

A influência dos algoritmos de inteligência artificial no mercado de criptoativos

Rayane Correa Moura Lima (UERJ)

rayanelima33763@gmail.com

Daiane Rodrigues dos Santos (UERJ)

daiane.santos@uerj.br

Christiano Arrigoni (UERJ/Ibmec)

christiano.arrigoni@gmail.com

Resumo

O avanço tecnológico do século XXI tem promovido mudanças estruturais no sistema financeiro global. A difusão dos criptoativos, após o surgimento do Bitcoin, deu origem a um mercado digital descentralizado, caracterizado por operações mais acessíveis, contínuas e com ausência de fronteiras. Diante desse cenário, o presente estudo teve como objetivo analisar o desempenho preditivo de algoritmos de inteligência artificial aplicados ao mercado de criptoativos, com foco na previsão de retornos do Bitcoin. Para isso, foi realizada uma análise empírica com dados diários de preços do Bitcoin (BTC) e do Ethereum (ETH), coletados entre janeiro e junho de 2025. Os preços foram transformados em retornos logarítmicos e utilizados na estimação de dois modelos preditivos: um modelo de regressão linear múltipla, utilizado como *benchmark*, e um modelo baseado em aprendizado de máquina por meio do algoritmo *Random Forest*. O desempenho dos modelos foi avaliado por métricas de erro fora da amostra. No experimento empírico os resultados indicaram que o modelo de inteligência artificial apresentou desempenho preditivo superior ao modelo econométrico tradicional. O modelo de IA superou o *benchmark* clássico em todas as métricas, reduzindo o erro quadrático médio (RMSE) em cerca de 19%.

Palavras-Chaves: *Criptoativos, Inteligência Artificial, Volatilidade, Liquidez, Arbitragem.*

1. Introdução

O avanço tecnológico do século XXI vem sendo marcado por uma extensa trajetória, e transformação no sistema financeiro global. A popularização dos criptoativos, com o lançamento da bitcoin em 2009, originou o atual mercado digital descentralizado, negociado de forma assídua e sem fronteiras geográficas (Nakamoto, 2008; Antonopoulos, 2017). Neste cenário, marcado por alta volatilidade, riscos sistêmicos e não sistêmicos, variações de liquidez e oportunidades de arbitragem, surgem, paralelamente, novas ferramentas capacitadas para processar grandes volumes de dados e executar operações em alta velocidade e uma delas são os Algoritmos de inteligência artificial (IA) (Chen; Cheng; Xu, 2021).

A função da inteligência artificial (IA) no mercado de criptoativos abrange, dentre outras, estratégias automatizadas de negociação, baseadas em aprendizado de máquina, como Redes neurais e machine learning e sistemas avançados de *deep learning* e *reinforcement learning* que ajustam decisões em tempo real (He; Liao, 2020; Sekhon; Ghosh, 2022). As tecnologias supramencionadas eram mais presentes nos mercados tradicionais (Alvarez-Díaz et al., 2020), porém, ganharam espaço no universo cripto que se tem alta fragmentação das corretoras (exchanges) e a disponibilidade de dados públicos em grande escala (Borri, 2019; Corbet; Lucey; Yarovaya, 2018).

Essa combinação de acontecimentos cria um cenário, até então, desconhecido e não regulado, no qual a presença de agentes automatizados pode influenciar diretamente a formação de preços, a liquidez dos ativos e a velocidade com que oportunidades de arbitragem são analisadas (Mao; Li, 2020). Destaca-se que entender como esses algoritmos afetam esse ambiente pode ser considerado uma estratégia para investidores, desenvolvedores, reguladores e estudiosos que querem acompanhar as mudanças econômicas e estruturais desse mercado que está mudando rapidamente.

O dinamismo do mercado de criptoativos, caracterizado por sua operação contínua, diferentemente do mercado tradicional, e arquitetura descentralizada, consolidou-se como um ambiente blockchain e passível de implementação de estratégias de negociação automatizadas, com o suporte da inteligência artificial (IA). Em mercados financeiros tradicionais, o uso de algoritmos já é um tema consolidado, que aponta para benefícios claros como o aumento da eficiência, a redução de spreads e a melhoria da liquidez (Alvarez-Díaz; Ferrari; Salas-Fumás,

2020; Hendershott; Jones; Menkveld, 2011). No entanto, o ecossistema cripto pautado em um ambiente blockchain e com atributos distintos, apresenta características que incitam essas decorrências: A alta fragmentação das corretoras (exchanges), a ausência de uma autoridade reguladora central, a maior exposição a choques externos e a sensibilidade a eventos de natureza especulativa (Borri, 2019; Corbet; Lucey; Yarovaya, 2018). Ademais, a literatura empírica sobre a interação entre os algoritmos de IA e esses três fatores no mercado de criptoativos ainda é escassa. Os estudos existentes concentram-se, em sua maioria, em previsões de preço ou negociações isoladas (Sekhon; Ghosh, 2022; Mao; Li, 2020). Há, diante do exposto, uma lacuna na literatura sobre a análise integrada da volatilidade, liquidez e arbitragem como variáveis interdependentes e sensíveis à presença de agentes automatizados.

O presente estudo se explica pela sua relevância acadêmica e prática da influência dos algoritmos de inteligência artificial (IA) no mercado de criptoativos. O tema tem avançado principalmente em aspectos como volatilidade e interdependência de mercados (Dyhrberg, 2016; Corbet *et al.*, 2019), mas ainda há uma lacuna persistente em relação a uma análise integrada da atuação desses algoritmos sobre a volatilidade, a liquidez e a arbitragem.

2. Referencial Teórico

Os criptoativos são uma categoria de ativos digitais que operam em redes blockchain de forma ininterrupta, 24 horas por dia (Nakamoto, 2008; Catalini; Gans, 2016). Esse mundo é bem interativo, com preços subindo e descendo rápido (volatilidade), uma facilidade de comprar e vender toda hora (liquidez) e com a chance de ganhar dinheiro com a diferença de preço entre as plataformas (arbitragem).

A IA funciona nesse mercado para processar dados e negociar de forma automática. Os algoritmos conseguem prever preços e encontrar oportunidades de arbitragem em segundos (Fischer, 2019; Mann, 2025). Entretanto, a literatura especializada evidencia que a aplicação de inteligência artificial (IA) aos mercados financeiros não é isenta de riscos. Diversos estudos apontam que o uso intensivo de algoritmos pode amplificar a volatilidade dos preços dos ativos, gerar uma liquidez artificial (Alexander, 2025), que desaparece em momentos de estresse, e pode reduzir as oportunidades de arbitragem disponíveis para outros agentes de mercado. Ademais, pesquisas recentes documentam a ocorrência de *latency arbitrage*, fenômeno no qual sistemas de alta frequência exploram diferenças mínimas no tempo de execução de ordens entre plataformas, obtendo ganhos informacionais que potencialmente comprometem a equidade e a eficiência do mercado, vide John *et al.* (2024), Ruhanen (2025) e Hautsch *et al.* (2018).

Diante do exposto, reconhece-se que a aplicação de inteligência artificial (IA) aos mercados financeiros apresenta benefícios potenciais, mas o seu impacto efetivo sobre a estabilidade e a eficiência do mercado permanece incerto. Essa incerteza constitui a lacuna de pesquisa que este trabalho se propõe a investigar.

Um criptoativo, que pode ser compreendido como token criptográfico ou criptomoeda, em uma generalização mais simplificada, é um meio alternativo de troca cuja segurança é estabelecida por meio de criptografia, o que é o oposto à confiança em uma autoridade governamental central (Corbet *et al.*, 2019; Nakamoto, 2008). A integridade das transações é assegurada por criptografia assimétrica em um ambiente descentralizado, conhecido também como tecnologia de registro distribuído (*distributed ledger technology*). Grande parte dos criptoativos opera em uma rede descentralizada ponto a ponto (*peer-to-peer*), a qual governa coletivamente a gestão da oferta monetária conforme o protocolo (Corbet *et al.*, 2019). A criação de novas unidades, como no caso do Bitcoin, é baseada em mecanismos de consenso como o *proof-of-work* (Nakamoto, 2008). Porém, outros mecanismos como o *Practical Byzantine Fault Tolerance*, *proof-of-stake* e *proof-of-burn* também são aplicados, todos utilizando algoritmos para alcançar consenso sobre o estado do sistema, em vez de depender de uma autoridade centralizada para validação de transações (Shen; Qu; Chen, 2023). A natureza descentralizada e o uso de um *backbone* criptográfico diferenciam os criptoativos das classes de ativos tradicionais.

Embora todos os tokens criptográficos compartilhem uma base tecnológica descentralizada e criptográfica, seus propósitos são distintos. Essa dessemelhança pode ser categorizada em três tipos principais, cada um com uma finalidade primária bem definida. As criptomoedas, por exemplo, foram concebidas para funcionar como dinheiro, servindo como meio de troca, unidade de conta e reserva de valor (Corbet *et al.*, 2019).

No entanto, os tokens foram projetados para representar um bem ou serviço específico, sendo necessários para a execução de contratos inteligentes (*smart contracts*). O Ether, token da plataforma Ethereum, exerce essa função ao servir como base para a operação de aplicações descentralizadas.


2.1 Inteligência Artificial e Aprendizado de Máquinas Aplicados a Finanças

A Inteligência Artificial (IA), por meio de técnicas de Machine Learning (ML) e *Deep Learning* (DL), tem emergido como uma ferramenta para mitigar os desafios de previsão de retornos em mercados financeiros, com aplicação crítica no ecossistema de criptoativos. O interesse é motivado pela observação de que a volatilidade e as flutuações de preços não

estacionários dos criptoativos tornam os métodos estatísticos tradicionais, como ARIMA e GARCH, insuficientes (Bouteska *et al.*, 2023).

O Aprendizado de Máquina (ML) e o Aprendizado Profundo (DL) são adequados para o mercado cripto devido à sua capacidade de extrair padrões não lineares de séries temporais complexas, que exibem *clustering* de volatilidade, dependência de longo alcance e distribuições de cauda pesada. A pesquisa tem se concentrado em comparar diferentes arquiteturas de redes neurais, como LSTM (*Long Short-Term Memory*), CNNs (*Convolutional Neural Networks*) e Transformers, com modelos tradicionais, demonstrando a superioridade dos métodos de DL. Em particular, a aplicação de modelos avançados em ativos como Bitcoin e Ethereum tem consistentemente demonstrado que as arquiteturas de *deep learning* superam os métodos econométricos clássicos na acurácia das previsões (Bouteska *et al.*, 2023).


Figura 1– Esquema detalhado da unidade de Long Short-Term Memory (LSTM)



Fonte: Tavares (2024, p. 4)

O avanço da modelagem de DL se manifesta em arquiteturas como as Redes Neurais Recorrentes (RNNs), projetadas para capturar dependências de longo prazo. A comparação entre *ensemble learning* e *deep learning*, validou a eficácia de modelos como LSTM e GRU (*Gated Recurrent Unit*). O GRU, por requerer menos parâmetros computacionais, demonstrou ser particularmente eficaz, superando o LSTM em algumas séries temporais. Além disso, o LightGBM, um método de ensemble learning baseado em boosting, se mostrou o melhor modelo preditivo para Bitcoin, Ethereum e Litecoin (Bouteska *et al.*, 2023).

Figura 2 – Esquema detalhado da Unidade Recorrente com Portas (GRU)



Fonte: Tavares (2024, p. 5)

Apesar da superioridade em acurácia, os modelos complexos de DL sofrem com o problema da 'caixa preta', dificultando a explicação e a confirmação das previsões. Em resposta a essa limitação, propuseram um framework de Inteligência Artificial Explicável (XAI) para a previsão de preços do Bitcoin, visando melhorar a transparência. O estudo utilizou um novo algoritmo, FS-SHAP (Feature Selection-SHAP), que integra a seleção de features baseada na teoria dos jogos (SHAP) com o modelo Extra Trees (ET). Esta abordagem demonstrou um alto desempenho na previsão multivariada, alcançando um R^2 *Out-of-Sample* (ROOS²) de 0,689 com o modelo LSTM baseado em FS-SHAP, contrastando drasticamente com o modelo OLS, cuja eficiência foi drasticamente reduzida (ROOS² caindo em território negativo) (Goodell *et al.*, 2023).

2.2 Inteligência Artificial Aplicada no Mercado de Criptoativos

O impacto dos algoritmos de inteligência artificial (IA) no ecossistema de criptoativos manifesta-se em um ciclo completo de valor que se inicia na precisão preditiva de alta frequência e culmina na otimização dinâmica da alocação de portfólio, com reflexos diretos na liquidez, na volatilidade e nas oportunidades de arbitragem.

A base desse ciclo está na geração de sinais preditivos com alta granularidade. Para previsões de 1 a 4 horas, a arquitetura *Gated Recurrent Unit* (GRU) destacou-se como o modelo de melhor desempenho ao lidar com a alta volatilidade dos dados em nível de minuto, alcançando um MAPE de 0,09% para o Bitcoin em previsões de 60 minutos, o que evidencia a eficiência de seus mecanismos de *gating* na filtragem de ruídos (Rodrigues; Machado, 2025). Em paralelo, o modelo LightGBM foi classificado como o melhor preditor para Bitcoin, Ethereum e Litecoin,

com Acurácia Direcional Média (MDA) entre 67,5% e 75,1%, fornecendo o sinal robusto necessário para a execução algorítmica (Bouteska *et al.*, 2023).

A partir desses sinais preditivos, a IA atua na microestrutura de mercado em duas frentes interconectadas. A primeira refere-se à exploração de ineficiências, uma vez que a arbitragem é considerada uma das estratégias sistemáticas fundamentais (Fang *et al.*, 2023). Nesse contexto, a arbitragem estatística entre Exchanges Centralizadas (CEXs) e Descentralizadas (DEXs) requer que a estratégia de negociação ideal combine liquidação de inventário e arbitragem especulativa, sendo otimizada conforme a profundidade do *pool* e os custos de convexidade, o que revela a sofisticação das operações algorítmicas nesse mercado (Cartea; Drissi; Monga, 2023). A segunda frente é a otimização da liquidez estrutural, impulsionada pelo avanço de arquiteturas de *Automated Market Makers* (AMMs) preditivos baseados em *Deep Reinforcement Learning* (DRL). Essa abordagem aumentou a utilização de liquidez de 56% para 93% e permitiu a execução de ordens 100 vezes maiores com impacto mínimo no preço, aprimorando diretamente a eficiência do mercado (Lim, 2023).

2.3 Modelagem e Previsão de Preços

A modelagem da série temporal de preços de criptoativos requer uma abordagem capaz de reconhecer e superar as limitações dos modelos econométricos tradicionais, como *Autoregressive Integrated Moving Average* (ARIMA) e *Generalized Autoregressive Conditional Heteroskedasticity* (GARCH), cujas premissas de linearidade e normalidade são violadas pela natureza não gaussiana e de caudas pesadas dos retornos de criptoativos (Gupta; Chaudhary, 2022). Em resposta a essa complexidade, a metodologia empírica do presente estudo adota modelos de *Deep Learning* (DL) e *Ensemble Learning*, aptos a capturar a não linearidade e a alta dimensionalidade dos dados que caracterizam a volatilidade persistente desse mercado.

A literatura demonstra de forma consistente a superioridade dos modelos não lineares. O uso do eXtreme Gradient Boosting (XGB) foi validado como o método mais eficaz entre diversos concorrentes de Machine Learning, alcançando acurácia preditiva (R^2 *out-of-sample*) de 4,855% ao analisar 3.703 criptomonedas entre 2013 e 2021. Esse modelo não linear, baseado em árvores e que utiliza gradientes de segunda ordem, demonstrou elevada capacidade de capturar interações e padrões complexos nos dados (Liu *et al.*, 2024).

A arquitetura *Long Short-Term Memory* (LSTM) é adotada neste estudo como base para a previsão de retornos. Trata-se de uma variante das *Recurrent Neural Networks* (RNNs), que se

destaca por mitigar o problema do *vanishing gradient*, sendo particularmente eficaz na modelagem de séries temporais financeiras devido à sua habilidade em capturar dependências de longo alcance e o *clustering* de volatilidade típico do mercado de criptoativos (Bouteska *et al.*, 2023). A eficácia do LSTM é potencializada por técnicas avançadas de pré-processamento. Nesse sentido, propõe-se o uso de um método híbrido que combina *Discrete Wavelet Transform* (DWT) com a função mãe bior3.1 e redes LSTM, a fim de remover ruídos e suavizar sinais de alta volatilidade antes da modelagem (Antunes; Milhomem; Dantas, 2022).

A eficiência do LSTM é ampliada por meio de uma abordagem de previsão multivariada, na qual o modelo integra variáveis de mercado e fatores externos (features). Entre os preditores, o retorno defasado de um dia (Previous 1-Day Return – P1DR) destaca-se como a feature mais relevante, apresentando maior poder explicativo que o conjunto das demais variáveis. Esse resultado indica que o mercado de criptoativos não é eficiente em sua forma fraca, pois há previsibilidade nos retornos (Liu *et al.*, 2024). Além disso, observa-se uma relação convexa entre risco (desvio-padrão) e retorno, indicando que criptoativos mais arriscados, geralmente de menor capitalização, tendem a apresentar retornos futuros mais elevados, refletindo uma estrutura de compensação de risco típica de mercados emergentes.

O processo de modelagem e previsão de preços é estruturado para incorporar esses achados. Os dados brutos de preços e volumes (BTC, ETH, entre outros) são transformados em log-retornos diários (R_t), e o modelo preditivo inclui indicadores de mercado e fatores macroeconômicos com comprovado poder explicativo. A inclusão de variáveis como Risco Geopolítico (GPR) e Taxa de Expectativa de Inflação (YIFR) é importante para identificar pontos críticos de inflexão e aprimorar a interpretabilidade das previsões, sendo o método SHAP (*Shapley Additive Explanations*) empregado para quantificar a contribuição de cada variável (Goodell *et al.*, 2023).

A arquitetura LSTM é treinada em uma configuração de janela deslizante (rolling window), conforme ilustrado na Figura 1, simulando um ambiente de negociação em tempo real. O desempenho é validado por meio de métricas como *Root Mean Square Error* (RMSE) e *Mean Directional Accuracy* (MDA) (Goodell *et al.*, 2023). A combinação entre arquiteturas de *Deep Learning* e uma metodologia de validação rigorosa permite testar a hipótese central desta pesquisa: a de que modelos de inteligência artificial (IA) podem aprimorar a previsão de

retornos em relação aos métodos convencionais, contribuindo para decisões de investimento mais robustas e mitigando os riscos inerentes à alta volatilidade do mercado de criptoativos.

3. Metodologia

A presente pesquisa adotou uma abordagem quantitativa e empírica com o objetivo de avaliar o desempenho preditivo de algoritmos de inteligência artificial aplicados ao mercado de criptoativos. O desenho metodológico combinou técnicas de análise de séries temporais financeiras e métodos de aprendizado de máquina e por fim uma comparação com uma abordagem econométrica tradicional.

A análise empírica conduzida neste estudo baseia-se na previsão do retorno diário do Bitcoin (BTC) a partir de informações contemporâneas e defasadas extraídas do mercado de criptoativos. O objetivo central é comparar o desempenho preditivo de duas abordagens sob a mesma base de dados e horizonte temporal: (i) um modelo tradicional de regressão linear múltipla (o *benchmark*), e (ii) um modelo não paramétrico baseado em *Random Forest* (RF), representando a técnica de Inteligência Artificial (IA) adotada. Esta comparação visa avaliar a capacidade incremental da modelagem não linear em relação à metodologia econométrica clássica.

A base de dados foi composta pelos preços de fechamento do Bitcoin (BTC-USD) e do Ethereum (ETH-USD), coletados diariamente entre 1º de janeiro e 1º de junho de 2025. Os preços foram transformados em retornos logarítmicos diários, de modo a estabilizar a variância e aproximar a distribuição dos retornos de uma estrutura compatível com processos estacionários (Tsay, 2010; Campbell; Lo; MacKinlay, 1997).

A amostra foi dividida de forma temporal em 70% para treinamento e 30% para teste, preservando a ordem cronológica e garantindo que o modelo fosse avaliado em um conjunto verdadeiramente fora da amostra (*out-of-sample*), conforme recomendado em contextos de previsão de séries temporais (Hyndman; Athanasopoulos, 2018).

A base supervisionada para previsão univariada foi estruturada formalmente como: $y_t = \text{BTC}_t$, $X_t = [\text{ETH}_t, \text{BTC}_{t-1}]$. A variável dependente corresponde ao retorno do Bitcoin no período t BTC_t , e as variáveis explicativas X_t são definidas como: (i) o retorno contemporâneo do Ethereum, escolhido por sua relevância na estrutura de comovimentos do mercado de criptoativos; e (ii) o retorno defasado do Bitcoin em $t-1$, utilizado como mecanismo de captura de persistência temporal (Tsay, 2010; Brooks, 2019).

Como linha de base (*benchmark*), estimou-se um modelo de regressão linear múltipla, supondo relação linear e paramétrica entre as variáveis. A regressão linear permite avaliar se a incorporação de métodos capazes de capturar não linearidades gera ganhos efetivos de precisão (Wooldridge, 2020). Na etapa de Inteligência Artificial, aplicou-se o método de Random Forest (RF) proposto por Breiman (2001), um algoritmo de aprendizagem supervisionada baseado na agregação (*bagging*) de múltiplas árvores de decisão. O RF é particularmente adequado para problemas financeiros devido à sua capacidade de modelar relações complexas e não lineares, à robustez a ruído e à menor sensibilidade a outliers (Krauss, Do; Huck, 2017). O modelo foi especificado com 1.000 árvores ($n_{tree} = 1000$) e $m_{try} = 1$, aumentando a diversidade entre as árvores, propriedade chave para melhorar o desempenho preditivo do ensemble (Breiman, 2001).


A comparação entre os modelos foi realizada exclusivamente sobre o conjunto de teste e baseada em quatro métricas: Erro Quadrático Médio (MSE), Raiz do Erro Quadrático Médio (RMSE), Erro Absoluto Médio (MAE) e Erro Percentual Absoluto Médio (MAPE) (Hyndman; Athanasopoulos, 2018).

4. Resultados e Discussão

A análise empírica foi conduzida com o objetivo de comparar a performance preditiva de um modelo linear (*benchmark*) e um modelo não linear de Inteligência Artificial (Random Forest), utilizando os retornos logarítmicos do Bitcoin (BTC) e do Ethereum (ETH) no período de janeiro a junho de 2025.

A série de retornos logarítmicos diários do Bitcoin (BTC), no período de janeiro a junho de 2025, como pode ser visto na Figura 3, revelou um comportamento típico de ativos financeiros de alta volatilidade, caracterizado por flutuações intensas ao redor de uma média próxima de zero e volatilidade. Observa-se a presença de movimentos abruptos, tanto positivos quanto negativos, que sugerem episódios recorrentes de choques de mercado, consistentes com o padrão de *clustering* de volatilidade frequentemente documentado na literatura de criptoativos.

Figura 3 – Evolução do Retorno Logarítmico Diário do Bitcoin (BTC) – Jan/25 a Jun/25



Fonte: Elaboração própria (2025)

O desempenho dos modelos, avaliado exclusivamente no conjunto de teste (*out-of-sample*), demonstrou uma superioridade consistente e significativa do algoritmo de ensemble learning (*Random Forest*) sobre a Regressão Linear, como pode ser analisado na Tabela 1.

Tabela 1 - Erros de previsão do modelo


Métrica	Regressão Linear	Random Forest	Melhor Modelo
MSE	2,64E+02	1,73E+02	Random Forest
RMSE	1,63E+04	1,32E+04	Random Forest
MAE	1,19E+04	1,07E+04	Random Forest
MAPE	2,08E+08	1,89E+08	Random Forest

Fonte: Elaboração própria (2025)

Em todas as quatro métricas avaliadas (MSE, RMSE, MAE e MAPE), o modelo Random Forest (RF) superou o *benchmark* linear. O MSE, que penaliza erros maiores, foi significativamente menor para o RF 1,730001e-04, indicando que o modelo de IA consegue reduzir as maiores discrepâncias entre a previsão e o retorno real do BTC.

A Figura 4 ilustra graficamente o desempenho no conjunto de teste. É evidente que as linhas de previsão do *Random Forest* e da Regressão Linear tentam seguir o Retorno Real do BTC, mas o modelo não linear (RF) demonstra uma capacidade sutilmente melhor de capturar os picos e vales do retorno, o que se reflete na redução dos erros.

Figura 4 – Desempenho Preditivo Out-of-Sample do Bitcoin: Random Forest vs Regressão Linear.



Fonte: Elaboração própria (2025)

Os resultados empíricos obtidos nesta pesquisa permitem validar a hipótese central da monografia: modelos não lineares baseados em Inteligência Artificial apresentam desempenho preditivo superior aos métodos econométricos tradicionais. O desempenho consistentemente superior do modelo Random Forest em todas as métricas analisadas, incluindo o menor erro quadrático médio (MSE), fornece indícios robustos contra a validade da Hipótese dos Mercados Eficientes (EMH) em sua forma fraca. Caso o mercado fosse plenamente eficiente, variáveis construídas a partir de informações históricas, como BTC_{t-1} e ETH_t , não deveriam apresentar qualquer capacidade preditiva sobre retornos futuros.

A superioridade do Random Forest em relação à Regressão Linear também fortalece a justificativa para o uso de algoritmos de Inteligência Artificial. Enquanto a Regressão Linear impõe uma relação funcional fixa, do tipo $BTC_t = \beta_0 + \beta_1 \cdot ETH_t + \beta_2 \cdot BTC_{t-1}$, o Random Forest, por ser um ensemble de árvores de decisão, consegue capturar interações complexas, efeitos não lineares e mudanças de regime sem pressupor a forma estrutural da relação entre as variáveis. Essa capacidade é particularmente relevante em mercados altamente voláteis e caracterizados por distribuições de retornos com caudas pesadas, conforme discutido por Krauss, Do e Huck (2017). Desse modo, a superioridade dos modelos não lineares observada nos experimentos reforça a literatura que aponta limitações de métodos lineares tradicionais nesse tipo de ambiente.

Além disso, a melhoria preditiva verificada possui implicações práticas importantes. A redução do erro (RMSE) em aproximadamente 19%, de 1,62% para 1,31%, representa não apenas um ganho estatístico, mas um benefício economicamente significativo para a aplicação em estratégias quantitativas. A maior precisão do modelo fornece uma base mais sólida para a execução de estratégias de arbitragem, ao permitir a identificação mais eficiente de ineficiências de preço, conforme abordado por Cartea, Drissi e Monga (2023). Simultaneamente, resultados mais robustos permitem alimentar modelos avançados de gestão e otimização de portfólio, incluindo abordagens baseadas em *Reinforcement Learning* e metodologias que dependem de previsões de risco e retorno, como as discutidas em Ferreira (2025) e em Soares e Canuto (2024).

5. Considerações Finais

Os resultados empíricos obtidos permitiram rejeitar a Hipótese do Mercado Eficiente (EMH) em sua forma fraca, indicando que o mercado de criptoativos apresenta regularidades estatísticas exploráveis mesmo sob uso exclusivo de informações históricas. Observou-se a superioridade preditiva do algoritmo Random Forest em relação à Regressão Linear, evidenciada por um Erro Quadrático Médio (MSE) significativamente menor, o que sugere a presença de não linearidades e interações complexas entre os retornos do Bitcoin e do Ethereum. Esse resultado está alinhado ao avanço recente da literatura, que identifica o retorno defasado de um dia (P1DR) como uma das variáveis preditivas mais relevantes (Liu et al., 2024), reforçando o argumento de que modelos baseados em IA capturam dimensões da dinâmica cripto que modelos lineares não conseguem.

Em termos práticos, os ganhos preditivos obtidos pelos modelos de IA possuem implicações diretas sobre estratégias de arbitragem, alocação e provisão de liquidez. No âmbito da microestrutura de mercado, verificou-se que o Random Forest gera um resultado que pode ser utilizado para estratégias de arbitragem estatística que exploram a fragmentação entre exchanges centralizadas (CEXs) e descentralizadas (DEXs), conforme discutido por Cartea, Drissi e Monga (2023). Adicionalmente, estudos recentes mostram que abordagens de Deep Reinforcement Learning podem otimizar a alocação de liquidez em mecanismos automáticos de market making (AMMs), reduzindo o slippage (deslizamento de preço) e ampliando a eficiência operacional (LIM, 2023).

Apesar dos resultados positivos, persistem desafios relevantes que orientam a agenda de pesquisa futura. Destaca-se, em primeiro lugar, o desempenho limitado dos algoritmos de *Reinforcement Learning* em cenários de baixa liquidez e em *bear markets*, como apontado por Ferreira (2025), o que demanda arquiteturas que incorporem custos de transação, restrições de liquidez e heterogeneidade comportamental. Ademais, a ausência de mecanismos transparentes de interpretação dos modelos recai sobre um problema emergente: a necessidade de intensificar o uso de ferramentas de inteligência artificial explicável (XAI), como o framework SHAP, para quantificar o protagonismo de variáveis macroeconômicas e geopolíticas na formação de preços, conforme argumentado por Goodell *et al.* (2023).

REFERÊNCIAS

- ALEXANDER, Anthony. **Latency arbitrage in cryptocurrency markets: analyzing execution speeds & liquidity dynamics**. SSRN, 7 fev. 2025. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5143158. Acesso em: 9 set. 2025.
- ANTUNES, Willian; MILHOMEM, Danilo; DANTAS, Maria. **Uso de redes neurais recorrentes para previsão de tendências em séries temporais de criptomoedas**. Open Science Research X, v. 10, p. 709–719, 2023. Disponível em: <https://downloads.editoracientifica.com.br/articles/23011845.pdf>. Acesso em: 5 nov. 2025.
- ARNER Douglas, AUER Raphael e FROST Jon. **STABLECOINS: risks, potential and regulation**. Basel: BIS Working Papers, n. 905, 2020. Disponível em: <https://www.bis.org/publ/work905.htm>. Acesso em: 9 out. 2025.
- BOUTESKA, Mohamed et al. **Cryptocurrency price forecasting – a comparative analysis of ensemble learning and deep learning methods**. International Review of Financial Analysis, art. 103055, 2023. DOI: 10.1016/j.irfa.2023.103055. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1057521923005719>. Acesso em: 5 nov. 2025.
- BREIMAN, Leo. **Random forests**. Machine Learning, v. 45, n. 1, p. 5–32, 2001. DOI: 10.1023/A:1010933404324. Disponível em: <https://link.springer.com/article/10.1023/A:1010933404324>. Acesso em: 12 nov. 2025.
- BROOKS, Chris. **Introductory econometrics for finance**. 4. ed. Cambridge: Cambridge University Press, 2019. Disponível em: https://assets.cambridge.org/97811084/22536/frontmatter/9781108422536_frontmatter.pdf. Acesso em: 16 nov. 2025.
- CAMPBELL, John Y. et al. **The econometrics of financial markets**. Princeton: Princeton University Press, 1997. Disponível em: <https://doi.org/10.2307/j.ctt7skm5>. Acesso em: 16 nov. 2025.
- CARTEA, Álvaro; DRISSI, Fayçal; MONGA, Marcello. **Decentralised finance and automated market making: execution and speculation**. Journal of Economic Dynamics and Control, v. 177, art. 105134, 2025. Disponível em: <https://www.sciencedirect.com/science/article/pii/S0165188925001009>. Acesso em: 22 set. 2025.
- COINMARKETCAP. **Gráfico de participação de mercado do Bitcoin e Ethereum**. Disponível em: <https://coinmarketcap.com/charts/bitcoin-dominance/>. Acesso em: 30 set. 2025.
- COINMETRICS. **State of the network**. 2025. Disponível em: <https://coinmetrics.io/>. Acesso em: 9 out. 2025.
- DYHRBERG, Anne Haubo. **Bitcoin, gold and the dollar – a GARCH volatility analysis**. Finance Research Letters, v. 16, p. 85–92, 2016. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S1544612315001038>. Acesso em: 9 set. 2025.



FANG, Fang et al. **Cryptocurrency trading: a comprehensive survey**. Financial Innovation, v. 8, n. 13, 2022. DOI: 10.1186/s40854-021-00321-6. Disponível em: <https://jfin-swufe.springeropen.com/counter/pdf/10.1186/s40854-021-00321-6.pdf>. Acesso em: 5 nov. 2025.

FERREIRA, Vitor Augusto. **Otimização de portfólio em criptoativos utilizando machine learning**. 2025. Trabalho de Conclusão de Curso (Graduação em Economia) — Universidade Federal de Santa Catarina, Centro Socioeconômico, Florianópolis, 2025. Disponível em: <https://repositorio.ufsc.br/handle/123456789/263821>. Acesso em: 5 nov. 2025.

FINANCIAL **stability risks from cryptoassets in emerging market economies**. Basel: BIS Papers, n. 138, 2023. Disponível em: <https://www.bis.org/publ/bppdf/bispap138.htm>. Acesso em: 9 out. 2025.

FISCHER, Thomas G.; KRAUSS, Christopher; DEINERT, Andreas. **Statistical arbitrage in cryptocurrency markets**. Journal of Risk and Financial Management, v. 12, n. 1, art. 31, 2019. Disponível em: <https://www.mdpi.com/1911-8074/12/1/31>. Acesso em: 9 set. 2025.

GOODELL, John W. et al. **Explainable artificial intelligence modeling to forecast bitcoin prices**. International Review of Financial Analysis, art. 102702, 2023. DOI: 10.1016/j.irfa.2023.102702. Disponível em: <https://www.sciencedirect.com/science/article/pii/S1057521923002181>. Acesso em: 5 nov. 2025.

GUPTA, Himanshu; CHAUDHARY, Ritesh. **An empirical study of volatility in cryptocurrency market**. Journal of Risk and Financial Management, v. 15, n. 11, art. 513, 2022. DOI: 10.3390/jrfm15110513. Disponível em: <https://www.mdpi.com/1911-8074/15/11/513>. Acesso em: 9 out. 2025.

HYNDMAN, Rob J.; ATHANASOPOULOS, George. **Forecasting: principles and practice**. 2. ed. [S.l.]: OTexts, 2018. Disponível em: <https://otexts.com/fpp2/>. Acesso em: 16 nov. 2025.

KRAUSS, Christopher; DO, Xuan Anh; HUCK, Nicolas. **Deep neural networks, gradient-boosted trees, random forests: statistical arbitrage on the S&P 500**. European Journal of Operational Research, v. 259, n. 2, p. 689–702, jun. 2017. DOI: 10.1016/j.ejor.2016.10.031. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0377221716308657>. Acesso em: 16 nov. 2025.

LIM, Tristan. **Predictive crypto-asset automated market maker architecture for decentralized finance using deep reinforcement learning**. Financial Innovation, v. 10, art. 144, 2024. Disponível em: <https://jfin-swufe.springeropen.com/articles/10.1186/s40854-024-00660-0>. Acesso em: 22 set. 2025.

LIU, Yiyang et al. **Forecasting cryptocurrency returns with machine learning**. Research in International Business and Finance, v. 65, art. 101905, 2023. DOI: 10.1016/j.ribaf.2023.101905. Disponível em: <https://www.sciencedirect.com/science/article/abs/pii/S0275531923000314>. Acesso em: 5 nov. 2025.

MANN, William. **Quantitative alpha in crypto markets: a systematic review**. SSRN, 2025. Disponível em: https://papers.ssrn.com/sol3/papers.cfm?abstract_id=5225612. Acesso em: 9 set. 2025.

NAKAMOTO, Satoshi. **Bitcoin: a peer-to-peer electronic cash system**. 2008. Disponível em: <https://bitcoin.org/bitcoin.pdf>. Acesso em: 3 set. 2025.

OLIVEIRA, Douglas de. **Desenvolvimento de modelo de inteligência artificial aplicado a day trading com criptoativos baseado em double deep Q-learning**. 2023. 104 f. Dissertação (Mestrado em Ciência da Computação e Tecnologia) — Universidade Federal Fluminense, Escola de Engenharia, Volta Redonda, 2023. Disponível em: <http://mcct.uff.br/wp-content/uploads/sites/454/2024/07/Dissertacao-Douglas-de-Olvieira-defendeu-em-23-11-2023.pdf>. Acesso em: 5 nov. 2025.

RODRIGUES, Fernando; MACHADO, Matheus. **High-frequency cryptocurrency price forecasting using machine learning models: a comparative study**. Information, v. 16, n. 4, art. 300, 2025. DOI: 10.3390/info16040300. Disponível em: <https://www.mdpi.com/2078-2489/16/4/300>. Acesso em: 5 nov. 2025.

SHEN, Zhiguang; QU, Qiang; CHEN, Xiaobin. **Blockchain consensus mechanisms: a comprehensive review and performance analysis framework**. Electronics, v. 12, n. 17, art. 3567, 2023. Disponível em: <https://www.mdpi.com/2079-9292/12/17/3567>. Acesso em: 22 set. 2025.



SOARES, Rodrigo; CANUTO, Sergio D. C. **Criando portfólios de alto desempenho: otimização de portfólios de ativos de alta volatilidade através da previsão de retorno baseada em CNN+BiLSTM.** In: SIMPÓSIO BRASILEIRO DE BANCO DE DADOS (SBBB), 40., 2025, Fortaleza. Anais [...]. Porto Alegre: SBC, 2025. p. 685–698. DOI: 10.5753/sbbd.2025.247441. Disponível em: <https://sol.sbc.org.br/index.php/sbbd/article/view/37274>. Acesso em: 5 nov. 2025.

TAVARES, Ramon Lima de Oliveira. **Redes neurais com LSTM e GRU na modelagem de focos ativos na Amazônia.** arXiv:2409.02681v2 [cs.LG], 2024. Disponível em: <https://arxiv.org/pdf/2409.02681v2>. Acesso em: 5 nov. 2025.

TSAY, Ruey. **Analysis of financial time series.** New York: Wiley, 2010.

WOOLDRIDGE, Jeffrey. **Introductory econometrics: a modern approach.** Boston: Cengage, 2020.