

## ANÁLISE E PREVISÃO DO PREÇO DO ETHEREUM UTILIZANDO REDES NEURAIS LSTM

Gabriel Eloy Ghellere Conti\*; Junior Mateus Peters Graf\*\*

\*Acadêmico de Engenharia de Software pela - Uniguaçu, [gabrieleloyghellere@gmail.com](mailto:gabrieleloyghellere@gmail.com).

\*\*Professor da Faculdade Uniguaçu do curso de Engenharia de Software, especialista em Business Intelligence, Big Data e Inteligência Artificial, [mtsptrs2@gmail.com](mailto:mtsptrs2@gmail.com)

### INFORMAÇÕES

#### Histórico de submissão:

Recebido em: 25 maio. 2025

Aceite: 07 jun. 2025

Publicação *online*: jun. 2025

### RESUMO

Este artigo apresenta uma análise da aplicabilidade de redes neurais recorrentes do tipo Long Short-Term Memory (LSTM) na previsão da direção do preço da criptomoeda Ethereum (ETH), com base em dados históricos de fechamento diário entre 2017 e 2025. O objetivo principal é investigar se modelos LSTM podem auxiliar investidores na tomada de decisão, antecipando se o preço do ativo irá subir ou cair no dia seguinte. A metodologia envolve o treinamento de modelos com dados normalizados, utilizando divisão temporal de 90% para treinamento, 5% para teste e 5% para validação. Foram realizados 27 experimentos variando a arquitetura da rede (camadas, neurônios e épocas) e aplicadas métricas de avaliação de acurácia direcional e lucro acumulado em uma estratégia Long/Short simulada. Os resultados foram comparados com a estratégia Buy and Hold. A melhor configuração identificada (RNA 16) obteve acurácia de 53,03%, enquanto o maior lucro na validação foi alcançado pela RNA 26, com 28,65%. Em contraste, a estratégia Buy and Hold gerou um prejuízo acumulado de -18,51%. Embora algumas simulações tenham mostrado lucros em determinados cenários, os modelos avaliados neste estudo não apresentaram acurácia significativamente superior ao acaso. Portanto, os resultados não são suficientes para afirmar que a abordagem LSTM testada seja eficaz na previsão da direção do preço do Ethereum, sendo necessário aprofundar a investigação com outras configurações e abordagens complementares.

**Palavras-chave:** previsão de preços; redes neurais LSTM; ethereum; mercado financeiro; aprendizado profundo.

### ABSTRACT

This article presents an analysis of the applicability of Long Short-Term Memory (LSTM) recurrent neural networks in predicting the price direction of the cryptocurrency Ethereum (ETH), based on daily closing data from 2017 to 2025. The main objective is to investigate whether LSTM models can assist investors in decision-making by anticipating whether the asset's price will rise or fall the following day. The methodology involves training models on normalized data using a temporal split of 90% for training, 5% for testing, and 5% for validation. A total of 27 experiments were conducted, varying the network architecture (layers, neurons, and epochs), and evaluating both directional accuracy and cumulative profit in a simulated Long/Short strategy. Results were compared with a Buy and Hold strategy. The best-performing configuration (RNA 16) achieved an accuracy of 53.03%, while the highest validation profit was obtained by RNA 26, at 28.65%. In contrast, the Buy and Hold strategy resulted in a cumulative loss of -18.51%. Although some simulations showed profits under certain conditions, the models tested in this study did not demonstrate directional accuracy significantly above chance level. Therefore, the results are not sufficient to claim that the tested LSTM approach is effective for predicting Ethereum price direction, highlighting the need for further investigation with alternative configurations and complementary techniques.

**Keywords:** price prediction; LSTM neural networks; ethereum; financial market; deep learning.

## INTRODUÇÃO

Nos últimos anos, o avanço das tecnologias de inteligência artificial tem impulsionado a aplicação de modelos de aprendizado de máquina no mercado financeiro, especialmente no campo da previsão de preços de ativos. Dentre esses ativos, o Ethereum (ETH) destaca-se como uma das principais criptomoedas em valor de mercado e volume de negociações, sendo amplamente utilizado tanto como forma de investimento quanto como base para aplicações descentralizadas (Buterin, 2014).

As criptomoedas são ativos digitais que utilizam criptografia para garantir transações seguras e para controlar a criação de novas unidades, operando de forma descentralizada por meio da tecnologia blockchain. Diferentemente das moedas fiduciárias, que dependem de bancos centrais e intermediários financeiros, as criptomoedas funcionam em redes distribuídas entre os participantes do sistema, conferindo maior transparência, resistência à censura e potencial de automação por meio de contratos inteligentes (Nakamoto, 2008).

A tecnologia blockchain é a base estrutural que viabiliza o funcionamento das criptomoedas. Trata-se de um banco de dados distribuído, imutável e descentralizado, que armazena registros de transações em blocos interligados por criptografia. Cada bloco contém um conjunto de transações validadas, um carimbo temporal (*timestamp*) e um código de verificação que referencia o bloco anterior, formando assim uma cadeia sequencial resistente a alterações retroativas (Narayanan *et al.*, 2016).

Esse modelo descentralizado elimina a necessidade de intermediários centrais para validar e registrar transações, conferindo maior segurança, transparência e confiabilidade ao sistema. No caso do Ethereum, por exemplo, a blockchain também permite a execução de contratos inteligentes (*smart contracts*), que são programas autoexecutáveis cujas regras estão codificadas diretamente na rede (Buterin, 2014).

Além do uso em criptomoedas, a tecnologia blockchain tem sido explorada em diversos setores, como cadeias de suprimentos, registros públicos, identidade digital e sistemas de votação, consolidando-se como uma inovação tecnológica com potencial disruptivo em diferentes áreas da economia e da sociedade (Tapscott; Tapscott, 2018).

As *exchanges* de criptomoedas são plataformas digitais que permitem a negociação de ativos como Bitcoin, Ethereum e outros *tokens*, funcionando de forma semelhante a corretoras do mercado tradicional. Por meio dessas plataformas, os usuários podem comprar, vender ou trocar criptomoedas

utilizando moedas fiduciárias ou outros criptoativos. As exchanges desempenham um papel essencial na liquidez do mercado cripto e na formação de preços, conectando compradores e vendedores em tempo real (Houben; Snyers, 2018).

Existem dois tipos principais de exchanges: centralizadas (*CEX*) e descentralizadas (*DEX*). Nas exchanges centralizadas, como Binance, Coinbase ou Kraken, as transações são intermediadas por uma entidade responsável por custodiar os ativos dos usuários e manter a infraestrutura da plataforma. Embora ofereçam maior liquidez e funcionalidades avançadas, essas exchanges representam um ponto central de falha e estão sujeitas a riscos regulatórios, operacionais e de segurança (Schär, 2021).

As exchanges descentralizadas, por outro lado, operam diretamente sobre protocolos de blockchain e eliminam a necessidade de intermediários. Nelas, os usuários mantêm controle total sobre seus fundos e as negociações ocorrem por meio de contratos inteligentes. Apesar das vantagens em termos de soberania e privacidade, as DEX ainda enfrentam limitações como menor liquidez, interfaces menos intuitivas e maior exposição a falhas de código (Werner *et al.*, 2021).

As carteiras de criptomoedas, conhecidas como *wallets*, são ferramentas digitais utilizadas para armazenar, enviar e receber ativos cripto como o Ether (ETH). Diferentemente de contas bancárias tradicionais, as carteiras não armazenam fisicamente os ativos, mas sim as chaves privadas que permitem o acesso e o controle sobre os fundos registrados na blockchain (Antonopoulos, 2017).

Existem diferentes tipos de carteiras, cada uma com níveis distintos de segurança e praticidade. As carteiras quentes (*hot wallets*) são conectadas à internet e oferecem maior conveniência, sendo ideais para uso cotidiano. Já as carteiras frias (*cold wallets*), como *hardware wallets* e *paper wallets*, operam offline e são mais seguras contra ataques cibernéticos, sendo preferidas para o armazenamento de longo prazo (Narayanan *et al.*, 2016; Antonopoulos, 2017).

A segurança das carteiras depende fundamentalmente da proteção das chaves privadas. A perda dessa chave implica na perda irreversível dos ativos, uma vez que não há uma entidade central que possa restaurar o acesso. Essa característica reforça o princípio de descentralização do ecossistema cripto, ao mesmo tempo em que impõe maior responsabilidade individual aos usuários (Narayanan *et al.*, 2016).

O Ethereum é uma plataforma descentralizada baseada em blockchain que permite a criação e execução de contratos inteligentes (*smart contracts*) e aplicações descentralizadas (*DApps*), sem a

necessidade de intermediários. Lançado em 2015 por Vitalik Buterin e outros desenvolvedores, o projeto ampliou os horizontes do uso de blockchain, indo além da função de moeda digital proposta pelo Bitcoin (Buterin, 2014).

A principal inovação do Ethereum está em sua máquina virtual, a Ethereum Virtual Machine (EVM), que permite que qualquer desenvolvedor escreva e implante contratos autônomos que são executados de forma imutável na rede. Isso viabiliza uma ampla gama de aplicações, como finanças descentralizadas (*DeFi*), *tokens* não fungíveis (*NFTs*) e sistemas de governança automatizada (Wood, 2014).

O ativo nativo da plataforma é o Ether (ETH), utilizado para pagar taxas de transação e incentivar os participantes da rede. Além de seu papel funcional, o ETH também é negociado como ativo financeiro nos mercados globais, sendo uma das criptomoedas mais relevantes em termos de capitalização de mercado, volume de transações e número de aplicações desenvolvidas sobre sua infraestrutura (Etherscan, 2025).

Desde seu lançamento, o Ethereum passou por diversas atualizações importantes, conhecidas como *hard forks*. Entre elas, destacam-se o “Homestead” (2016), que trouxe mais estabilidade à rede; o “Metropolis” (2017–2019), que introduziu melhorias de segurança e escalabilidade; e o “Istanbul” (2019), que otimizou o desempenho da EVM. Uma das mudanças mais relevantes foi o processo de transição do mecanismo de consenso de *Proof of Work* (PoW) para *Proof of Stake* (PoS), finalizado em setembro de 2022 com a atualização “The Merge”. Essa mudança reduziu drasticamente o consumo de energia da rede, consolidando o Ethereum como uma das plataformas blockchain mais sustentáveis e tecnologicamente avançadas da atualidade (Ethereum Foundation, 2022).

Desde o lançamento do Bitcoin em 2009, diversas outras criptomoedas foram criadas com propósitos distintos, como o Ethereum, que se consolidou não apenas como meio de troca, mas também como plataforma de desenvolvimento para aplicações descentralizadas (*DApps*). Esses ativos têm despertado o interesse de investidores, desenvolvedores e instituições financeiras, tanto por seu potencial de valorização quanto pela inovação que representam no sistema financeiro global (Catalini; Gans, 2016).

Ao contrário dos mercados tradicionais, o comportamento das criptomoedas apresenta elevada volatilidade e menor regulação, o que dificulta a modelagem baseada em premissas econômicas convencionais (Corbet *et al.*, 2018). Nesse contexto, as redes neurais recorrentes, especialmente os modelos do tipo Long Short-Term Memory (LSTM), têm ganhado atenção por sua capacidade de lidar com

dados sequenciais e capturar padrões temporais em séries temporais financeiras (Fischer; Krauss, 2018).

Este trabalho tem como objetivo principal investigar se uma rede neural LSTM pode ser utilizada para prever a direção do preço do Ethereum — ou seja, se o valor de fechamento no dia seguinte será maior ou menor que o do dia atual. Diferentemente de abordagens voltadas à previsão do valor exato, a ênfase aqui está na previsão de tendência, buscando avaliar se o modelo pode oferecer alguma vantagem prática em cenários de tomada de decisão.

A análise é conduzida com base em dados históricos do preço de fechamento diário do Ethereum entre dezembro de 2017 e março de 2025. Foram realizados 27 testes com diferentes configurações de rede (variando número de camadas, neurônios e épocas), avaliando tanto a acurácia direcional quanto o desempenho financeiro simulado por meio de uma estratégia Long/Short. Os resultados obtidos são comparados com a estratégia passiva Buy and Hold, frequentemente utilizada como referência de desempenho em estudos financeiros.

A hipótese inicial considera que um modelo LSTM, ainda que simples, pode capturar padrões suficientemente relevantes para superar o desempenho de uma estratégia passiva em determinadas condições de mercado. No entanto, como será discutido nas seções seguintes, os modelos avaliados apresentaram acurácia próxima ao acaso, o que limita sua utilidade prática nas condições testadas.

## FUNDAMENTAÇÃO TEÓRICA

A inteligência artificial (IA) é uma área da ciência da computação que estuda a criação de sistemas capazes de executar tarefas que normalmente exigiriam inteligência humana, como reconhecimento de padrões, tomada de decisão, raciocínio lógico e aprendizado a partir de dados. Dentre os diversos ramos da IA, destaca-se o aprendizado de máquina (*machine learning*), no qual algoritmos são treinados a partir de grandes volumes de dados para realizar previsões ou classificações (Russell; Norvig, 2021).

O avanço das técnicas de IA tem possibilitado aplicações relevantes em diversas áreas, como medicina, logística, segurança, indústria e, mais recentemente, nos mercados financeiros. Nesse último caso, modelos baseados em redes neurais têm se mostrado promissores por sua capacidade de detectar padrões não lineares e sutis em séries temporais, superando as limitações de métodos estatísticos tradicionais (Heaton; Polson; Witte, 2017). A utilização de arquiteturas como as redes neurais recorrentes (Recurrent Neural Networks – RNNs) e suas variantes, como as LSTM, tem permitido o desenvolvimento de sistemas preditivos voltados à análise de ativos voláteis como as criptomoedas, ainda

que com desafios significativos relacionados à sobreajuste, interpretabilidade e variabilidade dos dados de entrada.

O neurônio artificial é a unidade básica de processamento nas redes neurais, inspirado no funcionamento dos neurônios biológicos. Sua função principal é receber entradas (valores numéricos), aplicar a elas pesos (que representam a importância relativa de cada entrada), somá-las e, em seguida, passar esse valor por uma função de ativação não linear, como a *sigmoid*, *ReLU* ou *tanh*. O resultado final é uma saída que pode ser usada em uma tarefa de classificação ou regressão (Goodfellow; Bengio; Courville, 2016).

Essa estrutura permite que redes neurais aprendam padrões complexos ao ajustar os pesos dos neurônios durante o processo de treinamento, geralmente por meio de algoritmos como o gradiente descendente. Quando organizados em camadas, os neurônios artificiais formam arquiteturas profundas capazes de realizar representações cada vez mais abstratas dos dados de entrada. Esse empilhamento em múltiplas camadas é o que caracteriza o chamado deep learning, base de modelos como as redes LSTM utilizadas neste trabalho (LeCun; Bengio; Hinton, 2015).

A função de ativação é um componente essencial no funcionamento dos neurônios artificiais, sendo responsável por introduzir não linearidade ao modelo. Sem ela, a rede neural se comportaria como uma simples combinação linear das entradas, independentemente da profundidade da arquitetura, o que limitaria severamente sua capacidade de aprender padrões complexos (Goodfellow; Bengio; Courville, 2016).

Existem diversas funções de ativação utilizadas em redes neurais, cada uma com características próprias. A função sigmoide, historicamente uma das primeiras, mapeia a entrada para um intervalo entre 0 e 1, sendo útil em tarefas de classificação binária, mas propensa ao problema do “desvanecimento do gradiente”. A *tanh* oferece uma saída entre -1 e 1, centrada na origem, o que pode favorecer a convergência em alguns casos. Já a *ReLU* (Rectified Linear Unit), atualmente uma das mais utilizadas em redes profundas, retorna zero para entradas negativas e valor linear para entradas positivas, promovendo um treinamento mais eficiente e reduzindo significativamente os efeitos do desvanecimento do gradiente (Nair; Hinton, 2010).

A previsão de preços no mercado financeiro é um problema complexo e amplamente estudado, envolvendo fatores econômicos, comportamentais e técnicos. Tradicionalmente, modelos estatísticos como ARIMA e regressões lineares foram utilizados para modelar séries temporais de ativos financeiros. Contudo, essas abordagens possuem limitações na captura de não linearidades e dependências temporais

de longo prazo, comuns em mercados voláteis como o de criptomoedas (Zhang *et al.*, 1998).

Redes neurais recorrentes (RNNs) surgem como uma alternativa promissora por sua capacidade de processar sequências de dados e preservar informações anteriores por meio de ciclos internos. No entanto, RNNs tradicionais enfrentam dificuldades quando se trata de dependências de longo prazo, devido ao problema do desaparecimento ou explosão do gradiente (Hochreiter *et al.*, 2001).

Para contornar essas limitações, foi proposto o modelo Long Short-Term Memory (LSTM), uma arquitetura de rede neural recorrente com mecanismos internos chamados de “portas” que regulam o fluxo de informação e permitem o armazenamento e o esquecimento seletivo de dados ao longo do tempo (Hochreiter; Schmidhuber, 1997). Essa característica torna as LSTM particularmente adequadas para tarefas de previsão em séries temporais financeiras, onde padrões sutis e temporariamente distantes podem ter relevância preditiva.

Diversos estudos já exploraram o uso de LSTM no contexto de finanças. Fischer e Krauss (2018) demonstraram que modelos LSTM superaram métodos tradicionais na previsão de retornos do mercado de ações dos Estados Unidos. No campo das criptomoedas, Bao *et al.* (2017) utilizaram LSTM para prever os preços do Bitcoin, com resultados promissores, embora ainda sujeitos à alta variabilidade do mercado.

Paralelamente ao uso de modelos preditivos, também é necessário considerar métricas adequadas de avaliação. A acurácia direcional, ou seja, a capacidade de prever corretamente se o preço irá subir ou cair, é particularmente relevante para estratégias de negociação ativa. Além disso, o desempenho financeiro pode ser avaliado por meio de simulações de estratégias baseadas nas previsões geradas, como Long/Short, que combinam operações de compra (long) e venda (short) com base na tendência prevista (Yeh *et al.*, 2011).

A comparação com estratégias passivas, como o Buy and Hold, é fundamental para estabelecer a relevância prática de qualquer modelo preditivo. A estratégia Buy and Hold consiste em comprar o ativo e mantê-lo por todo o período analisado, sendo considerada um benchmark por sua simplicidade e resistência ao ruído de curto prazo (Malkiel, 2003).

Um dos principais desafios no treinamento de redes neurais é o equilíbrio entre aprendizagem e generalização. O *overfitting* ocorre quando o modelo se ajusta excessivamente aos dados de treinamento, capturando ruídos e padrões específicos que não se repetem nos dados novos. Como resultado, o modelo apresenta desempenho elevado durante o treinamento, mas falha ao generalizar para dados fora

da amostra, como os de teste ou validação (Goodfellow; Bengio; Courville, 2016).

Esse fenômeno é especialmente crítico em tarefas de previsão de séries temporais financeiras, como no caso das criptomoedas, onde os dados são altamente voláteis e sujeitos a variações não sistemáticas. Segundo Heaton, Polson e Witte (2017), em contextos como o mercado financeiro, a generalização é ainda mais desafiadora devido à natureza não estacionária e ao alto ruído dos dados históricos.

Diversas estratégias podem ser empregadas para mitigar o overfitting, entre elas o uso de técnicas de regularização como o dropout, que consiste em desativar aleatoriamente neurônios durante o treinamento para evitar dependência excessiva de determinados caminhos na rede (Srivastava *et al.*, 2014). Outra abordagem é o uso de early stopping, que interrompe o treinamento assim que o desempenho na validação começar a se deteriorar, impedindo o modelo de continuar ajustando-se a ruídos nos dados de treinamento (Prechelt, 1998).

## METODOLOGIA

Este estudo utilizou dados históricos do preço de fechamento diário do Ethereum (ETH), obtidos por meio da biblioteca yFinance, referente ao período de 1º de dezembro de 2017 a 1º de março de 2025. Após a coleta, os dados foram tratados para remoção de valores nulos e, em seguida, normalizados utilizando a técnica Min-Max Scaling, que transforma os valores para a faixa entre 0 e 1. A variável-alvo foi definida como binária, indicando se o fechamento do dia seguinte seria maior (1) ou menor (0) em relação ao fechamento do dia atual.

Para estruturar os dados sequencialmente, foi empregada uma janela deslizante de 28 dias ( $n\_steps = 28$ ), gerando conjuntos de entrada com 28 registros consecutivos da série normalizada, e uma saída correspondente à direção do próximo valor. A base de dados resultante foi então dividida de forma temporal em três conjuntos: 90% para treinamento, 5% para teste e 5% para validação. Essa divisão respeita a ordem cronológica dos dados, evitando vazamento de informações entre os conjuntos e simulando uma situação mais próxima da realidade de um investidor (García *et al.*, 2020).

O modelo LSTM foi implementado com a biblioteca Keras, permitindo variações dinâmicas de arquitetura por meio de parâmetros ajustáveis no código. Foram testadas 27 configurações diferentes, alterando-se o número de camadas LSTM (entre 1 e 20), a quantidade de neurônios por camada (entre 1 e 300), e o número de épocas até EarlyStopping. Em todos os casos, o treinamento foi limitado a no máximo 180 épocas, mas nenhuma das redes atingiu esse limite. O critério de parada antecipada (*EarlyStopping*) monitorou a perda

na validação ( $val\_loss$ ) com paciência de 15 épocas, restaurando os melhores pesos ao final. Notou-se empiricamente que redes mais rasas (com menos camadas) tendiam a alcançar mais épocas de treinamento do que as mais profundas, o que sugere maior estabilidade e menor propensão a overfitting inicial.

O *EarlyStopping* é uma técnica de regularização amplamente utilizada no treinamento de redes neurais, cujo objetivo é interromper o processo de aprendizagem antes que o modelo comece a superajustar os dados de treinamento. Essa abordagem monitora o desempenho do modelo em um conjunto de validação e cessa o treinamento assim que a métrica observada (geralmente a perda de validação) para de melhorar após um número pré-definido de épocas — parâmetro conhecido como “paciência” (Prechelt, 1998).

A lógica do *EarlyStopping* está fundamentada na ideia de que, após certo ponto, continuar o treinamento não resulta em melhor generalização e, na prática, pode levar a um modelo excessivamente ajustado ao conjunto de treino. Segundo Goodfellow, Bengio e Courville (2016), essa técnica funciona como um controle automático de complexidade, especialmente útil em problemas com conjuntos de dados ruidosos ou limitados em tamanho.

Na prática, o algoritmo armazena os pesos da melhor época observada — isto é, aquela que obteve o menor valor de perda no conjunto de validação. Ao final do treinamento, os pesos retornam a esse ponto ótimo, mitigando os efeitos de flutuações negativas nas últimas épocas. Isso evita que o modelo termine o processo de treinamento em um estado menos generalizável, mesmo que tenha aprendido mais sobre os dados de treino (Bishop, 2006).

O otimizador escolhido foi o Adam (Adaptive Moment Estimation), amplamente utilizado em tarefas de aprendizado profundo por combinar as vantagens do momentum e da adaptação individual de taxas de aprendizado para cada parâmetro (Kingma; Ba, 2015). Sua eficiência em convergência e robustez em problemas ruidosos o tornam particularmente indicado para aplicações em dados financeiros.

A função de perda utilizada foi a *binary crossentropy*, apropriada para problemas de classificação binária. Como métricas de avaliação foram consideradas a acurácia direcional — percentual de previsões corretas quanto à direção do movimento do preço — e o lucro acumulado em uma simulação de operações Long/Short, descontando taxas de operação. Além disso, as previsões geradas foram comparadas com a performance da estratégia Buy and Hold, medida como a variação percentual do preço do Ethereum ao longo do período de validação.

Em problemas de previsão de preços de ativos financeiros, a escolha da métrica de avaliação é fundamental para refletir os objetivos reais da

aplicação. Neste trabalho, optou-se por utilizar a acurácia direcional (*directional accuracy*), uma métrica binária que avalia se o modelo conseguiu prever corretamente a direção do movimento de preço — ou seja, se o valor de fechamento no dia seguinte será maior ou menor que o atual (Tse; Xiang; Wang, 2010).

Ao contrário de métricas tradicionais como erro quadrático médio (MSE), erro absoluto médio (MAE) ou desvio percentual absoluto médio (MAPE), que medem a precisão na estimativa do valor numérico do ativo, a acurácia direcional está mais alinhada com o interesse prático de muitos investidores, especialmente em estratégias de tomada de decisão como operações de compra (long) ou venda (short) (González-Rivera, 2001). Em cenários altamente voláteis, como o das criptomoedas, prever com exatidão o valor absoluto do ativo é extremamente difícil, mas prever corretamente a direção pode ser suficiente para gerar lucro operacional.

Além disso, segundo Kara, Boyacioglu e Baykan (2011), a acurácia direcional é mais robusta a ruídos em séries temporais financeiras e permite a aplicação de modelos simplificados, como redes LSTM univariadas, sem perda significativa de aplicabilidade prática. Essa abordagem facilita também a avaliação por meio de simulações com estratégias baseadas em decisões binárias, como a Long/Short utilizada neste estudo.

Todos os experimentos foram realizados em ambiente Google Colab.

## RESULTADOS E DISCUSSÃO

Os 27 testes realizados com diferentes arquiteturas de redes LSTM apresentaram variação significativa nos resultados de lucro acumulado porém notou-se pouca variação de acurácia direcional. Para cada configuração, foram registradas as métricas de desempenho no conjunto de validação, sendo este o principal critério de análise por representar a capacidade preditiva do modelo em dados nunca vistos.

A Tabela 1 apresenta um resumo dos principais indicadores de cada rede neural testada, incluindo a acurácia direcional no conjunto de validação e o lucro acumulado da estratégia Long/Short, comparado ao desempenho da estratégia Buy and Hold. Entre todas as configurações avaliadas, a RNA 16 obteve a maior acurácia na validação, com 53,03%. Já a maior rentabilidade foi alcançada pela RNA 26, que acumulou um lucro de 28,65% no mesmo conjunto. Em contraste, a estratégia Buy and Hold resultou em um prejuízo de -18,51% no mesmo período.

A Figura 1 ilustra o desempenho financeiro da RNA 26, responsável pelo maior lucro acumulado em validação. A curva mostra a evolução percentual do

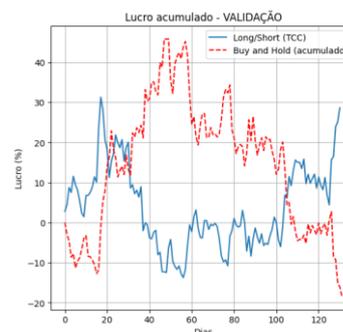
capital ao longo do tempo, comparando a estratégia baseada nas previsões do modelo com a estratégia Buy and Hold.

Tabela 1 – Resultados dos testes de redes neurais LSTM com variação de camadas, neurônios e épocas.

Configuração	Camadas	Neurônios	Épocas	Acurácia Direcional (%)	Lucro Acumulado no Período LSTM (%)	Lucro Acumulado no Período Buy and Hold (%)
RNA 1	4	14	180	50.76	-11.73	-18.51
RNA 2	4	12	180	49.24	-30.40	-18.51
RNA 3	2	12	180	48.48	-14.76	-18.51
RNA 4	1	10	180	47.73	-20.92	-18.51
RNA 5	5	14	180	49.24	-30.40	-18.51
RNA 6	4	18	180	50.76	-11.73	-18.51
RNA 7	4	16	180	49.24	-30.40	-18.51
RNA 8	8	28	180	49.24	-30.40	-18.51
RNA 9	4	100	180	50.76	-11.73	-18.51
RNA 10	4	200	180	50.76	-11.73	-18.51
RNA 11	2	16	180	50.76	-11.73	-18.51
RNA 12	1	2	180	48.48	-5.67	-18.51
RNA 13	2	2	180	49.24	-12.19	-18.51
RNA 14	1	4	180	50.76	-11.73	-18.51
RNA 15	2	1	180	49.24	-30.40	-18.51
RNA 16	1	1	180	53.03	26.77	-18.51
RNA 17	1	2	180	49.24	-30.40	-18.51
RNA 18	1	1	180	49.24	-30.40	-18.51
RNA 19	1	1	180	50.76	-11.73	-18.51
RNA 20	1	1	180	49.24	-30.40	-18.51
RNA 21	1	3	180	50.76	-11.73	-18.51
RNA 22	2	3	180	49.24	-30.40	-18.51
RNA 23	3	1	180	49.24	-30.40	-18.51
RNA 24	20	1	180	49.24	-30.40	-18.51
RNA 25	1	50	180	50.76	-11.73	-18.51
RNA 26	1	100	180	51.52	28.65	-18.51
RNA 27	1	300	180	50.76	-11.73	-18.51

Fonte: do Autor

Figura 1 – Gráfico de lucro acumulado da RNA 26 comparado ao Buy and Hold.



Fonte: do Autor

Apesar de algumas configurações apresentarem desempenho financeiro positivo, especialmente em termos de lucro acumulado, a maioria das redes testadas registrou acurácia direcional em torno de 50%, o que é próximo ao resultado esperado por puro acaso. Este comportamento levanta dúvidas sobre a consistência estatística das previsões e limita a generalização dos resultados.

Além disso, observou-se que redes com menos camadas tenderam a atingir um número maior de épocas antes da interrupção por *EarlyStopping*, o que sugere uma maior estabilidade no processo de

treinamento. Já redes mais profundas frequentemente encerravam o treinamento precocemente, o que pode indicar maior propensão ao sobreajuste ou dificuldade na otimização dos pesos.

## CONCLUSÕES

Os 27 testes realizados com diferentes arquiteturas de redes LSTM indicaram que, embora algumas configurações específicas tenham obtido lucro acumulado positivo em simulações Long/Short — com destaque para a RNA 26, que acumulou 28,65% de lucro na validação — a acurácia direcional dos modelos permaneceu próxima de 50% na maioria dos casos. A melhor rede em termos de previsão, a RNA 16, alcançou 53,03% de acurácia na validação, o que representa apenas uma ligeira vantagem sobre o acaso. Já a estratégia Buy and Hold, usada como referência, teve um desempenho negativo de -18,51% no mesmo período.

Embora os lucros obtidos por algumas redes possam sugerir uma utilidade prática pontual, os resultados demonstram que, nas condições específicas testadas, os modelos LSTM avaliados não apresentaram desempenho consistente o bastante para justificar seu uso como ferramenta confiável de apoio à tomada de decisão no mercado de criptomoedas. Essa limitação, no entanto, não invalida o potencial da arquitetura LSTM em contextos mais amplos, mas ressalta a importância de uma calibração mais cuidadosa dos hiperparâmetros e da inclusão de variáveis adicionais.

Outro aspecto observado foi a tendência de redes com menos camadas atingirem um número maior de épocas de treinamento antes do EarlyStopping, sugerindo uma maior estabilidade durante o processo de otimização. Em contrapartida, redes mais profundas frequentemente encerravam o treinamento de forma precoce, o que pode indicar maior sensibilidade a ruído ou dificuldade em ajustar seus parâmetros com eficácia.

Como em todo estudo empírico, esta pesquisa apresenta limitações que devem ser consideradas na interpretação dos resultados. A primeira diz respeito à natureza univariada dos dados utilizados. O modelo LSTM foi alimentado exclusivamente com o histórico do preço de fechamento diário do Ethereum, sem considerar variáveis técnicas adicionais, como volume de negociação, médias móveis, volatilidade implícita ou indicadores baseados em sentimento. Segundo Patel et al. (2015), a inclusão de variáveis exógenas pode melhorar substancialmente o desempenho de modelos de previsão em mercados financeiros, sobretudo em ativos voláteis.

Outra limitação está relacionada ao horizonte de previsão adotado. O modelo foi treinado para prever a direção do movimento de preço de um único dia à

frente. Embora esse horizonte seja útil para simulações operacionais do tipo Long/Short, ele pode ser sensível a ruídos e flutuações aleatórias. Conforme apontado por Zbikowski (2015), previsões com janelas muito curtas tendem a ser mais instáveis, enquanto janelas maiores podem capturar tendências mais robustas.

Além disso, a pesquisa utilizou uma divisão temporal fixa dos dados (90% treino, 5% teste, 5% validação), sem aplicação de técnicas de validação cruzada com janelas deslizantes (rolling windows), que poderiam aumentar a confiabilidade dos resultados em séries temporais (Bergmeir; Benítez, 2012). A ausência dessa abordagem limita a avaliação da estabilidade do modelo em diferentes períodos do histórico.

Por fim, todos os testes foram realizados com modelos LSTM de arquitetura simples, variando apenas número de camadas e neurônios. Arquiteturas híbridas, como LSTM com convoluções ou mecanismos de atenção, não foram exploradas neste estudo. Segundo Qin *et al.* (2017), essas abordagens podem capturar dependências complexas de forma mais eficaz, especialmente em ambientes não lineares como o mercado de criptomoedas.

Ficam como sugestões para estudos futuros: (i) a inclusão de variáveis técnicas complementares, como indicadores de tendência e volume; (ii) a comparação com outras arquiteturas de redes neurais, como GRU ou Transformers; e (iii) a realização de testes em diferentes janelas temporais e ciclos de mercado, visando avaliar a robustez dos modelos sob cenários mais diversos.

## REFERÊNCIAS

ANTONOPOULOS, A. M. **Mastering Ethereum: Building Smart Contracts and DApps.**

Sebastopol: O'Reilly Media, 2017.

BAO, W.; YOU, S.; ZHANG, C. A deep learning framework for financial time series using stacked autoencoders and long short-term memory. **PLOS ONE**, San Francisco, v. 12, n. 7, 2017. Disponível em: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0180944>. Acesso em: 23 maio 2025.

BERGMEIR, C.; BENÍTEZ, J. M. On the use of cross-validation for time series predictor evaluation. **Information Sciences**, v. 191, p. 192–213, 2012.

BISHOP, C. M. **Pattern recognition and machine learning.** New York: Springer, 2006.

- BUTERIN, V. A next-generation smart contract and decentralized application platform. **Ethereum White Paper**, 2014. Disponível em: <https://ethereum.org/en/whitepaper/>. Acesso em: 23 maio 2025.
- CATALINI, C.; GANS, J. S. Some simple economics of the blockchain. **National Bureau of Economic Research**, Working Paper 22952, 2016. Disponível em: <https://www.nber.org/papers/w22952>. Acesso em: 24 maio 2025.
- CORBET, S.; LUCEY, B.; YAROVAYA, L. Datestamping the Bitcoin and Ethereum bubbles. **Finance Research Letters**, Amsterdam, v. 26, p. 81–88, 2018.
- ETHEREUM FOUNDATION. **Ethereum completes The Merge**. 2022. Disponível em: <https://ethereum.org/en/upgrades/merge/>. Acesso em: 24 maio 2025.
- ETHERSCAN. **Ethereum Charts and Statistics**. 2025. Disponível em: <https://etherscan.io/charts>. Acesso em: 24 maio 2025.
- FISCHER, T.; KRAUSS, C. Deep learning with long short-term memory networks for financial market predictions. **European Journal of Operational Research**, Amsterdam, v. 270, n. 2, p. 654–669, 2018.
- GARCÍA, S.; LUENGO, J.; HERRERA, F. A survey of discretization techniques: Taxonomy and empirical analysis in supervised learning. **IEEE Transactions on Knowledge and Data Engineering**, Piscataway, v. 27, n. 12, p. 2935–2947, 2020.
- GONZÁLEZ-RIVERA, G. Assessing forecast performance in a value-at-risk framework. **Journal of Econometrics**, v. 105, n. 1, p. 171–192, 2001.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep learning**. Cambridge: MIT Press, 2016.
- HEATON, J. B.; POLSON, N. G.; WITTE, J. H. Deep learning in finance. **Annual Review of Financial Economics**, v. 9, p. 145–181, 2017. <https://doi.org/10.1146/annurev-financial-110716-032843>
- HOCHREITER, S. *et al.* Gradient flow in recurrent nets: the difficulty of learning long-term dependencies. In: KÜHN, R. *et al.* (Ed.). **A Field Guide to Dynamical Recurrent Networks**. Cambridge: IEEE Press, 2001.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. **Neural Computation**, Cambridge, v. 9, n. 8, p. 1735–1780, 1997.
- Houben, R.; Snyers, A. **Cryptocurrencies and blockchain: Legal context and implications for financial crime, money laundering and tax evasion**. European Parliament, Policy Department for Economic, Scientific and Quality of Life Policies, 2018. Disponível em: <https://www.europarl.europa.eu>. Acesso em: 24 maio 2025.
- KARA, Y.; BOYACIOGLU, M. A.; BAYKAN, Ö. K. Predicting direction of stock price index movement using artificial neural networks and support vector machines: The sample of the Istanbul Stock Exchange. **Expert Systems with Applications**, v. 38, p. 5311–5319, 2011.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. **International Conference on Learning Representations (ICLR)**, 2015. Disponível em: <https://arxiv.org/abs/1412.6980>. Acesso em: 23 maio 2025.
- LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, v. 521, p. 436–444, 2015. <https://doi.org/10.1038/nature14539>
- MALKIEL, B. G. **A Random Walk Down Wall Street**. 8. ed. New York: W. W. Norton & Company, 2003.
- NAIR, V.; HINTON, G. E. Rectified linear units improve restricted boltzmann machines. In: **Proceedings of the 27th International Conference on Machine Learning (ICML)**. Haifa, Israel, 2010.
- NAKAMOTO, S. Bitcoin: **A peer-to-peer electronic cash system**. 2008. Disponível em: <https://bitcoin.org/bitcoin.pdf>. Acesso em: 24 maio 2025.
- NARAYANAN, A. *et al.* **Bitcoin and cryptocurrency technologies: a comprehensive introduction**. Princeton: Princeton University Press, 2016.
- PATEL, J. *et al.* Predicting stock and stock price index movement using trend deterministic data preparation and machine learning techniques. **Expert Systems with Applications**, v. 42, n. 1, p. 259–268, 2015.
- PETERS GRAF, Junior Mateus. **Aplicando Redes Neurais Artificiais para a Previsão de**

**Tendências de Mercado da Criptomoeda**

- Bitcoin.** 2022. 67 f. Trabalho de Conclusão de Curso (Bacharelado em Engenharia de Software) – Faculdade UNIGUAÇU, São Miguel do Iguaçú, 2022.
- PRECHELT, L. Early stopping — but when? In: **NEURAL NETWORKS: TRICKS OF THE TRADE.** Springer, Berlin, Heidelberg, 1998. p. 55–69.
- QIN, Y. *et al.* A dual-stage attention-based recurrent neural network for time series prediction. In: **Proceedings of the 26th International Joint Conference on Artificial Intelligence (IJCAI).** Melbourne, 2017.
- RUSSELL, S.; NORVIG, P. **Artificial intelligence: a modern approach.** 4. ed. Hoboken: Pearson, 2021.
- SCHÄR, F. Decentralized finance: On blockchain- and smart contract-based financial markets. **Federal Reserve Bank of St. Louis Review**, v. 103, n. 2, p. 153–174, 2021.
- SRIVASTAVA, N. *et al.* Dropout: A simple way to prevent neural networks from overfitting. **Journal of Machine Learning Research**, v. 15, p. 1929–1958, 2014.
- TAPSCOTT, D.; TAPSCOTT, A. **Blockchain revolution: how the technology behind bitcoin is changing money, business, and the world.** New York: Penguin, 2018.
- TSE, Y. K.; XIANG, Y.; WANG, T. A directional accuracy test based on generalized spectrum. **Economics Letters**, v. 109, n. 3, p. 157–160, 2010.
- WERNER, S. M. *et al.* Sok: Decentralized exchanges (DEX) with automated market makers (AMM). **arXiv preprint**, 2021. Disponível em: <https://arxiv.org/abs/2103.12732>. Acesso em: 24 maio 2025.
- WOOD, G. Ethereum: A secure decentralised generalised transaction ledger – Byzantium version. **Ethereum Project Yellow Paper**, 2014. Disponível em: <https://ethereum.github.io/yellowpaper/paper.pdf>. Acesso em: 24 maio 2025.
- YEH, C. H.; HUANG, T. L.; LEE, C. Y. A multiple-kernel support vector regression approach for stock market price forecasting. **Expert Systems with Applications**, Amsterdam, v. 38, p. 2177–2186, 2011.
- ZBIKOWSKI, K. Using volume-weighted support vector machines with walk-forward testing and feature selection for the purpose of creating stock trading strategy. **Expert Systems with Applications**, v. 42, n. 4, p. 1797–1805, 2015.
- ZHANG, G.; EDDY PUI, B.; HU, M. Forecasting with artificial neural networks: The state of the art. **International Journal of Forecasting**, Amsterdam, v. 14, p. 35–62, 1998.