.6). Nas seções seguintes será apresentado como ocorreu a execução de cada uma dessas etapas. A Figura 4 apresenta um fluxograma que representa as etapas do processo descrito.

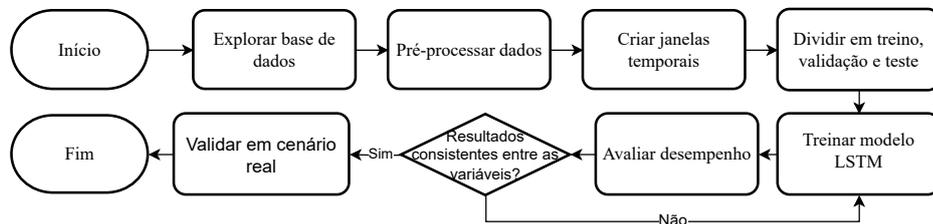


Figura 4 – Fluxograma das etapas do trabalho.

4.1 Descrição da Base de Dados

Para este trabalho, a base de dados foi obtida na plataforma *Investing*, uma plataforma utilizada por investidores e analistas, que disponibiliza informações financeiras como cotações históricas de ações, criptomoedas, índices e moedas de diversos mercados globais. A base de dados conta com informações do BTC em cotações registradas em dólar dos Estados Unidos da América (USD, *United States Dollar*), devido à maior liquidez e volume de transações nessa moeda. Esta série temporal contempla em ordem cronológica o período de 1º de janeiro de 2021 a 7 de abril de 2025, totalizando 1558 amostras para análise preditiva. Inicialmente a base de dados possui sete colunas principais. A Tabela 2 descreve os atributos presentes na base de dados original. Por sua vez, a Tabela 3 apresenta as cinco primeiras amostras coletadas.

Tabela 2 – Descrição das colunas da base de dados original.

Coluna	Descrição	Unidade/Formato
<i>Date</i>	Data da observação	mm/dd/yyyy
<i>Price</i>	Preço de fechamento do <i>Bitcoin</i> ao final do dia.	USD
<i>Open</i>	Preço de abertura do <i>Bitcoin</i> no início do dia.	USD
<i>High</i>	Maior preço registrado durante o dia.	USD
<i>Low</i>	Menor preço registrado durante o dia.	USD
<i>Vol.</i>	Volume total de negociação em USD no período.	Inteiro
<i>Change %</i>	Variação percentual do preço em relação ao dia anterior.	%

Tabela 3 – Amostras iniciais da base de dados.

Date	Price	Open	High	Low	Vol.	Change %
04/07/2025	79,162.5	78,406.6	81,095.9	74,524.2	170.57K	0.98%
04/06/2025	78,391.3	83,528.0	83,731.7	77,171.1	79.17K	-6.18%
04/05/2025	83,552.1	83,876.0	84,249.3	82,384.4	32.71K	-0.38%
04/04/2025	83,866.7	83,160.2	84,704.1	81,691.1	91.54K	0.85%
04/03/2025	83,159.4	82,522.6	83,908.9	81,313.8	83.15K	0.77%

4.2 Pré-processamento dos Dados

A etapa de pré-processamento foi realizada visando padronizar os formatos, corrigir inconsistências e enriquecer os atributos disponíveis para as etapas posteriores de análise e previsão. Inicialmente, a coluna *Date* foi convertida para o formato padrão de datas do Python, permitindo a correta manipulação temporal dos dados. Em seguida, as amostras foram reorganizadas em ordem crescente de data; essa ordenação é essencial, uma vez que modelos de séries temporais dependem da sequência cronológica dos dados para aprender padrões históricos e estimar valores futuros.

Em continuidade, os nomes das colunas foram renomeados para o português, com o intuito de facilitar a leitura e uniformizar a terminologia ao longo do trabalho. As alterações foram: *Date* para Data, *Price* para Fechamento, *Open* para Abertura, *High* para Alta do dia, *Low* para Baixa do dia, *Vol.* para Volume e *Change %* para Variação (%). As colunas monetárias: Fechamento, Abertura, Alta do dia e Baixa do dia foram convertidas de cadeias de caracteres para valores numéricos reais, substituindo os separadores de milhar e vírgulas decimais pelo padrão computacional.

A coluna Volume apresentava os sufixos 'K', 'M' e 'B', correspondentes a mil, milhão e bilhão, respectivamente. Para permitir seu uso quantitativo, os valores foram padronizados para a escala numérica por meio de multiplicadores específicos. Por fim, a coluna Variação (%) também foi convertida para o tipo numérico. Todas essas transformações visaram garantir a consistência dos dados antes da etapa de modelagem. As estatísticas descritivas das variáveis numéricas da base são apresentadas na Tabela 4. Esses valores fornecem uma

visão geral do comportamento do ativo ao longo do período, permitindo uma análise inicial sobre variações de preço, amplitude diária e volume de negociação.

Tabela 4 – Estatísticas descritivas das variáveis numéricas.

Estatística	Fechamento	Abertura	Alta do dia	Baixa do dia	Volume	Variação (%)
Média	45.731	45.699	46.710	44.623	38.942.490	0,11
Mínimo	15.776	15.777	16.275	15.504	260	-15,63
1º Quartil	27.913	27.913	28.358	27.263	54.122	-1,37
Mediana	41.757	41.722	42.682	40.740	84.765	-0,01
3º Quartil	60.395	60.373	61.543	59.015	156.887	1,56
Máximo	106.157	106.157	109.229	105.351	4.470.000.000	19,41
Desvio Padrão	21.948	21.936	22.368	21.469	275.647.200	3,22

Além das colunas originais, foram criados novos atributos derivados para enriquecer a base de dados, trazendo informações detalhadas sobre a variação diária dos preços do *Bitcoin*. Os atributos adicionados foram: o Preço Médio, que representa a média aritmética entre os preços de abertura e fechamento, fornecendo uma estimativa centralizada do valor do ativo ao longo do dia; e as variações percentuais: Variação Baixa-Alta (%), Variação Baixa-Média (%) e Variação Média-Alta (%), calculadas com base nos preços mínimo, médio e máximo, para capturar a amplitude e a dinâmica das oscilações diárias.

Esses novos atributos foram incorporados visando auxiliar o modelo a compreender melhor as variações diárias, complementando as informações fornecidas nas colunas monetárias originais. Com a inclusão dessas variáveis, a base de dados passou a contar com 11 atributos no total. As colunas monetárias: Fechamento, Abertura, Alta do dia, Baixa do dia e Preço Médio são expressas em valores numéricos reais, com os números referentes aos centavos de dólar sendo removida, mantendo os valores arredondados às centenas e milhares. Já os atributos de variação percentual foram elaborados para capturar a dinâmica das oscilações internas ao longo de cada sessão de negociação. A Tabela 5 apresenta a descrição de cada um desses atributos, bem como suas respectivas unidades de medida.

Tabela 5 – Descrição dos novos atributos da base de dados.

Coluna	Descrição	Unidade
Preço Médio	Média aritmética entre os preços de abertura e fechamento do dia, representando uma estimativa centralizada do preço no período.	USD
Variação Baixa-Alta (%)	Variação percentual entre o preço mínimo e o preço máximo do dia, indicando a amplitude total da oscilação diária.	%
Variação Baixa-Média (%)	Variação percentual entre o preço mínimo e o preço médio do dia, indicando a oscilação na primeira metade da faixa de preço.	%
Variação Média-Alta (%)	Variação percentual entre o preço médio e o preço máximo do dia, indicando a oscilação na segunda metade da faixa de preço.	%

4.3 Análise Exploratória dos Dados

Nesta etapa foi realizada uma análise da distribuição da variável principal da base de dados, o preço de fechamento do *Bitcoin*. Para isso, utilizou-se o gráfico Quantile-Quantile (Q-Q), que compara os quantis dos dados observados com os quantis esperados de uma distribuição normal teórica. O objetivo dessa análise é verificar se os dados seguem ou se aproximam de uma distribuição normal, o que pode influenciar na escolha e no desempenho dos modelos. A Figura 5 apresenta o gráfico Q-Q da distribuição do preço de fechamento.

Os pontos do gráfico Q-Q apresentaram desvios significativos da linha reta de referência, principalmente nas extremidades, evidenciando a presença de caudas pesadas e uma distribuição assimétrica. O que indica que os dados do preço de fechamento do *Bitcoin* não seguem uma distribuição normal, refletindo a volatilidade e a ocorrência de eventos extremos característicos do mercado de criptomoedas. A ausência de normalidade implica na necessidade de técnicas para lidar com dados assimétricos e com *outliers*.

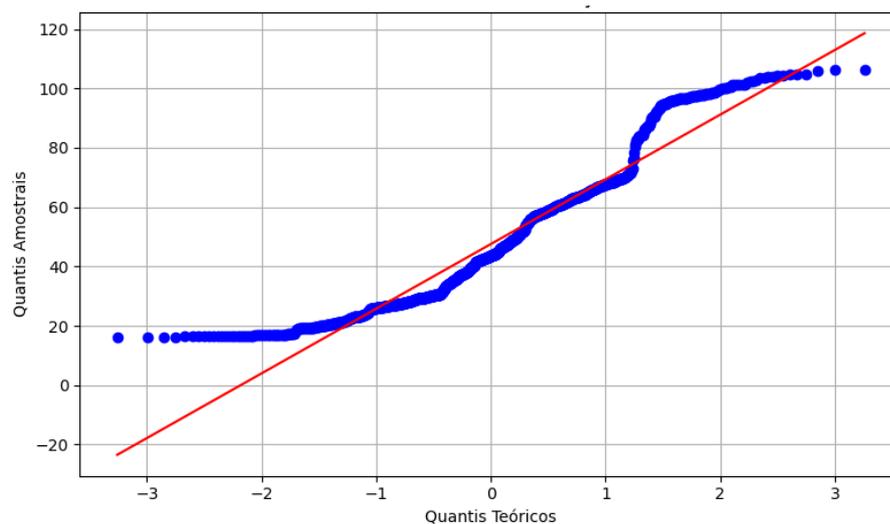


Figura 5 – Probabilidade Quantílica (Q-Q) do Preço de Fechamento.

Valores extremos e atípicos podem gerar ruídos que prejudicam a aprendizagem dos padrões subjacentes, levando a uma piora na capacidade de generalização do modelo. O preço do *Bitcoin* é altamente volátil e, portanto, está sujeito a flutuações bruscas, que podem resultar em observações fora do padrão esperado. Por isso, a aplicação de métodos para identificação e tratamento desses *outliers* é realizada para melhorar a qualidade dos dados utilizados e, conseqüentemente, a precisão das previsões.

Para esse fim, foi utilizado o método do intervalo interquartil (IQR, *InterQuartile Range*) para identificar e remover os *outliers* encontrados em todas as variáveis da base de dados. O IQR é uma medida estatística que representa a amplitude entre o primeiro quartil (Q_1 , 25% dos dados abaixo) e o terceiro quartil (Q_3 , 75% dos dados abaixo), ou seja, $IQR = Q_3 - Q_1$. A partir dessa medida, são definidos os limites inferior e superior para os

dados aceitáveis, que correspondem a $Q_1 - 1,5 \times IQR$ e $Q_3 + 1,5 \times IQR$, respectivamente. Valores que estiverem fora desse intervalo são considerados *outliers* por estarem muito distantes da distribuição central dos dados. O uso desse método é vantajoso por ser simples, não exigir suposições paramétricas rígidas e ser aplicável a variáveis com diferentes distribuições. Ao aplicar o método IQR para todos os atributos, a base de dados foi reduzida em 312 amostras, contando com um total de 1246 amostras, preservando a integridade da série temporal.

Os gráficos apresentados na Figura 6 ilustram a distribuição do atributo Fechamento antes (Gráfico 6a) e após (Gráfico 6b) a aplicação do método de remoção de *outliers* pelo intervalo interquartil (IQR). Esses histogramas, acompanhados de curvas de densidade, evidenciam visualmente o efeito da filtragem estatística, mostrando a redução dos valores extremos e uma concentração maior dos dados na faixa central. Essa etapa de pré-processamento é fundamental para garantir a qualidade dos dados que serão utilizados no treinamento do modelo preditivo.

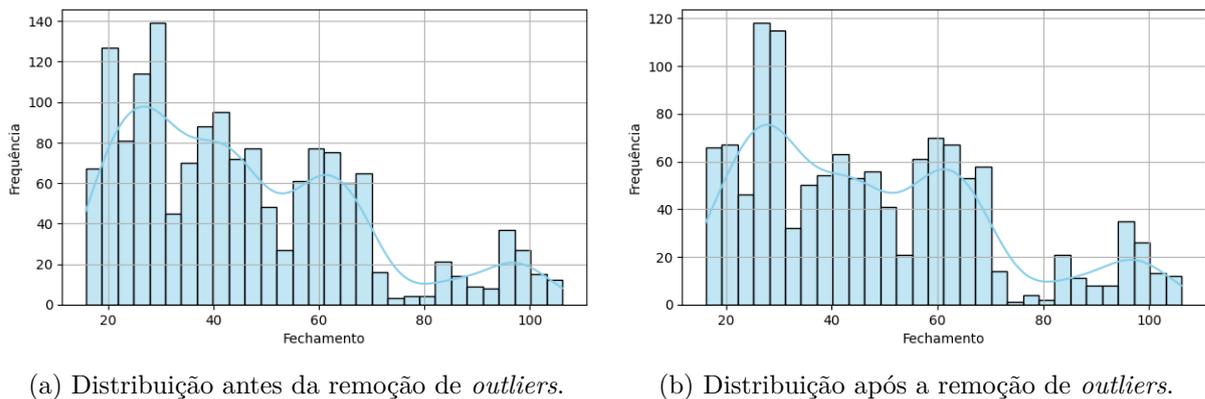


Figura 6 – Comparação da distribuição do atributo Fechamento antes e depois da aplicação do método IQR.

4.4 Transformação dos Dados

Antes da criação dessas janelas temporais, reservou-se as últimas sete amostras da base de dados (correspondentes aos dias 31 de março, 1, 2, 3, 4, 5 e 7 de abril de 2025) para compor o conjunto de validação em cenário real, utilizado para a validação iterativa do modelo após o treinamento. Para estruturar a base de dados adequadamente ao treinamento do modelo de aprendizado de máquina, adotou-se o formato de janela deslizante, no qual os atributos referentes a seis dias consecutivos são achatados em um vetor unidimensional utilizado para prever os valores do sétimo dia, identificado como *target*. A lista de colunas utilizadas corresponde a todos os atributos do conjunto, exceto a coluna de data, excluída da modelagem. Os atributos receberam nomes padronizados, indicando o dia da janela (de 1 a 6) e o nome do atributo, para manter a rastreabilidade e facilitar a interpretação dos dados.

Após criar a primeira amostra, a janela se desloca um dia à frente: o segundo dia passa a ser o primeiro da nova janela, os dias seguintes são incluídos sequencialmente, e o dia previamente previsto torna-se o sexto dia da nova janela. Dessa forma, é criada uma série de janelas temporais que avançam ao longo da base de dados, preservando a sequência cronológica. Devido a essa estrutura, as primeiras seis amostras da base original não são utilizadas no treinamento, pois não há dados suficientes anteriores para formar as janelas completas necessárias para a previsão. A base de dados produzida possui, portanto, um total de 1234 amostras para o treinamento do modelo contendo 70 atributos, 60 correspondem aos atributos dos seis dias que compõem a janela (10 atributos por dia) e os últimos 10 são referentes ao *target*.

4.5 Divisão dos Dados em Conjuntos

Antes de realizar a divisão da base de dados, os atributos a serem utilizados como entrada e as variáveis a serem previstas são separadas. Os atributos de entrada correspondem aos dados dos seis dias consecutivos que compõem cada janela, enquanto as variáveis previstas são os valores associados ao sétimo dia. A base de dados no formato de janelas deslizantes foi dividida em conjuntos para treinamento, validação e teste, respeitando a ordem cronológica.

Essa divisão foi realizada respeitando a sequência temporal dos dados, evitando o embaralhamento, para preservar a ordem cronológica fundamental em séries temporais. Inicialmente, 70% das amostras foram destinadas ao conjunto de treinamento, enquanto os 30% restantes foram reservados para validação e teste. Posteriormente, essa parcela de 30% foi dividida igualmente entre os conjuntos de validação e teste, correspondendo a 15% para cada um. Ao final da divisão, o conjunto de treinamento contava com 863 amostras, enquanto o conjunto de validação e teste possuíam 186 e 185 amostras respectivamente.

Em sequência, os dados são normalizados pelo método Min-Max, que escala os valores para o intervalo entre zero e um. A normalização foi ajustada exclusivamente no conjunto de treinamento e aplicada, com os mesmos parâmetros, aos conjuntos de validação e teste. Essa prática garante que a avaliação reflita condições reais, preservando a integridade dos dados utilizados na validação e teste, e assegurando uma avaliação confiável da capacidade preditiva do modelo.

4.6 Configuração e Treinamento do Modelo

Para explorar a estrutura temporal dos dados, os conjuntos de entrada foram reorganizados em um formato tridimensional adequado ao modelo LSTM. Nesse formato, cada amostra é composta por uma sequência de seis dias consecutivos, contendo suas respectivas variáveis de entrada. Assim, os dados originalmente estruturados em uma matriz

bidimensional foram transformados para um arranjo com três dimensões: quantidade total de amostras, intervalo de seis dias e número de atributos por dia (dez no total). As variáveis-alvo mantiveram sua estrutura bidimensional. Os experimentos foram realizados em um *notebook* com sistema operacional Windows 10 de 64 bits, processador Intel Core i5-1135G7, 8 gigabytes de memória RAM e placa de vídeo integrada com 128 megabytes de memória.

O modelo LSTM foi construído utilizando a biblioteca Keras, composto por três camadas LSTM empilhadas com 64, 32 e 16 unidades de memória, respectivamente, todas ativadas pela função ReLU. Essa função é utilizada para permitir que a rede adquira flexibilidade para representar comportamentos lineares e não lineares nos dados. Entre as camadas LSTM, foram inseridas camadas de *dropout*, que desativam aleatoriamente uma pequena fração dos neurônios durante o aprendizado, com taxas de 5%, 4% e 3% ao longo das camadas para reduzir o risco de *overfitting*. A camada final é uma camada densa com função de ativação linear, responsável por gerar as múltiplas saídas do modelo para as variáveis-alvo, permitindo realizar a regressão multivariada necessária.

O modelo foi configurado com a função de perda MSE e ajustado com o método de otimização Adam, utilizando uma taxa de aprendizado inicial de 0,0007. Para tornar o treinamento mais eficaz, foram aplicados *callbacks* que monitoram o desempenho do modelo ao longo das iterações. O processo é interrompido automaticamente se não houver melhora na métrica de validação após 10 épocas consecutivas (*EarlyStopping*), evitando o *overfitting*; caso o desempenho pare de evoluir por 5 épocas, a taxa de aprendizado é reduzida pela metade (*ReduceLROnPlateau*), permitindo ajustes mais finos; além disso, a melhor versão do modelo é salva durante todo o processo com base em seu desempenho na validação (*ModelCheckpoint*), garantindo que os melhores resultados sejam preservados. O treinamento foi configurado para até 100 épocas, utilizando subconjuntos de 16 amostras por iteração. Os *callbacks* interromperam o processo automaticamente após 62 épocas, indicando uma convergência antecipada e eficiente. Essa configuração buscou balancear a estabilidade do treinamento com a prevenção de *overfitting*, visando alcançar o melhor desempenho preditivo possível.

5 Resultados

Neste capítulo, será apresentado os resultados detalhados do treinamento do modelo LSTM para a previsão do comportamento do BTC a partir previsão das variáveis monetárias de Fechamento, Abertura, Alta do dia, Baixa do Dia e Preço Médio. A análise será pautada nas métricas de desempenho discutidas na Seção 2, que foram utilizadas para avaliar a precisão do modelo nas previsões realizadas com a base de dados estruturada em janelas deslizantes de seis dias.

5.1 Previsões das Variáveis Monetárias

Acompanhando o processo de treinamento, é possível analisar como o modelo evoluiu ao longo das épocas e verificar a estabilidade do aprendizado. A Figura 7 apresenta a evolução da função de perda nos conjuntos de treinamento e validação. Observa-se que a perda, em ambos os conjuntos, diminuiu rapidamente nas primeiras épocas, estabilizando-se em níveis baixos a partir da metade do processo. A proximidade entre as curvas sugere que o modelo não apresentou sinais de *overfitting* nem de *underfitting*, demonstrando boa capacidade de generalização para novos dados.

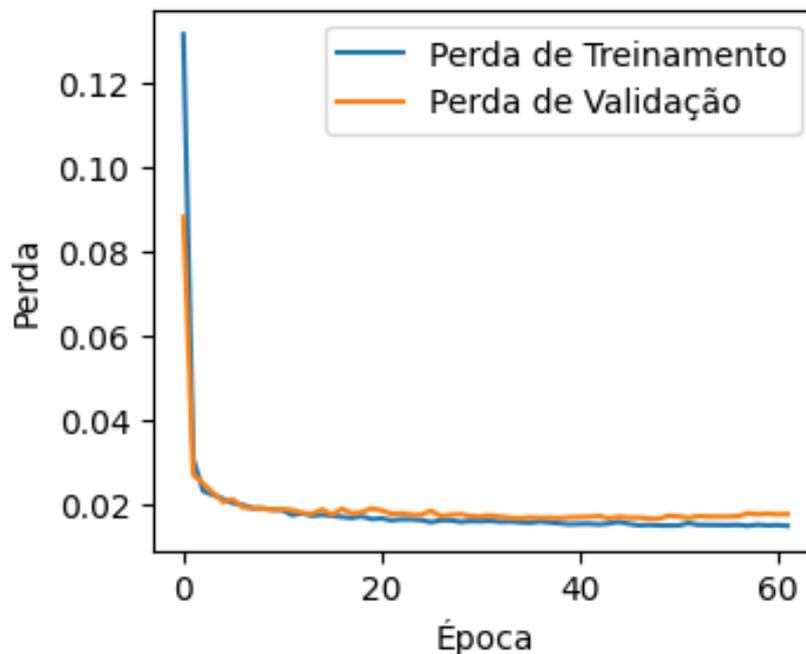


Figura 7 – Curva de aprendizado do modelo durante o treinamento.

Os valores consolidados das métricas calculadas para cada variável revelam um desempenho consistente do modelo LSTM na previsão das variáveis selecionadas. Todas

as previsões resultaram em coeficientes de determinação (R^2) superiores a 0.94, acompanhados por erros absolutos e percentuais relativamente baixos, evidenciando uma boa capacidade de generalização. A variável Alta do Dia obteve os melhores resultados nas principais métricas de erro, indicando maior precisão do modelo ao antecipar os valores máximos do dia. Já as previsões para Abertura e Baixa do Dia apresentaram os maiores valores de MAE e $RMSE$, sugerindo maior dificuldade na modelagem dos comportamentos para essas variáveis. As variáveis Fechamento e Preço Médio apresentaram desempenho equilibrado, com baixos valores de $MAPE$ e elevados R^2 , reforçando a estabilidade dessas séries e a capacidade do modelo de acompanhar suas variações com maior fidelidade. A Tabela 6 apresenta os valores para cada métrica calculada para cada variável.

Tabela 6 – Resultados das métricas para cada variável prevista no conjunto de teste.

Métrica	Fechamento	Abertura	Alta do dia	Baixa do dia	Preço Médio
MAE	2,200	2,490	1,927	2,519	2,006
MSE	8,897	11,306	7,828	10,441	8,091
RMSE	2,982	3,362	2,798	3,231	2,844
MAPE (%)	2,54	2,70	2,16	2,88	2,25
R²	0,957	0,946	0,964	0,947	0,961

A Figura 8 apresenta a comparação entre os valores reais e os valores previstos pelo modelo LSTM para a variável de Fechamento ao longo do conjunto de teste. Observa-se uma forte correlação visual entre as curvas, com o modelo conseguindo capturar em diversos momentos a tendência geral dos dados e também as oscilações de curto prazo. Durante o período inicial, o modelo acompanha consistentemente o comportamento ascendente da série, com os valores previstos praticamente sobrepostos aos valores reais.

Essa proximidade entre as curvas se mantém ao longo de grande parte do período, inclusive no intervalo de maior variação, entre as amostras 50 e 75, no qual ocorre uma elevação acentuada, seguida por uma sequência de correções. O modelo demonstrou capacidade satisfatória de identificar essas transições, mesmo diante de oscilações expressivas. Apesar do bom desempenho geral, é possível observar pequenas divergências pontuais nos momentos de inflexão mais abruptos, em que o modelo apresenta certo atraso na captura das mudanças de direção. Tais desvios são esperados, sobretudo no contexto de ativos com alta volatilidade, como o BTC e outras criptomoedas. Ainda assim, essas discrepâncias não comprometem significativamente a qualidade das previsões, como evidenciado pelas métricas quantitativas discutidas anteriormente.

Na Figura 9, são apresentados os valores previstos da variável Abertura pelo modelo LSTM no conjunto de teste. De maneira geral, observa-se que o modelo conseguiu acompanhar razoavelmente bem o comportamento da série temporal, especialmente nos períodos de tendência mais suave ou contínua. No intervalo entre as amostras 50 e 75, o modelo demonstra certa lentidão em capturar a forte valorização do ativo, apresentando uma defasagem visível em sua resposta. Além disso, na sequência de correções que se segue

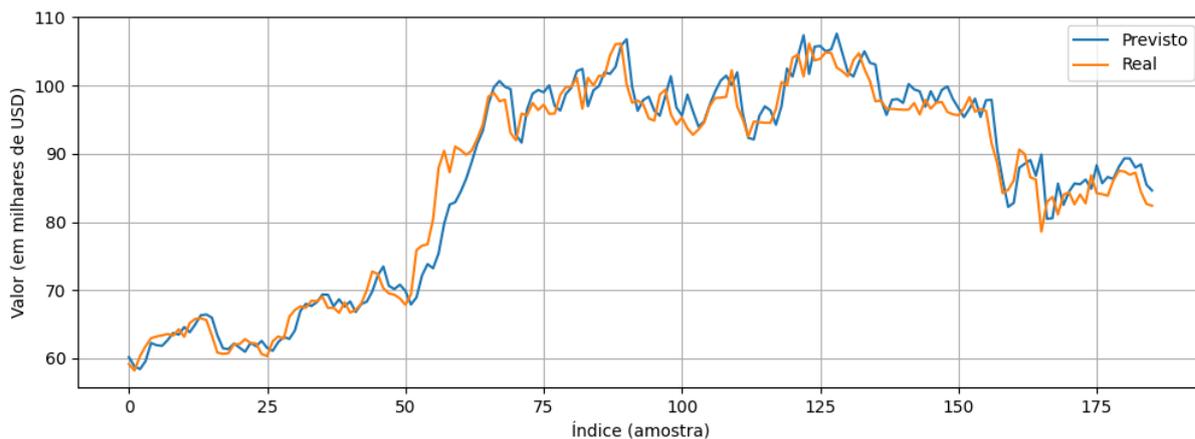


Figura 8 – Valores reais vs. previstos da variável Fechamento no conjunto de teste.

à alta, os valores previstos tendem a subestimar os valores reais, indicando uma dificuldade do modelo em reagir de forma ágil às mudanças de direção. Após esse período de maior oscilação, a partir da amostra 150, o modelo volta a apresentar maior precisão, com diferenças menos expressivas entre os valores previstos e os reais para a variável Abertura.

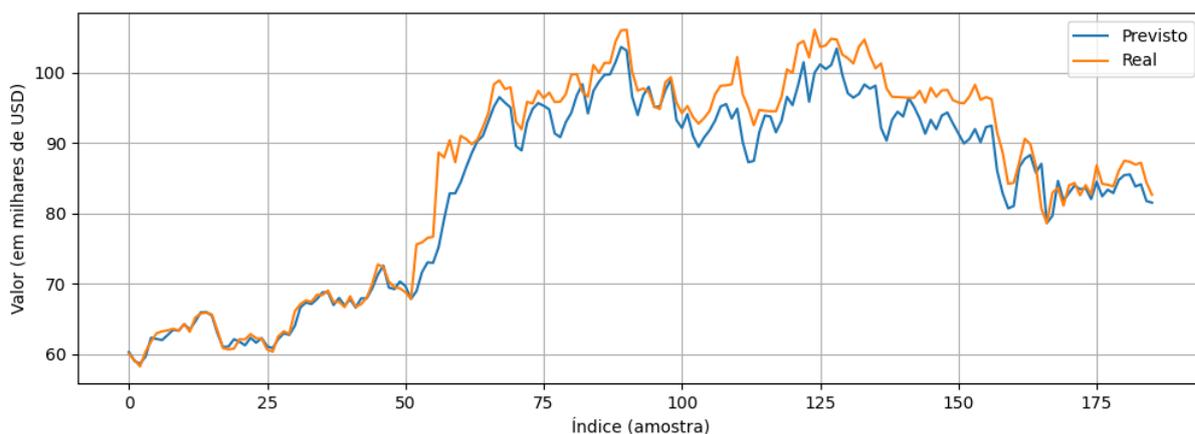


Figura 9 – Valores reais vs. previstos da variável Abertura no conjunto de teste.

Na Figura 10, é apresentada a comparação entre os valores reais e os valores previstos para a variável Alta do Dia no conjunto de teste. De modo geral, o modelo LSTM demonstrou bom desempenho, acompanhando com fidelidade a tendência da série temporal e conseguindo representar com consistência os picos de preço ao longo das amostras. Observa-se que o modelo respondeu bem às variações ascendentes, especialmente após a amostra 75, período em que o valor do BTC atinge sua fase de maior oscilação e valor no conjunto de teste. A partir desse ponto, as previsões se mantêm próximas aos valores reais e apresentam pequenos desvios positivos e negativos, que não comprometem a interpretação da tendência. Para essa variável, o modelo foi eficaz em se aproximar dos valores crescentes da Alta do Dia. Contudo, dificuldades em capturar com precisão os períodos de queda são perceptíveis, principalmente após a amostra 150, quando ocorre uma queda acentuada nos valores reais. Nesse trecho, o modelo tende a superdimensionar a magni-

tude da queda e apresenta certa lentidão para se ajustar ao comportamento oscilante que se segue.

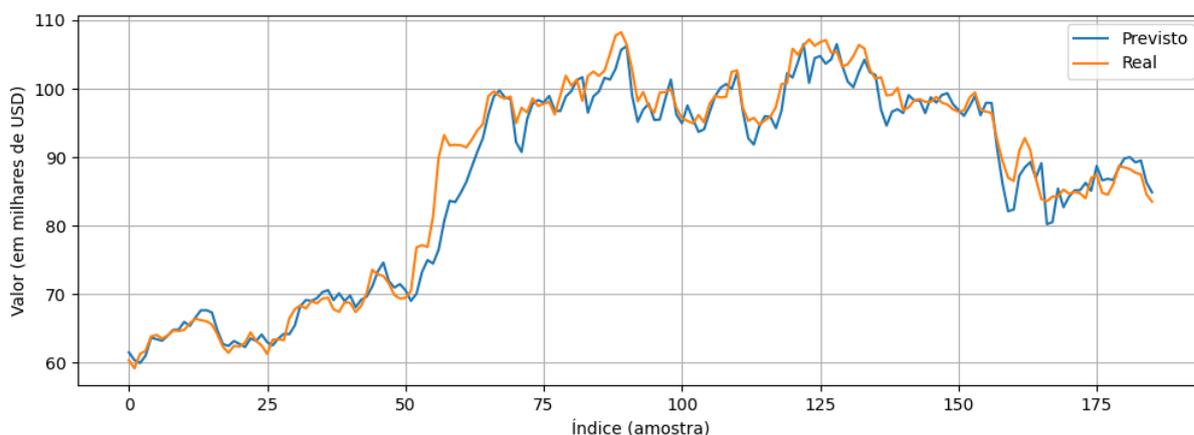


Figura 10 – Valores reais vs. previstos da variável Alta do dia no conjunto de teste.

A Figura 11 apresenta a comparação entre os valores reais e os valores previstos para a variável Baixa do Dia no conjunto de teste. De maneira geral, o modelo LSTM conseguiu acompanhar a tendência geral da série, com destaque para as regiões inicial e final, mas apresentou maiores dificuldades em prever com precisão os pontos mínimos, sobretudo nos momentos de reversão acentuada do mercado. Após o período de forte valorização, entre as amostras 50 e 75, o modelo seguiu o movimento ascendente da curva com relativa precisão, embora tenha subestimado os valores reais em diversos momentos. Quando os valores reais passam a oscilar de forma mais abrupta, principalmente em tendência de queda, as previsões começam a divergir com maior frequência, evidenciando uma sensibilidade limitada do modelo às variações negativas mais intensas.

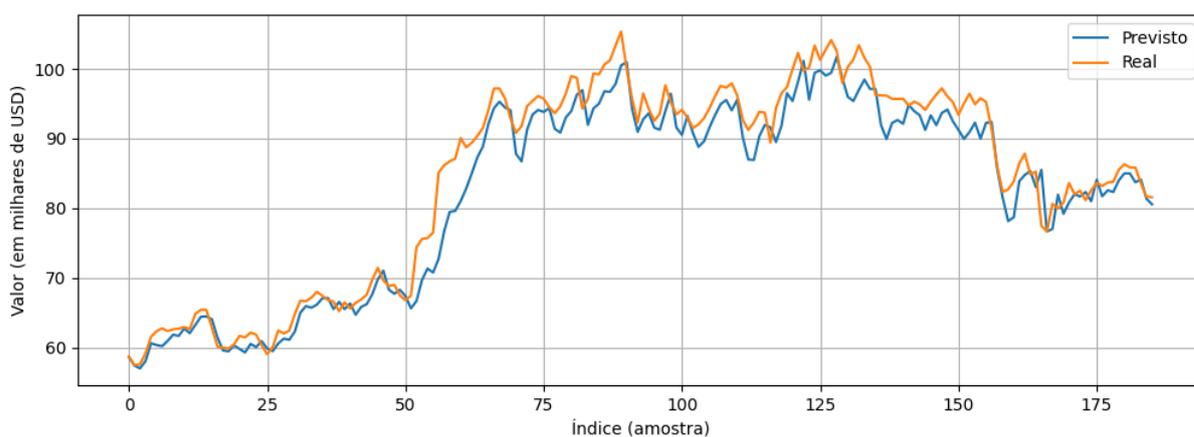


Figura 11 – Valores reais vs. previstos da variável Baixa do dia no conjunto de teste.

Na Figura 12, é apresentada a comparação entre os valores reais e os valores previstos pelo modelo LSTM para a variável Preço Médio no conjunto de teste. Observa-se que o modelo conseguiu acompanhar com boa precisão a tendência geral da série, mantendo-se próximo aos valores reais durante quase todo o período analisado. O modelo demonstrou

desempenho satisfatório ao captar tanto a aceleração nos movimentos de alta quanto as fases de queda, ainda que com tendência à subestimação em diversos pontos. Em trechos posteriores, nos quais os valores do Preço Médio passam a oscilar de forma mais intensa, as previsões mantêm uma proximidade razoável com os dados reais, inclusive durante momentos de correção. Um comportamento específico é observado entre as amostras 125 e 150, quando o mercado entra em um período de lateralização com leve tendência de baixa. Nesse intervalo, os valores reais seguem uma trajetória relativamente estável, com variações suaves e bem distribuídas. No entanto, o modelo LSTM apresenta previsões com maior instabilidade, oscilando além do comportamento esperado. Esse padrão indica uma super-resposta do modelo às pequenas variações nos dados, sugerindo uma sensibilidade excessiva frente a micro flutuações, mesmo em um cenário de estabilidade relativa.

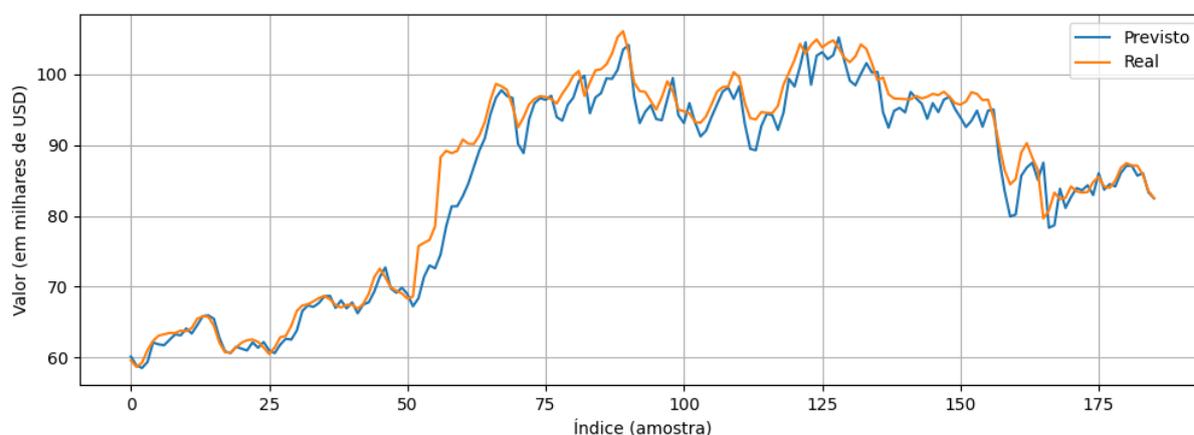


Figura 12 – Valores reais vs. previstos da variável Preço Médio no conjunto de teste.

Para sintetizar o comportamento do modelo em relação à precisão de suas previsões, a Tabela 7 apresenta a média e o desvio padrão dos erros obtidos para cada variável prevista. O erro, neste contexto, refere-se à diferença entre os valores reais e os valores previstos. Ambos os valores, média e desvio padrão, são expressos em dólar americano (USD). A variável Fechamento foi a única a apresentar erro médio negativo, indicando leve tendência de superestimação dos valores reais. No entanto, seu desvio padrão foi o mais elevado entre todas as variáveis, sugerindo maior dispersão nos erros mesmo com média próxima de zero. Por outro lado, a variável Abertura apresentou o maior erro médio absoluto (2.276), revelando um viés mais acentuado de subestimação por parte do modelo. As variáveis de Alta do Dia e Baixa do Dia mostraram desempenhos similares, com erros médios próximos de 1.0000 e 2.000 USD, respectivamente, e desvios padrão em torno de 2.4–2.6, indicando relativa estabilidade para a Baixa do dia, mas maior instabilidade para a Alta do dia. Já o Preço Médio apresentou os menores valores de dispersão entre os erros, demonstrando não somente precisão, mas também regularidade nas previsões. Em conjunto, esses resultados reforçam os padrões observados nos gráficos.

Tabela 7 – Erro médio e desvio padrão por variável prevista no conjunto de teste.

Variável	Média do Erro	Desvio Padrão do Erro
Fechamento	-0.308	2.975
Abertura	2.276	2.481
Alta do Dia	0.988	2.624
Baixa do Dia	2.152	2.416
Preço Médio	1.610	2.351

5.2 Validação Autorregressiva Iterativa

Para avaliar a capacidade preditiva do modelo com dados não vistos durante o treinamento, validação e teste, realizou-se uma validação em cenário real por meio de uma abordagem autorregressiva iterativa. Esse tipo de validação simula a aplicação prática do modelo, em que previsões são feitas sequencialmente com base nos dados reais disponíveis até o momento da previsão. A Tabela 8 apresenta as últimas amostras da base de dados, que não foram utilizadas no processo de treinamento do modelo. Cada linha desta tabela corresponde a um dia a ser previsto nesta etapa de validação, contendo todos os atributos originais e derivados previamente verificados pelo método IQR. Ressalta-se que o dia 06/04 foi excluído por esse critério, não sendo incluído nesta etapa. Essa metodologia de validação permite avaliar se o modelo mantém sua capacidade preditiva diante de novos dados, preservando estabilidade e coerência ao longo de várias iterações. Além disso, aproxima o processo de validação de um contexto real de uso, no qual o modelo é utilizado continuamente com dados atualizados à medida que se tornam disponíveis.

Tabela 8 – Amostras finais utilizadas na validação autorregressiva iterativa.

Data	Fechamento	Abertura	Alta do dia	Baixa do dia	Volume	Variação (%)	Preço Médio	Variação Baixa-Alta (%)	Variação Baixa-Média (%)	Variação Média-Alta (%)
2025-03-31	82.549	82.375	83.896	81.300	61.760	0,22	82.462	3,19	1,43	1,74
2025-04-01	85.164	82.549	85.506	82.436	66.720	3,17	83.857	3,72	1,73	1,96
2025-04-02	82.525	85.166	88.377	82.359	104.050	-3,10	83.846	7,31	1,81	5,40
2025-04-03	83.159	82.523	83.909	81.314	83.150	0,77	82.841	3,19	1,88	1,29
2025-04-04	83.867	83.160	84.704	81.691	91.540	0,85	83.514	3,69	2,23	1,43
2025-04-05	83.552	83.876	84.249	82.384	32.710	-0,38	83.714	2,26	1,61	0,64
2025-04-07	79.162	78.407	81.096	74.524	170.570	0,98	78.785	8,82	5,71	2,94

A análise das métricas apresentadas na Tabela 9 permite avaliar o comportamento do modelo diante de dados não vistos anteriormente. O modelo demonstrou boa capacidade de generalização para séries temporais mais estáveis, como Abertura e Preço Médio, que apresentaram os menores erros ($MAE < 1,5$ e $MAPE < 2\%$). Esses resultados indicam que o modelo conseguiu compreender padrões regulares e previsíveis nessas variáveis. Em contraste, a variável Fechamento representou o maior desafio preditivo, registrando os erros mais elevados em todas as métricas ($MAE = 2,695$; $MSE = 12,048$). Além disso, o modelo manteve a tendência de superestimar seus valores e apresentou lentidão na identificação de mudanças rápidas de direção.

A variável Baixa do Dia, embora tenha apresentado um erro percentual moderado ($MAPE = 2,40\%$), obteve um RMSE de 3,023 consideravelmente maior que o registrado

por outras variáveis com desempenho semelhante. Esse resultado aponta para a ocorrência de erros de maior magnitude, ainda que menos frequentes, provavelmente associados a momentos de forte correção ou reversões abruptas que o modelo teve maior dificuldade em antecipar. Cabe ressaltar que a métrica R^2 não foi considerada nesta etapa, pois sua aplicação foi somente no processo de treinamento, para verificar se o modelo estava conseguindo compreender os padrões das variáveis previstas. Na fase de validação, o foco recai sobre a avaliação direta dos erros de previsão.

Tabela 9 – Métricas de desempenho na validação autorregressiva iterativa.

Métrica	Fechamento	Abertura	Alta do Dia	Baixa do Dia	Preço Médio
MAE	2,695	1,466	1,576	1,857	1,451
MSE	12,048	3,698	4,393	9,139	4,431
RMSE	3,471	1,923	2,096	3,023	2,105
MAPE (%)	3,30	1,81	1,89	2,40	1,79

A Tabela 10 apresenta os valores previstos para cada variável monetária nesta validação. De forma geral, as previsões se mantiveram próximas dos valores reais na maior parte do período. As variáveis Abertura, Alta do Dia e Preço Médio obtiveram os melhores resultados, com erros percentuais frequentemente abaixo de 2%, reforçando a precisão e estabilidade das previsões. Em contraste, a variável Fechamento apresentou maior discrepância entre os valores previstos e observados, refletindo os maiores erros identificados nas métricas, sendo a única variável a ultrapassar 3% do MAPE. A média do MAPE ficou próxima de 2%, reforçando a eficácia do modelo ao lidar com dados não vistos.

Tabela 10 – Valores previstos na validação autorregressiva iterativa.

Data	Fechamento	Abertura	Alta do Dia	Baixa do Dia	Preço Médio
2025-03-31	84.667	81.681	85.012	80.723	82.591
2025-04-01	84.440	81.601	84.839	80.571	82.441
2025-04-02	87.033	84.046	87.399	83.031	85.011
2025-04-03	83.154	81.006	83.476	79.352	81.229
2025-04-04	85.411	82.272	85.546	81.442	83.219
2025-04-05	86.671	83.217	86.588	82.590	84.299
2025-04-07	86.010	82.849	85.758	81.991	83.746

5.3 Discussões

A análise dos resultados obtidos com o uso do modelo LSTM para a previsão de variáveis financeiras do *Bitcoin* demonstra a robustez e a viabilidade da metodologia como apoio à tomada de decisões de investimento. Os coeficientes de determinação (R^2) superiores a 0,94 para todas as variáveis previstas: Fechamento, Abertura, Alta do Dia, Baixa do Dia e Preço Médio, evidenciam a boa capacidade de generalização do modelo. Dentre os resultados, destaca-se o desempenho da variável Alta do Dia, que apresentou

os melhores resultados nas métricas de erro, com um MAE de 1,927, RMSE de 2,798 e MAPE de 2,16%. Além disso, a variável Preço Médio demonstrou estabilidade nas previsões e menor dispersão nos erros, com um MAE de 2,006, RMSE de 2,844 e MAPE de 2,25%, reforçando a capacidade do modelo em acompanhar suas variações com maior fidelidade, especialmente em períodos mais estáveis. A inclusão de atributos derivados, como as variações percentuais entre preços mínimo, médio e máximo, aliada ao uso de janelas deslizantes de seis dias, contribuiu significativamente para enriquecer a base de dados e aprimorar a capacidade preditiva da rede.

A principal diferença deste estudo em relação aos trabalhos da literatura está na previsão simultânea múltiplas variáveis monetárias, ampliando o suporte informacional ao investidor. A maioria dos estudos analisados concentrou-se exclusivamente na previsão do preço de fechamento. Mesmo quando comparado diretamente, o modelo proposto obteve valores nas métricas de erro menores que abordagens anteriores. Para a variável Fechamento, foram obtidos MAE de 2,200, RMSE de 2,982 e MAPE de 2,54%, valores inferiores aos de [Mudassir et al. \(2020\)](#), que reportou MAE de 22,05, RMSE de 36,12 e MAPE de 3,83%. Além disso, a validação autorregressiva iterativa, ausente nos trabalhos comparados, reforçou a eficácia do modelo ao lidar com dados não vistos durante o processo de treinamento, validação e teste, mantendo MAPE médio aproximadamente de 2,24%.

Apesar dos bons resultados, algumas limitações foram observadas. O modelo demonstrou dificuldade em capturar mudanças bruscas de direção, especialmente em momentos de alta oscilação. Tal comportamento afetou todas as variáveis previstas, evidenciando resposta tardia frente a mudanças bruscas de tendência, levando a erros localizados de superestimação ou subestimação. No caso do Preço Médio, em períodos de lateralização com leve tendência de queda, observou-se sensibilidade excessiva a pequenas oscilações, gerando variações mais acentuadas que as observadas nos dados reais.

6 Conclusão

Neste trabalho, foi analisada a capacidade preditiva do modelo LSTM quando aplicado a séries temporais financeiras da criptomoeda *Bitcoin*. A proposta teve como objetivo explorar o potencial dos algoritmos de aprendizado de máquina no apoio à tomada de decisões de investimento, com foco na previsão de variáveis monetárias essenciais para o investidor, como preços de fechamento, abertura, alta, baixa e preço médio. As previsões foram realizadas com base em janelas deslizantes de seis dias, o que permitiu ao modelo se apoiar nos dados mais recentes para embasar suas estimativas, fator fundamental para avaliar um ativo tão volátil.

O modelo LSTM apresentou desempenho satisfatório na previsão simultânea de cinco variáveis monetárias do *Bitcoin*. Os coeficientes de determinação (R^2) permaneceram acima de 0,94 no conjunto de teste, indicando boa qualidade do ajuste geral do modelo aos dados. As variáveis, Alta do Dia e Preço Médio se destacaram com os menores valores de MAPE, 2,16% e 2,25%, além dos maiores R^2 , ambos em torno de 0,96, e os menores RMSE, 2,80 e 2,84, respectivamente, evidenciando a precisão e estabilidade dessas previsões. A validação autorregressiva iterativa, que simulou um cenário real de uso com dados não vistos, reforçou esses resultados: Alta do Dia e Preço Médio mantiveram o melhor desempenho, confirmando a capacidade de generalização do modelo para séries mais estáveis.

A principal contribuição deste trabalho foi demonstrar a eficácia do modelo LSTM na previsão simultânea de cinco variáveis monetárias do *Bitcoin*, ampliando o escopo frente à maioria dos estudos que se concentram em uma única variável. A metodologia adotada, com janelas deslizantes de seis dias e atributos derivados como variações percentuais, enriqueceu a base de dados e aprimorou a capacidade preditiva do modelo. Apesar dos resultados positivos, observou-se limitação na capacidade do modelo de reagir rapidamente a mudanças abruptas de tendência, especialmente em cenários de alta volatilidade, resultando em superestimacões pontuais. Na validação autorregressiva iterativa, a variável Fechamento apresentou os maiores erros quando comparada às demais variáveis, e o modelo demonstrou sensibilidade a pequenas flutuações em períodos de relativa estabilidade.

Com base nas informações apresentadas, para trabalhos futuros foi identificada a necessidade de incorporar variáveis externas, provenientes de análise de sentimentos de redes sociais (por exemplo, o X, antigo Twitter) e indicadores financeiros como o Índice de Força Relativa (RSI, *Relative Strength Index*), para auxiliar na previsão da reversão de tendência de crescimento ou queda. Além disso, a expansão do conjunto de dados para períodos com maior granularidade intradiária permitiria realizar análises mais detalhadas. Sugere-se ainda investigar modelos híbridos, combinando o LSTM com outras arquiteturas. Essas sugestões visam fortalecer a adaptação do modelo e o apoio aos investidores de *Bitcoin*.

Referências

- AGARWAL, A. et al. Prediction of bitcoin, litecoin and ethereum trends using state-of-art algorithms. In: IEEE. *2021 IEEE Mysore Sub Section International Conference (MysuruCon)*. [S.l.], 2021. p. 538–545. Citado 2 vezes nas páginas 26 e 28.
- ALBELADI, K.; ZAFAR, B.; MUEEN, A. Time series forecasting using lstm and arima. *International Journal of Advanced Computer Science and Applications*, Science and Information (SAI) Organization Limited, v. 14, n. 1, p. 313–320, 2023. Citado 2 vezes nas páginas 22 e 23.
- ALIU, J. et al. Driving forces behind the adoption of ieq principles in building design: evidence from nigerian quantity surveying firms. *International Journal of Building Pathology and Adaptation*, Emerald Publishing Limited, 2024. Citado na página 12.
- ANGELA, O.; SUN, Y. Factors affecting cryptocurrency prices: Evidence from ethereum. In: IEEE. *2020 International Conference on Information Management and Technology (ICIMTech)*. [S.l.], 2020. p. 318–323. Citado na página 17.
- ATTARDE, D. V.; SINGH, M. Survey on recommendation system using data mining and clustering techniques. *Int. J. Res. Eng. Appl. Management*, v. 3, p. 68–72, 2017. Citado na página 16.
- BAIG, M. The impact of cryptocurrency over the turkish capital market: A case study of bitcoin (btc). *Global Research Review in Business and Economics [GRRBE] ISSN (Online)*, p. 2454–3217, 2022. Citado na página 12.
- BAKTHA, K.; TRIPATHY, B. K. Investigation of recurrent neural networks in the field of sentiment analysis. In: *2017 International Conference on Communication and Signal Processing (ICCSP)*. [S.l.: s.n.], 2017. p. 2047–2050. Citado 2 vezes nas páginas 20 e 21.
- BAO, Y.; XIONG, T.; HU, Z. Multi-step-ahead time series prediction using multiple-output support vector regression. *Neurocomputing*, Elsevier, v. 129, p. 482–493, 2014. Citado na página 17.
- BAUR, D. G.; HONG, K.; LEE, A. D. Bitcoin: Medium of exchange or speculative assets? *Journal of International Financial Markets, Institutions and Money*, Elsevier, v. 54, p. 177–189, 2018. Citado na página 12.
- BEHESHTI, A. et al. Towards cognitive recommender systems. *Algorithms*, MDPI, v. 13, n. 8, p. 176, 2020. Citado na página 15.
- BILLIG, O. A.; GRZYBOVSKI, G. H. O uso das criptomoedas como dinheiro e sua coexistência com moedas fiduciárias. *RECIMA21-Revista Científica Multidisciplinar- ISSN 2675-6218*, v. 3, n. 9, p. e391922–e391922, 2022. Citado na página 14.
- BISWAS, P. K.; LIU, S. A hybrid recommender system for recommending smartphones to prospective customers. *Expert Systems with Applications*, Elsevier, v. 208, p. 118058, 2022. Citado na página 16.

- BOX, G. E. et al. *Time series analysis: forecasting and control*. [S.l.]: John Wiley & Sons, 2015. Citado na página 19.
- BREESE, J. S.; HECKERMAN, D.; KADIE, C. Empirical analysis of predictive algorithms for collaborative filtering. *arXiv preprint arXiv:1301.7363*, 2013. Citado na página 15.
- BRUHN, P.; ERNST, D. Assessing the risk characteristics of the cryptocurrency market: A garch-evt-copula approach. *Journal of Risk and Financial Management*, MDPI, v. 15, n. 8, p. 346, 2022. Citado na página 12.
- BURKE, R. Hybrid recommender systems: Survey and experiments. *User modeling and user-adapted interaction*, Springer, v. 12, p. 331–370, 2002. Citado na página 16.
- CAI, J. et al. Prediction and analysis of net ecosystem carbon exchange based on gradient boosting regression and random forest. *Applied energy*, Elsevier, v. 262, p. 114566, 2020. Citado na página 24.
- CENI, A. Random orthogonal additive filters: A solution to the vanishing/exploding gradient of deep neural networks. *IEEE Transactions on Neural Networks and Learning Systems*, p. 1–14, 2025. Citado na página 20.
- CHEN, S.-H.; WANG, P. P.; KUO, T.-W. *Computational intelligence in economics and finance: shifting the research frontier*. [S.l.]: Springer, 2007. Citado na página 19.
- CORBET, S. et al. Cryptocurrencies as a financial asset: A systematic analysis. *International Review of Financial Analysis*, Elsevier, v. 62, p. 182–199, 2019. Citado na página 12.
- Corporate Finance Institute. *Functions of Money*. 2025. Acesso em: 08 mar. 2025. Disponível em: <<https://corporatefinanceinstitute.com/resources/economics/functions-of-money/>>. Citado na página 14.
- CUI, Z. et al. Personalized recommendation system based on collaborative filtering for iot scenarios. *IEEE Transactions on Services Computing*, v. 13, n. 4, p. 685–695, 2020. Citado na página 15.
- ENSAFI, Y. et al. Time-series forecasting of seasonal items sales using machine learning—a comparative analysis. *International Journal of Information Management Data Insights*, Elsevier, v. 2, n. 1, p. 100058, 2022. Citado na página 19.
- FAISAL, A. F. et al. Neural networks based multivariate time series forecasting of solar radiation using meteorological data of different cities of bangladesh. *Results in Engineering*, Elsevier, v. 13, p. 100365, 2022. Citado 2 vezes nas páginas 22 e 23.
- FERNANDEZ, I. et al. Natsa: A near-data processing accelerator for time series analysis. In: IEEE. *2020 IEEE 38th International Conference on Computer Design (ICCD)*. [S.l.], 2020. p. 120–129. Citado na página 17.
- FRANÇOIS-LAVET, V. et al. An introduction to deep reinforcement learning. *Foundations and Trends® in Machine Learning*, Now Publishers, Inc., v. 11, n. 3-4, p. 219–354, 2018. Citado na página 18.

- GURI, M. Bitcoin: Leaking private keys from air-gapped cryptocurrency wallets. In: *2018 IEEE International Conference on Internet of Things (iThings) and IEEE Green Computing and Communications (GreenCom) and IEEE Cyber, Physical and Social Computing (CPSCom) and IEEE Smart Data (SmartData)*. [S.l.: s.n.], 2018. p. 1308–1316. Citado na página 15.
- HAN, Z. et al. A review of deep learning models for time series prediction. *IEEE Sensors Journal*, v. 21, n. 6, p. 7833–7848, 2021. Citado na página 17.
- HEWAMALAGE, H.; BERGMEIR, C.; BANDARA, K. Recurrent neural networks for time series forecasting: Current status and future directions. *International Journal of Forecasting*, Elsevier, v. 37, n. 1, p. 388–427, 2021. Citado 2 vezes nas páginas 20 e 21.
- HUYNH-THE, T. et al. Blockchain for the metaverse: A review. *Future Generation Computer Systems*, Elsevier, v. 143, p. 401–419, 2023. Citado na página 14.
- JAIN, S. et al. Trends, problems and solutions of recommender system. In: IEEE. *International conference on computing, communication & automation*. [S.l.], 2015. p. 955–958. Citado na página 16.
- JIANG, Y. et al. Empowering time series analysis with large language models: A survey. *arXiv preprint arXiv:2402.03182*, 2024. Citado na página 17.
- KANAUJIA, P. K. M. et al. Recommendation system for financial analytics. In: IEEE. *2016 International Conference on ICT in Business Industry & Government (ICTBIG)*. [S.l.], 2016. p. 1–5. Citado na página 12.
- KANG, C. Y.; LEE, C. P.; LIM, K. M. Cryptocurrency price prediction with convolutional neural network and stacked gated recurrent unit. *Data*, MDPI, v. 7, n. 11, p. 149, 2022. Citado 2 vezes nas páginas 26 e 28.
- KAUR, J.; PARMAR, K. S.; SINGH, S. Autoregressive models in environmental forecasting time series: a theoretical and application review. *Environmental Science and Pollution Research*, Springer, v. 30, n. 8, p. 19617–19641, 2023. Citado na página 19.
- KIRAN, R.; KUMAR, P.; BHASKER, B. Dnnrec: A novel deep learning based hybrid recommender system. *Expert Systems with Applications*, Elsevier, v. 144, p. 113054, 2020. Citado na página 16.
- KONTOPOULOU, V. I. et al. A review of arima vs. machine learning approaches for time series forecasting in data driven networks. *Future Internet*, MDPI, v. 15, n. 8, p. 255, 2023. Citado na página 19.
- KUMARI, S.; SINGH, S. K. Machine learning-based time series models for effective co2 emission prediction in india. *Environmental Science and Pollution Research*, Springer, v. 30, n. 55, p. 116601–116616, 2023. Citado na página 21.
- LIU, Z. et al. Forecast methods for time series data: A survey. *IEEE Access*, v. 9, p. 91896–91912, 2021. Citado na página 18.
- MANZOOR, B.; OTHMAN, I.; POMARES, J. C. Digital technologies in the architecture, engineering and construction (aec) industry—a bibliometric—qualitative literature review of research activities. *International journal of environmental research and public health*, MDPI, v. 18, n. 11, p. 6135, 2021. Citado na página 12.

- MBA, J. C.; MWAMBI, S. A markov-switching cogarch approach to cryptocurrency portfolio selection and optimization. *Financial Markets and Portfolio Management*, Springer, v. 34, p. 199–214, 2020. Citado na página 12.
- MBA, J. C.; PINDZA, E.; KOUMBA, U. A differential evolution copula-based approach for a multi-period cryptocurrency portfolio optimization. *Financial Markets and Portfolio Management*, Springer, v. 32, p. 399–418, 2018. Citado na página 12.
- MILANO, S.; TADDEO, M.; FLORIDI, L. Recommender systems and their ethical challenges. *Ai & Society*, Springer, v. 35, p. 957–967, 2020. Citado na página 15.
- MOHAMMED, M.; KHAN, M. B.; BASHIER, E. B. M. *Machine learning: algorithms and applications*. [S.l.]: Crc Press, 2016. Citado na página 18.
- MUDASSIR, M. et al. Time-series forecasting of bitcoin prices using high-dimensional features: a machine learning approach. *Neural computing and applications*, Springer, p. 1–15, 2020. Citado 4 vezes nas páginas 26, 27, 28 e 43.
- NAKAMOTO, S. Bitcoin: A peer-to-peer electronic cash system. *Satoshi Nakamoto*, 2008. Citado na página 12.
- NAWARA, D.; KASHEF, R. Iot-based recommendation systems – an overview. In: *2020 IEEE International IOT, Electronics and Mechatronics Conference (IEMTRONICS)*. [S.l.: s.n.], 2020. p. 1–7. Citado na página 16.
- NGUYEN, L. V. et al. Cognitive similarity-based collaborative filtering recommendation system. *Applied Sciences*, MDPI, v. 10, n. 12, p. 4183, 2020. Citado na página 15.
- NIU, T. et al. Developing a deep learning framework with two-stage feature selection for multivariate financial time series forecasting. *Expert Systems with Applications*, Elsevier, v. 148, p. 113237, 2020. Citado 3 vezes nas páginas 25, 27 e 28.
- NOH, S.-H. Analysis of gradient vanishing of rnns and performance comparison. *Information*, MDPI, v. 12, n. 11, p. 442, 2021. Citado na página 21.
- OLIVER, A. et al. Realistic evaluation of deep semi-supervised learning algorithms. *Advances in neural information processing systems*, v. 31, 2018. Citado na página 18.
- PAN, H.; TANG, Y.; WANG, G. A stock index futures price prediction approach based on the multi-garch-lstm mixed model. *Mathematics*, MDPI, v. 12, n. 11, p. 1677, 2024. Citado 3 vezes nas páginas 25, 27 e 28.
- PAREKH, R. et al. Dl-guess: Deep learning and sentiment analysis-based cryptocurrency price prediction. *IEEE Access*, v. 10, p. 35398–35409, 2022. Citado na página 14.
- PASCANU, R.; MIKOLOV, T.; BENGIO, Y. On the difficulty of training recurrent neural networks. In: PMLR. *International conference on machine learning*. [S.l.], 2013. p. 1310–1318. Citado na página 20.
- PIRANI, M. et al. A comparative analysis of arima, gru, lstm and bilstm on financial time series forecasting. In: *2022 IEEE International Conference on Distributed Computing and Electrical Circuits and Electronics (ICDCECE)*. [S.l.: s.n.], 2022. p. 1–6. Citado 2 vezes nas páginas 25 e 28.

PORTUGAL, I.; ALENCAR, P.; COWAN, D. The use of machine learning algorithms in recommender systems: A systematic review. *Expert Systems with Applications*, Elsevier, v. 97, p. 205–227, 2018. Citado na página 18.

RICCI, F.; ROKACH, L.; SHAPIRA, B. Introduction to recommender systems handbook. In: *Recommender systems handbook*. [S.l.]: Springer, 2010. p. 1–35. Citado 2 vezes nas páginas 12 e 16.

ROCHA, W. F. et al. Machine learning protocol from ultrasound data for monitoring, predicting, and supporting the analysis of dam slopes. In: IEEE. *2022 21st IEEE International Conference on Machine Learning and Applications (ICMLA)*. [S.l.], 2022. p. 1619–1623. Citado na página 18.

RODRIGUEZ-NIEVA, J. F.; SCHEURER, M. S. Identifying topological order through unsupervised machine learning. *Nature Physics*, Nature Publishing Group UK London, v. 15, n. 8, p. 790–795, 2019. Citado na página 18.

ROUHANI, S.; ABEDIN, E. Crypto-currencies narrated on tweets: a sentiment analysis approach. *International Journal of Ethics and Systems*, Emerald Publishing Limited, v. 36, n. 1, p. 58–72, 2020. Citado na página 12.

RUNDO, F. et al. Machine learning for quantitative finance applications: A survey. *Applied Sciences*, MDPI, v. 9, n. 24, p. 5574, 2019. Citado na página 19.

SATRIO, C. B. A. et al. Time series analysis and forecasting of coronavirus disease in indonesia using arima model and prophet. *Procedia Computer Science*, Elsevier, v. 179, p. 524–532, 2021. Citado na página 19.

SCHÄFER, A. M.; ZIMMERMANN, H. G. Recurrent neural networks are universal approximators. In: SPRINGER. *Artificial Neural Networks–ICANN 2006: 16th International Conference, Athens, Greece, September 10–14, 2006. Proceedings, Part I 16*. [S.l.], 2006. p. 632–640. Citado na página 20.

SHARAF, M. et al. A survey on recommendation systems for financial services. *Multimedia Tools and Applications*, Springer, v. 81, n. 12, p. 16761–16781, 2022. Citado 2 vezes nas páginas 12 e 15.

SHUMWAY, R. H.; STOFFER, D. S. *Time Series Analysis and Its Applications: With R Examples*. [S.l.]: Springer Cham, 2017. (Springer Texts in Statistics). ISBN 978-3-319-52451-1. Citado na página 17.

SIAMI-NAMINI, S.; TAVAKOLI, N.; NAMIN, A. S. A comparison of arima and lstm in forecasting time series. In: IEEE. *2018 17th IEEE international conference on machine learning and applications (ICMLA)*. [S.l.], 2018. p. 1394–1401. Citado na página 19.

SIAMI-NAMINI, S.; TAVAKOLI, N.; NAMIN, A. S. The performance of lstm and bilstm in forecasting time series. In: *2019 IEEE International Conference on Big Data (Big Data)*. [S.l.: s.n.], 2019. p. 3285–3292. Citado 2 vezes nas páginas 17 e 18.

SIMON, P. *Too Big to Ignore: The Business Case for Big Data*. [S.l.]: Wiley, 2013. Citado na página 18.

- SINGH, P. et al. An improved model for opinion mining of public reviews using recurrent neural network. In: *2021 International Conference on Technological Advancements and Innovations (ICTAI)*. [S.l.: s.n.], 2021. p. 20–25. Citado na página 20.
- SINGH, S. et al. Study of arima and least square support vector machine (ls-svm) models for the prediction of sars-cov-2 confirmed cases in the most affected countries. *Chaos, Solitons & Fractals*, Elsevier, v. 139, p. 110086, 2020. Citado na página 19.
- SOVBETOV, Y. Factors influencing cryptocurrency prices: Evidence from bitcoin, ethereum, dash, litcoin, and monero. 2018. Citado na página 17.
- SURATKAR, S.; SHIROLE, M.; BHIRUD, S. Cryptocurrency wallet: A review. In: *2020 4th International Conference on Computer, Communication and Signal Processing (ICCCSP)*. [S.l.: s.n.], 2020. p. 1–7. Citado na página 15.
- WALEK, B.; FAJMON, P. A hybrid recommender system for an online store using a fuzzy expert system. *Expert Systems with Applications*, Elsevier, v. 212, p. 118565, 2023. Citado na página 16.
- WANG, B.; ZHANG, W. Research on edge network topology optimization based on machine learning. In: IEEE. *2023 5th International Conference on Applied Machine Learning (ICAML)*. [S.l.], 2023. p. 41–46. Citado na página 18.
- WANG, J. et al. Deep learning for multivariate time series imputation: A survey. *arXiv preprint arXiv:2402.04059*, 2024. Citado na página 17.
- ZAIETS, O.; YESKOV, S. Cryptocurrency market analysis: realities and prospects. In: ATLANTIS PRESS. *International Conference on Economics, Law and Education Research (ELER 2021)*. [S.l.], 2021. p. 158–162. Citado na página 12.
- ZHANG, G. P.; KLINE, D. M. Quarterly time-series forecasting with neural networks. *IEEE transactions on neural networks*, Ieee, v. 18, n. 6, p. 1800–1814, 2007. Citado na página 19.
- ZHANG, K. et al. Self-supervised learning for time series analysis: Taxonomy, progress, and prospects. *IEEE transactions on pattern analysis and machine intelligence*, IEEE, 2024. Citado na página 17.
- ZHANG, K. et al. Self-supervised learning for time series analysis: Taxonomy, progress, and prospects. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, v. 46, n. 10, p. 6775–6794, 2024. Citado na página 17.
- ZHOU, S. et al. An optimized heterogeneous structure lstm network for electricity price forecasting. *IEEE Access*, v. 7, p. 108161–108173, 2019. Citado na página 21.



TERMO DE AUTORIZAÇÃO PARA PUBLICAÇÃO DIGITAL NA BIBLIOTECA “JOSÉ ALBANO DE MACEDO”

Identificação do Tipo de Documento

- Tese
- Dissertação
- Monografia
- Artigo

Eu, **JOSÉ WANDERLEI FRANCISCO DE SOUSA ROCHA**, autorizo com base na Lei Federal nº 9.610 de 19 de Fevereiro de 1998 e na Lei nº 10.973 de 02 de dezembro de 2004, a biblioteca da Universidade Federal do Piauí a divulgar, gratuitamente, sem ressarcimento de direitos autorais, o texto integral da publicação **Uso de Aprendizado de Máquina no Apoio a Tomada de Decisões em Investimentos de Bitcoins** de minha autoria, em formato PDF, para fins de leitura e/ou impressão, pela internet a título de divulgação da produção científica gerada pela Universidade.

Picos-PI, 07 de Julho de 2025.



Documento assinado digitalmente
JOSE WANDERLEI FRANCISCO DE SOUSA ROCH
Data: 07/07/2025 13:39:51-0300
Verifique em <https://validar.iti.gov.br>

Assinatura