

CENTRO FEDERAL DE EDUCAÇÃO TECNOLÓGICA DE MINAS GERAIS
CURSO DE ENGENHARIA DE COMPUTAÇÃO

VINÍCIUS LIMA FERNANDES

USO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA NA PREVISÃO DE
ATIVOS FINANCEIROS UTILIZANDO INDICADORES TÉCNICOS:

Avaliação de modelos preditivos em séries temporais financeiras

Leopoldina

2026

VINÍCIUS LIMA FERNANDES

**USO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA NA PREVISÃO DE
ATIVOS FINANCEIROS UTILIZANDO INDICADORES TÉCNICOS:**

Avaliação de modelos preditivos em séries temporais financeiras

Trabalho de Conclusão de Curso apresentado ao Curso de Engenharia de Computação do Centro Federal de Educação Tecnológica de Minas Gerais, do Campus Leopoldina, como parte do requisito para obtenção do título de Bacharel em Engenharia de Computação.

Orientador: Samuel da Costa Alves Basílio

Coorientador: Fernando Garcia Diniz Campos
Ferreira

Leopoldina

2026

Fernandes, Vinícius Lima.

F363u Uso de algoritmos de aprendizado de máquina na previsão de ativos financeiros técnicos: avaliação de modelos preditivos em séries temporais financeiras. / Vinícius Lima Fernandes. – 2026.
68 f. : il., gráfs.

Orientador: Samuel da Costa Alves Basílio.
Coorientador: Fernando Garcia Diniz Campos.
Bibliografia: f. 50-53.

Trabalho de Conclusão de Curso (Graduação) - Centro Federal de Educação Tecnológica de Minas Gerais, *Campus* Leopoldina, apresentada ao curso de Engenharia de Computação. Departamento de Computação, 2026.

1. Inteligência artificial. 2. Aprendizado computacional. 3. Indicadores. 4. Análise de séries temporais. 5. Dinheiro digital. I. Basílio, Samuel da Costa Alves. II. Campos, Fernando Garcia Diniz. III. Título.

CDU: 004.8

Elaboração da ficha catalográfica pela bibliotecária Luzia Adriana Damasceno,
CRB 6º - 2305 / CEFET-MG *campus* Leopoldina.

VINÍCIUS LIMA FERNANDES

**USO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA NA PREVISÃO DE
ATIVOS FINANCEIROS UTILIZANDO INDICADORES TÉCNICOS : Avaliação de
modelos preditivos em séries temporais financeiras**

Trabalho de conclusão de curso apresentado ao
Curso de Engenharia de Computação do Centro
Federal de Educação Tecnológica de Minas
Gerais, do Campus Leopoldina, como parte do
requisito para obtenção do título de Bacharel em
Engenharia de Computação.

Aprovado em: 19 de junho de 2026

Rocha Examinadora:
Documento assinado digitalmente
 **SAMUEL DA COSTA ALVES BASILIO**
Data: 30/06/2026 13:40:06-0300
Verifique em <https://validar.iti.gov.br>

Dr. Samuel da Costa Alves Basílio- Orientador

CEFET-MG

Documento assinado digitalmente
 **FERNANDO GARCIA DINIZ CAMPOS FERREIRA**
Data: 02/07/2026 12:41:51-0300
Verifique em <https://validar.iti.gov.br>

Dr. Fernando Garcia Diniz Campos Ferreira- Coorientador

CEFET-MG

Documento assinado digitalmente
 **JOSE EDUARDO HENRIQUES DA SILVA**
Data: 02/07/2026 12:53:08-0300
Verifique em <https://validar.iti.gov.br>

Dr. José Eduardo Henriques da Silva

CEFET-MG

Msc. Luan Soares Oliveira

CEFET-MG

Documento assinado digitalmente
 **LUAN SOARES OLIVEIRA**
Data: 03/07/2026 08:53:38-0300
Verifique em <https://validar.iti.gov.br>

(Assinaturas Digitais)

Leopoldina

2026

USO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA NA PREVISÃO DE ATIVOS FINANCEIROS UTILIZANDO INDICADORES TÉCNICOS: Avaliação de modelos preditivos em séries temporais financeiras

Vinícius Lima Fernandes

Samuel da Costa Alves Basílio

Fernando Garcia Diniz Campos Ferreira

RESUMO

Prever o comportamento de um ativo no mercado financeiro é uma tarefa complexa, uma vez que seu valor é determinado pela combinação de diversos fatores, como condições econômicas, políticas, emocionais e até mesmo comportamentais dos agentes de mercado. Nesse contexto, as criptomoedas representam ativos com características distintas dos mercados tradicionais, como alta volatilidade e ausência de regulação centralizada, o que torna a previsão de sua tendência ainda mais desafiadora. Este trabalho tem como objetivo avaliar o desempenho de diferentes algoritmos de aprendizado de máquina na previsão de tendências de criptomoedas com características distintas de mercado, verificando como essas características influenciam na eficácia dos modelos. Para isso, foram utilizados os modelos *Random Forest* (RF), *K-Nearest Neighbors* (KNN) e *Long Short-Term Memory* (LSTM), aplicados ao Bitcoin (BTC), Ethereum (ETH) e Cardano (ADA), representando respectivamente um ativo de referência, um cenário de maior estabilidade e um cenário de maior volatilidade. Os indicadores técnicos foram utilizados como entrada para os modelos, com foco na métrica de Precisão como critério principal de avaliação. Cada modelo foi executado por trinta simulações independentes, permitindo a análise estatística. O ETH, representando o cenário mais estável, apresentou os piores resultados de precisão, com modelos próximos ao limiar aleatório de 50%. O ADA, representando o cenário mais volátil, produziu os melhores retornos financeiros. O LSTM foi o único modelo a superar significativamente o *buy and hold* nos três ativos simultaneamente, demonstrando maior capacidade de generalização entre diferentes cenários de mercado.

Palavras-chave: Aprendizado de Máquina. Indicadores Técnicos. Previsão de Tendência. Criptomoedas.

**USE OF MACHINE LEARNING ALGORITHMS IN FINANCIAL ASSET
PREDICTION USING TECHNICAL INDICATORS:** Evaluation of predictive models in
financial time series

Vinícius Lima Fernandes

Samuel da Costa Alves Basílio

Fernando Garcia Diniz Campos Ferreira

ABSTRACT

Predicting the behavior of a financial asset is a complex task, since its value is determined by a combination of diverse factors, such as economic, political, emotional, and even behavioral conditions of market agents. In this context, cryptocurrencies represent assets with distinct characteristics from traditional financial markets, such as high volatility and the absence of centralized regulation, which makes predicting their trends even more challenging. This work aims to evaluate the performance of different machine learning algorithms in predicting cryptocurrency trends with distinct market characteristics, verifying how these characteristics influence the effectiveness of the models. For this purpose, the *Random Forest* (RF), *K-Nearest Neighbors* (KNN), and *Long Short-Term Memory* (LSTM) models were applied to Bitcoin (BTC), Ethereum (ETH), and Cardano (ADA), representing respectively a reference asset, a more stable scenario, and a more volatile scenario. Technical indicators were used as model inputs, with Precision as the main evaluation metric. Each model was executed over thirty independent simulations, enabling statistical analysis. ETH, representing the most stable scenario, presented the worst precision results, with models close to the random threshold of 50%. ADA, representing the most volatile scenario, produced the best financial returns. LSTM was the only model to significantly outperform the *buy and hold* strategy across all three assets simultaneously, demonstrating greater generalization capacity across different market scenarios.

Keywords: Machine Learning. Technical Indicators. Trend Forecast. Cryptocurrencies.

TERMO DE RESPONSABILIDADE POR AUTORIA DO TRABALHO DE CONCLUSÃO DE CURSO

Eu, **VINÍCIUS LIMA FERNANDES**, matrícula **20203017457**, discente do Curso de Engenharia de Computação, declaro para os devidos fins, que o presente Trabalho de Conclusão de Curso, de título **USO DE ALGORITMOS DE APRENDIZADO DE MÁQUINA NA PREVISÃO DE ATIVOS FINANCEIROS UTILIZANDO INDICADORES TÉCNICOS**, é de minha autoria e que estou ciente dos:

- Artigos 297 a 299 do Código Penal;
- Decreto-Lei n 2.848 de 7 de dezembro de 1940;
- Lei no 9.610, de 19 de fevereiro de 1998, sobre os Direitos Autorais;
- Regulamento Disciplinar Discente do CEFET-MG;
- E que plágio consiste na reprodução de obra alheia e submissão dela como trabalho próprio ou na inclusão, em trabalho próprio, de ideias, textos, tabelas ou ilustrações (quadros, figuras, gráficos, fotografias, retratos, lâminas, desenhos, organogramas, fluxogramas, plantas, mapas e outros) transcritos de obras de terceiros sem a devida e correta citação da referência.

Por ser verdade, e por ter ciência do referido artigo, firmo a presente declaração, isentando o(a) professor(a) orientador(a) **SAMUEL DA COSTA ALVES BASÍLIO**, o(a) professor(a) coorientador(a) **FERNANDO GARCIA DINIZ CAMPOS FERREIRA**, os membros da banca examinadora e o Centro Federal de Educação Tecnológica de Minas Gerais, Campus Leopoldina, de qualquer responsabilidade.

Leopoldina 19 de junho de 2026

Assinatura do Discente

LISTA DE ILUSTRAÇÕES

Figura 2.1 – Fluxograma do processo de seleção dos artigos para revisão	18
Figura 2.2 – Representação do modelo Random Forest	29
Figura 2.3 – Ilustração do modelo K-Nearest Neighbors	30
Figura 3.1 – Estrutura das janelas temporais de treinamento e testes	38

LISTA DE TABELAS

Tabela 2.1 – Matriz de confusão	33
Tabela 3.1 – Precisão média para os algoritmos em diferentes horizontes	37
Tabela 3.2 – Grade de busca - RF	39
Tabela 3.3 – Grade de busca - KNN	39
Tabela 3.4 – Grade de busca - LSTM	39
Tabela 4.1 – Resumo das médias das métricas para o Bitcoin	41
Tabela 4.2 – Resumo dos retornos para o Bitcoin	42
Tabela 4.3 – Resumo das médias das métricas para o Ethereum	43
Tabela 4.4 – Resumo dos retornos para o Ethereum	43
Tabela 4.5 – Resumo das médias das métricas para o Cardano	44
Tabela 4.6 – Resumo dos retornos para o Cardano	44
Tabela 4.7 – Comparação da precisão entre os ativos	45
Tabela 4.8 – Comparação dos retornos entre os ativos	46
Tabela 4.9 – Valores da estatística Z para comparação dos retornos médios com a estratégia <i>buy and hold</i>	47
Tabela A.1 – Resultados do Bitcoin por execução	54
Tabela B.1 – Resultados do Ethereum por execução	59
Tabela C.1 – Resultados de Cardano por execução	64

LISTA DE ABREVIATURAS E SIGLAS

BTC Bitcoin

ETH Ethereum

ADA Cardano

RSI Índice de Força Relativa

TSI Índice de Força Verdadeira

VWMA Média Móvel Ponderada por Volume (*Volume Weighted Moving Average*)

FWMA Média Móvel Ponderada por Fractal (*Fractal Weighted Moving Average*)

MA Média Móvel (*Moving Average*)

EMA Média Móvel Exponencial (*Exponential Moving Average*)

MACD Convergência Divergência de Médias Móveis

BB Bandas de Bollinger

ML Aprendizado de Máquina (*Machine Learning*)

IA Inteligência Artificial

RF *Random Forest*

KNN *K-Nearest Neighbors*

LSTM *Long Short Term Memory*

MAE Erro Absoluto Médio (*Mean Absolute Error*)

MSE Erro Quadrático Médio (*Mean Squared Error*)

RMSE Raiz do Erro Quadrático Médio (*Root Mean Squared Error*)

MAPE Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error*)

TP Verdadeiros Positivos

TN Verdadeiros Negativos

FP Falsos Positivos

FN Falsos Negativos

LISTA DE SÍMBOLOS

n	Período total
i	Instante
P_i	Preço no instante i
$\dot{P}_i$	Previsão para o instante i
RS	Razão entre média dos ganhos e média das perdas
M_u	Média dos ganhos
M_d	Média das perdas
U_i	Ganho entre o preço de fechamento no instante i e o fechamento anterior
D_i	Perda entre o preço de fechamento no instante i e o fechamento anterior
m	Momento atual do preço
$Close_i$	Preço de fechamento no instante i
$Close_{i-1}$	Preço de fechamento no instante anterior
$Volume_i$	Volume no instante i
W_i	Peso em cada instante i
K	Número de desvios padrões
σ	Desvio padrão
Σ	Somatório
α	Fator de suavização

SUMÁRIO

1	INTRODUÇÃO	14
1.1	Justificativa	14
1.2	Objetivos	15
1.2.1	Objetivo Geral	15
1.2.2	Objetivos Específicos	15
1.3	Estrutura do Trabalho	16
2	REFERENCIAL TEÓRICO	17
2.1	Revisão da Literatura	17
2.2	Mercado financeiro	17
2.3	Indicadores técnicos	20
2.3.1	Indicadores de Tendência	20
2.3.1.1	Média Móvel	21
2.3.1.2	Média Móvel Exponencial	21
2.3.1.3	Convergência/Divergência de Médias Móveis	22
2.3.2	Indicadores de <i>Momentum</i>	22
2.3.2.1	Índice de Força Relativa	22
2.3.2.2	Índice de Força Verdadeira	23
2.3.3	Indicadores de Sobreposição	24
2.3.3.1	Média Móvel Ponderada por Volume	24
2.3.3.2	Média Móvel Ponderada por Fractal	24
2.3.4	Indicadores de Volatilidade	25
2.3.4.1	Bandas de Bollinger	25
2.4	Aprendizado de máquina	26
2.5	Séries temporais	26
2.5.1	Modelos	27
2.5.1.1	<i>Random Forest</i>	28
2.5.1.2	<i>K-Nearest Neighbours</i>	29
2.5.1.3	<i>Long Short Term Memory</i>	30
2.6	Métricas de desempenho	31
2.6.1	Métricas de Regressão	31

2.6.1.1	Erro Absoluto Médio	32
2.6.1.2	Erro Quadrático Médio	32
2.6.1.3	Erro Quadrático Médio da Raiz	32
2.6.1.4	Erro Percentual Absoluto Médio	32
2.6.2	Métricas de Classificação	33
2.6.2.1	Acurácia	33
2.6.2.2	Precisão	34
2.6.2.3	Revocação	34
2.6.2.4	Medida F1	34
3	MÉTODOS	36
3.1	Experimento	36
4	RESULTADOS	41
4.1	Bitcoin	41
4.2	Ethereum	42
4.3	Cardano	43
4.4	Comparação entre os modelos	45
5	CONCLUSÃO	48
5.1	Limitações	49
5.2	Trabalhos Futuros	49
	REFERÊNCIAS	50
A	Resultados detalhados para o Bitcoin	54
B	Resultados detalhados para o Ethereum	59
C	Resultados detalhados para o Cardano	64

1 INTRODUÇÃO

Prever o comportamento de um ativo no mercado financeiro é uma tarefa que investidores e organizações realizam constantemente, com o objetivo de gerar ganhos financeiros a partir da variação dos preços desse ativo (FERREIRA; GANDOMI; CARDOSO, 2020). Entretanto, antecipar o valor futuro de um ativo é uma tarefa complexa, uma vez que seu valor é determinado pela combinação de diversos fatores, como condições econômicas, políticas, emocionais e até mesmo comportamentais dos agentes de mercado são responsáveis por determiná-lo (GAMBOGI, 2013).

Historicamente, o estudo do mercado financeiro se apoia em duas abordagens distintas: a análise fundamentalista, que considera fatores macroeconômicos e a análise técnica, que é baseada em padrões estatísticos e históricos dos preços (FERREIRA; GANDOMI; CARDOSO, 2020). Essas abordagens são utilizadas por investidores e analistas para fundamentar decisões de compra ou venda dos ativos, permitindo interpretar tendências do mercado, avaliar riscos e identificar oportunidades de investimento (IJEGWA et al., 2014).

Nesse contexto, as criptomoedas surgiram como uma nova classe de ativos digitais baseados na tecnologia *Blockchain*, que registra transações de forma descentralizada e transparente (CHANG et al., 2020). No entanto, diferentemente dos ativos do mercado financeiro tradicional, as criptomoedas apresentam características distintas, como alta volatilidade, operação ininterrupta e ausência de regulação centralizada, o que torna a previsão do seu comportamento uma tarefa ainda mais complexa (GUPTA; CHAUDHARY, 2022).

Com o avanço tecnológico, o acesso a informação e a disponibilidade de dados sobre o mercado financeiro cresceram de forma significativa, possibilitando que técnicas de inteligência artificial e aprendizado de máquina se tornassem cada vez mais relevantes (IGARASHI; VALDEVIESO; IGARASHI, 2021). Essas técnicas possibilitam a análise de grande volume de dados para identificar padrões complexos e contribuir com a tomada de decisão (LOURES; JÚNIOR; KALILI, 2024).

1.1 Justificativa

De acordo com Cervelló-Royo e Guijarro (2020), apesar de algoritmos de aprendizado de máquina em conjunto de indicadores técnicos apresentarem resultados promissores na previsão de tendências de ativos financeiros, ainda existem limitações em ativos com cenários distintos:

tipo de ativo, período analisado, volume de negociação e volatilidade.

No contexto das criptomoedas, prever o comportamento de um ativo torna-se uma tarefa ainda mais complexa, já que esses ativos apresentam uma volatilidade maior comparada a volatilidade encontrada nos ativos presentes no mercado acionários tradicional (ZUBAIR et al., 2024). Além disso, a atenção acadêmica está concentrada ao Bitcoin, que é a principal criptomoeda em volume de negociações e valor de mercado, enquanto as demais criptomoedas são pouco exploradas (AKYILDIRIM; GONCU; SENSOY, 2021).

Dessa forma, a comparação de desempenho dos algoritmos de aprendizado de máquina em cenários distintos, se faz relevante pela necessidade de compreender como a dinâmica do mercado em diferentes ativos afeta a precisão dos resultados dos modelos de aprendizado, o que permite identificar quais métodos apresentam melhor desempenho a diferentes dinâmicas, contribuindo para apoio a tomada de decisão (WOLFF; ECHTERLING, 2024).

Portanto, este estudo se justifica pela necessidade de compreender a relação entre a forma de analisar criptomoedas em diferentes cenários e a capacidade de prever suas tendências de preço, avaliando se as características de cada ativo, como volatilidade e volume de negociação, influenciam no desempenho dos modelos de previsão.

1.2 Objetivos

1.2.1 Objetivo Geral

O objetivo geral deste trabalho é avaliar, analisar e discutir o desempenho de diferentes algoritmos de aprendizado de máquina na previsão da tendência, utilizando indicadores técnicos e séries temporais aplicadas a criptomoedas com cenários distintos no mercado. Com isso, busca-se verificar como diferentes características das criptomoedas influenciam no desempenho dos modelos de aprendizado de máquina.

1.2.2 Objetivos Específicos

- Coletar, organizar e pré-processar dados históricos de preços e indicadores técnicos das criptomoedas.
- Calcular e selecionar os indicadores técnicos a serem utilizados pelos modelos.
- Implementar e treinar modelos de aprendizado de máquina para a previsão das tendências.

- Definir e aplicar métricas para avaliar o desempenho do algoritmo.
- Comparar o desempenho dos modelos em criptomoedas com diferentes características.

1.3 Estrutura do Trabalho

O presente estudo está dividido nas seguintes sessões: Capítulo 1, onde foi apresentado a introdução do tema, a justificativa e os objetivos da pesquisa. No Capítulo 2, é apresentado o referencial teórico com os principais conceitos relacionados ao tema, como definições, indicadores técnicos, algoritmos de aprendizado de máquina aplicados na previsão de tendências dos ativos e métricas de avaliação. O Capítulo 3, apresenta os métodos utilizados para o desenvolvimento da pesquisa, bem como as ferramentas utilizadas e o planejamento para etapa de desenvolvimento. No Capítulo 4, são apresentados os resultados encontrados na pesquisa para cada um dos modelos em cada um dos cenários propostos. Por fim, o Capítulo 5 apresenta a conclusão do trabalho, as principais limitações do estudo e sugestões para trabalhos futuros.

2 REFERENCIAL TEÓRICO

Nesse capítulo, são apresentados os principais conceitos que estão relacionados ao tema deste estudo.

2.1 Revisão da Literatura

A revisão da literatura sobre os principais algoritmos de aprendizado de máquina, assim como os principais indicadores e métricas utilizados, foi feita utilizando a base de dados do Periódicos Capes, que é um dos principais acervos científicos do Brasil. Os descritores utilizados para construção da frase de busca foram escolhidos a partir do objetivo central do trabalho, com isso, foram utilizados como descritores "*Machine learning algorithms*", "*Stock market forecasting*" e "*Technical indicators*". Para construção da frase de busca foi utilizado o operador *AND* entre os descritores.


Foram utilizados filtros para garantir que os artigos selecionados apresentassem um contexto atual do desenvolvimento da área, com isso, foi adicionado o filtro de data para publicações dos últimos 5 anos. Também foram utilizados critérios de elegibilidade para garantir a relevância dos artigos revisados, os critérios adotados foram: a) artigos que abordassem a explicação de pelo menos um algoritmo de aprendizado de máquina para previsão de ativos financeiros; b) artigos que utilizassem indicadores técnicos como base para a previsão.

O Figura 2.1 apresenta o fluxograma do processo de seleção dos estudos para revisão. A busca encontrou 169 artigos, que passou inicialmente pela aplicação do filtro de data no qual 93 artigos foram removidos. Na etapa de elegibilidade foram lidos títulos e resumos dos 76 artigos restantes, e após a aplicação dos critérios de elegibilidade e remoção das duplicatas restaram 62 artigos que foram incluídos na revisão. Também foi necessário realizar revisões auxiliares para definir conceitos fundamentais relacionados ao tema.

2.2 Mercado financeiro

O mercado financeiro pode ser definido como um ambiente de negociação de recursos financeiros, que permite que investidores, instituições e o governo movimentem capital (LUPI; KNOERR; OLIVEIRA, 2019). Sua função é conectar os poupadores, que são agentes econômicos superavitários que possuem recursos disponíveis para aplicar, aos tomadores, que

Figura 2.1 – Fluxograma do processo de seleção dos artigos para revisão



Fonte: autor

são os agentes econômicos deficitários que necessitam de capital para financiar suas operações (CHIKAMI; SOUZA, 2011).

De acordo com Lupi, Knoerr e Oliveira (2019), o mercado financeiro é dividido em quatro segmentos de mercado distintos, cada um deles desempenhando funções específicas dentro do sistema econômico, eles são: o Mercado Monetário, que é utilizado para operações de curto prazo e controle da liquidez econômica; o Mercado de Crédito, onde os recursos disponíveis por agentes poupadores são utilizados por instituições financeiras; o Mercado de Câmbio, onde é realizada a troca de moedas estrangeiras por moeda nacional; e o Mercado de Capitais, onde ocorre a captação e aplicação de recursos entre os agentes poupadores e tomadores através da emissão e negociação de valores mobiliários, como as ações.

A centralização de mercado, na qual uma única entidade é responsável por intermediar transações, administrar dados e definir regras, demonstrou fragilidade em sua estabilidade e resiliência durante períodos de crise financeira (LI; PEREZ-SAIZ, 2018). Então, com o avanço da internet e da tecnologia da informação, o mercado financeiro passou por transformações em sua estrutura, se digitalizando para melhorar sua eficiência e velocidade de realizar transações financeiras (GUO; ZHOU, 2023).

Nesse contexto, o Blockchain, que é uma tecnologia que apresenta como característica

a descentralização de sua estrutura, teve sua primeira idealização no ano de 2008 por Satoshi Nakamoto (CHANG et al., 2020). Segundo Yoo (2017), um Blockchain pode ser compreendido como um banco de dados distribuído e imutável, no qual os registros são armazenados de forma encadeada e são protegidos criptograficamente.

Com a descentralização estrutural empregada pelo Blockchain, a atuação de intermediários nas transações financeiras deixa de ser necessária, garantindo mais transparência e segurança nas transações (GUO; ZHOU, 2023). Além de garantir um aumento na velocidade de pagamento e na redução dos custos das transações financeiras, o Blockchain também é utilizado para criação de ativos digitais financeiros, como as criptomoedas e tokens (CHANG et al., 2020).

Como exposto por Chang et al. (2020), as criptomoedas são ativos financeiros digitais que utilizam a estrutura do Blockchain para registrar, armazenar e validar transações financeiras. O Bitcoin (BTC), foi a primeira criptomoeda criada seguindo esses conceitos, seu objetivo era funcionar de forma descentralizada onde as transações pudessem ocorrer no formato *peer-to-peer* (ponto a ponto) (HOLZMANN; SCOTTI, 2022).

Por ser a primeira criptomoeda criada e ainda a mais utilizada, o BTC concentra um grande volume de negociações e mantém o domínio sobre o mercado das criptomoedas (KANAT, 2023). Essa relevância faz com que o BTC funcione como um indicador de sentimento e direção de mercado, já que movimentos em seu preço tendem a afetar diretamente outras criptomoedas e o nível de confiança dos investidores (AMIRZADEH et al., 2023).

Por ter como principal característica a descentralização e a volatilidade, as criptomoedas atraem a atenção dos investidores, uma vez que as variações em seus preços geram oportunidade de lucro para os agentes poupadores (GUPTA; CHAUDHARY, 2022). Segundo Vasconcelos et al. (2024), o mercado de criptomoedas ainda carece de uma regulamentação clara, o que combinado com baixa liquidez em grande parte dos ativos (GUPTA; CHAUDHARY, 2022) e com a elevada sensibilidade dos preços as notícias, fazem com que oscilações significativas nos preços sejam comuns.

Dessa forma, os agentes poupadores buscam prever o comportamento dos ativos para gerarem lucro a partir das variações dos preços (FERREIRA; GANDOMI; CARDOSO, 2020). Nesse contexto, a análise técnica é frequentemente utilizada, pois permite a aplicação de indicadores técnicos com base nos dados históricos dos preços para identificar possíveis padrões e prever tendências futuras (DEY; NAHAR; HOSSAIN, 2020).

As tendências são classificadas entre tendência de alta e tendências de baixa, onde a tendência de alta ocorre quando o preço de fechamento de um ativo é superior ao seu preço de abertura, e uma tendência de baixa ocorre quando o preço de fechamento é inferior ao preço de abertura (AKYILDIRIM; GONCU; SENSOY, 2021).

A sessão a seguir apresenta os principais indicadores técnicos utilizados na literatura, descrevendo suas características e ressaltando suas utilidades.

2.3 Indicadores técnicos

Os indicadores técnicos são ferramentas matemáticas utilizados pela análise técnica para compreender a tendência do movimento dos preços de um ativo, baseados nos dados históricos de preço e no volume de negociação (PHUOC et al., 2024). Esses indicadores são construídos a partir da série histórica dos preços, e através deles é possível fundamentar a tomada de decisão para determinar os pontos de compras e vendas dos ativos financeiros (LING; MOHAMAD; KELVIN, 2022).

De acordo com (GOUTTE et al., 2023), o preço de um ativo em um determinado instante de tempo é representado por quatro indicadores fundamentais: o preço de abertura, o preço de fechamento, o preço máximo e o preço mínimo.

No artigo publicado por Pagliaro (2023), é apresentada uma classificação dos indicadores técnicos com base em suas características, mostrando os indicadores em quatro categorias distintas: Indicadores de tendência, Indicadores de momento, Indicadores de Sobreposição e Indicadores de volatilidade.

2.3.1 Indicadores de Tendência

Os indicadores de tendência são utilizados para identificar a direção em que os preços dos ativos vão se movimentar em um determinado período de tempo, contribuindo para a percepção de possíveis inícios, continuidades ou reversão de tendências (HARIKRISHNAN et al., 2021).

Nos últimos anos, diversos indicadores de tendência foram utilizados em conjunto com modelos de aprendizado de máquina com o objetivo de prever comportamentos em ativos financeiros, entre os principais indicadores utilizados destaca-se, a Média Móvel (*Moving Average*) (MA) que foi aplicada por Kanat (2023) como parâmetro de entrada na construção de seu modelo de classificação aplicado a predição do BTC, e a Média Móvel Exponencial

(*Exponential Moving Average*) (EMA), que em conjunto com outros indicadores foi utilizada por Saetia e Yokrattanasak (2022) para prever movimentos de curto prazo no mercado acionário tailandês.

Outro indicador de tendência comumente utilizado na literatura é o Convergência Divergência de Médias Móveis (MACD), onde no estudo de Patil et al. (2024) foi aplicado para gerar sinais de compra e venda de criptomoedas analisando o cruzamento das EMAs de 12 e 26 períodos. Da mesma forma, no estudo de Ling, Mohamad e Kelvin (2022), o MACD foi utilizado em conjunto com outros três indicadores para identificar sinais de compra e venda, onde foi analisado o cruzamento da linha MACD com a EMA de 9 dias para determinar se o sinal era de alta ou baixa.

2.3.1.1 Média Móvel

A MA é um dos indicadores de tendência utilizados para suavizar alterações de preços e mostrar a direção do mercado. Esse indicador, é calculado em um período específico de tempo e auxilia na identificação de suportes, resistências e possíveis pontos de reversão de um ativo (VIDOTTO; MIGLIATO; ZAMBON, 2009). A MA pode ser calculada de acordo com a Equação (2.1), onde n é o valor total do período de tempo analisado e P_i corresponde ao preço no instante i .

$$MA = \frac{1}{n} \sum_{i=1}^n P_i \quad (2.1)$$

2.3.1.2 Média Móvel Exponencial

A EMA é uma variação da MA que atribui maior peso aos preços mais recentes, o que faz com que esse indicador tenha maior sensibilidade às mudanças recentes do mercado e permita uma rápida identificação de possíveis reversões de tendência (BUSTOS; POMARES-QUIMBAYA, 2020, apud SAETIA; YOKRATTANASAK, 2022). A EMA pode ser calculada de acordo com a Equação (2.2), onde P_i é o preço de fechamento do instante atual i , α é o fator de suavização, EMA_{i-1} é a EMA do instante anterior e n é o total de instantes avaliados (PAGLIARO, 2023).

$$EMA_i = \alpha P_i + (1 - \alpha) EMA_{i-1} \quad (2.2)$$

O fator de suavização é calculado através da Equação (2.3) a seguir, onde n é o período:

$$\alpha = \frac{2}{n + 1} \quad (2.3)$$

2.3.1.3 Convergência/Divergência de Médias Móveis

O MACD é um indicador de momento e tendência que avalia alterações na força, direção e duração de uma tendência. Ele é calculado pela diferença de duas EMAs de períodos distintos, geralmente 12 e 26 períodos, e gera uma linha de sinal ao ser suavizado por uma média móvel adicional, geralmente 9 períodos. Dessa forma, ele permite identificar cruzamentos, divergências e acelerações nas tendências, o que gera sinais de compra ou venda dos ativos (LING; MOHAMAD; KELVIN, 2022). A Equação (2.4) representa a expressão matemática para calcular o MACD, onde EMA_x e EMA_y são as EMAs de um período curto e um período longo, respectivamente.

$$MACD = EMA_x - EMA_y \quad (2.4)$$

2.3.2 Indicadores de *Momentum*

Os indicadores de *momentum* tem sido explorados na literatura como ferramentas para medir a velocidade e direção do movimento de um ativo financeiro, como no estudo do Thakurdesai (2024) onde o indicador Índice de Força Relativa (RSI) foi utilizado junto com outros indicadores técnicos para prever a direção de fechamento de um ativo para o dia seguinte. Outro exemplo, foi o trabalho do Pagliaro (2023), que utilizou o Índice de Força Verdadeira (TSI) para melhorar a identificação de possíveis mudanças no preço dos ativos.

2.3.2.1 Índice de Força Relativa

O RSI é um indicador de *momentum* que busca identificar condições de sobrecompra e sobrevenda, ou seja, situações que o preço de um ativo pode estar baixo ou alto demais, significando que podem haver correções no preço desse ativo. Esse indicador avalia o comportamento dos ativos medindo a velocidade e a intensidade dos preços ao longo de um período definido de tempo, permitindo a identificação do *momentum* do mercado, seu resultado varia entre 0 a 100, onde valores acima de 70 indicam sobrecompra e valores abaixo de 30 indicam sobrevenda (AKYILDIRIM; GONCU; SENSOY, 2021).

A Equação (2.5) representa o cálculo do RSI, nela o RS representa a razão entre os ganhos médios e as perdas médias de um ativo.

$$RSI = 100 - \frac{100}{1 + RS} \quad (2.5)$$

A Equação (2.6) define o cálculo do RS , onde M_u representa o ganho médio e M_d representa a perda média em um determinado período.

$$RS = \frac{M_u}{M_d} \quad (2.6)$$

As variáveis M_u e M_d podem ser calculadas a partir das Equações (2.7) e (2.8), respectivamente, onde U_i representa o ganho entre o preço de fechamento atual e o anterior e o D_i representa a perda no mesmo intervalo n .

$$M_u = \frac{\sum_{i=1}^n U_i}{n} \quad (2.7)$$

$$M_d = \frac{\sum_{i=1}^n D_i}{n} \quad (2.8)$$

2.3.2.2 Índice de Força Verdadeira

O TSI é o indicador de *momentum* utilizado para medir a força de uma tendência, seu funcionamento é semelhante ao do RSI, porém utiliza uma dupla suavização para taxa de variação do preço. Assim como o RSI, o TSI também é utilizado para identificar possíveis condições de sobrecompra e sobrevenda, além de auxiliar na detecção de divergências entre o movimento do preço e o comportamento do indicador, seu resultado oscila próximo de zero, quando valores positivos indica o *momentum* de alta e valores negativos indicam *momentum* de baixa (PAGLIARO, 2023).

A Equação (2.9) representa o modo como o TSI é calculado, onde EMA representa a média móvel exponencial calculada e m representa o *momentum* do preço.

$$TSI = 100 * \frac{EMA(EMA(m))}{EMA(EMA(|m|))} \quad (2.9)$$

O *momentum* do preço m pode ser calculado a partir da Equação (2.10), onde $Close_i$ é o preço no instante i e $Close_{i-1}$ é o preço no instante anterior.

$$m = Close_i - Close_{i-1} \quad (2.10)$$

2.3.3 Indicadores de Sobreposição

Os indicadores de sobreposição são ferramentas que estão relacionadas diretamente com a parte gráfica dos preços, elas são utilizadas para facilitar a leitura do comportamento do mercado, permitindo visualizar tendências, regiões de suporte e resistência. Na literatura, estudos como o de Kanat (2023), utilizaram o Média Móvel Ponderada por Volume (*Volume Weighted Moving Average*) (VWMA), que é um indicador de sobreposição, para avaliar sua efetividade na geração de sinais de compra e venda para o BTC.

Outro indicador destacado na literatura é a Média Móvel Ponderada por Fractal (*Fractal Weighted Moving Average*) (FWMA). Em trabalhos como o de Pagliaro (2023), esse indicador foi utilizado para identificar com antecedência mudanças significativas no mercado, servindo como variável de entrada nos modelos de aprendizado de máquina para diferenciar os dias nos quais houve grandes movimentações nos preços dos dias em que o movimento foi normal.

2.3.3.1 Média Móvel Ponderada por Volume

O indicador de sobreposição VWMA é uma média móvel que leva em consideração o volume de negociação do ativo na ponderação dos preços, trazendo assim, uma visão mais específica do comportamento em comparação as médias móveis tradicionais (KANAT, 2023).

O VWMA pode ser calculado através da Equação (2.11), onde $Close_i$ é o preço de fechamento do ativo em determinado instante i , $Volume_i$ é o volume de negociação no mesmo instante e n é o número de períodos.

$$VWMA = \frac{\sum_{i=1}^n Close_i * Volume_i}{\sum_{i=1}^n Volume_i} \quad (2.11)$$

2.3.3.2 Média Móvel Ponderada por Fractal

O indicador FWMA também é uma média móvel, assim como o VWMA, porém nele os preços mais recentes recebem maior peso. Dessa forma, esse indicador é útil em contextos onde é necessário captar mudanças na direção do mercado de forma rápida, uma vez que a maior ponderação nos preços mais recentes permite uma maior sensibilidade às variações do preço (PAGLIARO, 2023).

O FWMA pode ser calculado de acordo com a Equação (2.12), onde $Close_i$ é o preço de fechamento do ativo em determinado instante i , W_i é o peso dado para cada instante e n é o número de períodos.

$$FWMA = \frac{\sum_{i=1}^n Close_i * W_i}{\sum_{i=1}^n W_i} \quad (2.12)$$

2.3.4 Indicadores de Volatilidade

Os indicadores de volatilidade são ferramentas para avaliar a frequência e a intensidade das variações do preço de um ativo em um período de tempo. Na literatura, destaca-se o uso das Bandas de Bollinger (BB), que no estudo de Cervelló-Royo e Guijarro (2020) foi utilizada junto com outros indicadores, como variável para os modelos implementados, buscando prever tendências do mercado de ações do NASDAQ-100.

2.3.4.1 Bandas de Bollinger

As BB são utilizadas para medir a volatilidade do mercado, identificar sinais de sobrecompra e sobrevenda, além de fornecer indicações sobre possíveis pontos de reversão e a intensidade dos movimentos de preço. Elas são compostas por uma média móvel central e bandas superior e inferior calculadas a partir do desvio padrão. A expansão das BB significa uma maior volatilidade do mercado, enquanto uma contração delas, indicam uma menor volatilidade (DEY; NAHAR; HOSSAIN, 2020).

A Equação (2.13) mostra como a banda central da BB pode ser calculada, onde SMA representa uma média móvel simples e n representa o período.

$$MiddleBand = SMA(n) \quad (2.13)$$

As Equações (2.14) e (2.15) representam o cálculo das bandas superior e inferior das BB. Nelas, SMA representa a média móvel simples, n representa o número de períodos, σ representa o desvio padrão calculado no período n e k é o número de desvios padrões.

$$UpperBand = SMA(n) + k * \sigma \quad (2.14)$$

$$LowerBand = SMA(n) - k * \sigma \quad (2.15)$$

O desvio padrão no período n é calculado através da Equação (2.16), onde P_i representa o valor do preço no instante i e $SMA(n)$ representa a média móvel dos preços no período n .

$$\sigma = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - SMA(n))^2} \quad (2.16)$$

2.4 Aprendizado de máquina

A Inteligência Artificial (IA) pode ser definida como o estudo de agentes inteligentes que são capazes de perceber o ambiente e interagir com ele, em busca de atingir um objetivo específico (RUSSELL; NORVIG; INTELLIGENCE, 1995). Nesse contexto, o Aprendizado de Máquina (*Machine Learning*) (ML) representa um conjunto de técnicas que permitem aos agentes inteligentes melhorarem seu desempenho para atingir seu objetivo (RUSSELL; NORVIG; INTELLIGENCE, 1995).

O aprendizado de máquina é responsável por explorar a construção de algoritmos computacionais capazes de aprender padrões a partir de dados (MITCHELL, 2006). Segundo Paixão et al. (2022), o principal objetivo de construir um modelo de ML é que ele gere resultados de predição, classificação e análise com base em seu aprendizado de dados pré-definidos.

A aplicação do aprendizado de máquina no contexto financeiro se justifica pela capacidade desses algoritmos de interpretar grandes volumes de dados e identificar padrões ocultos que não são facilmente percebidos (LUDERMIR, 2021). Nesse cenário, técnicas de ML são utilizadas para interpretar diversas variáveis como: volume, preço máximo, preço mínimo, abertura e fechamento, por meio da série histórica dos dados e fornecem resultados que auxiliam na tomada de decisão (LING; MOHAMAD; KELVIN, 2022).

Ainda no contexto financeiro, são aplicados alguns tipos de algoritmos de aprendizado de máquina, entre eles: algoritmos de regressão e algoritmos de classificação. Os algoritmos de regressão são utilizados quando o objetivo é prever o preço futuro de um ativo (PAGLIARO, 2023), enquanto os algoritmos de classificação são utilizados quando o objetivo é classificar as tendências de algum ativo (DEY; NAHAR; HOSSAIN, 2020).

2.5 Séries temporais

A série histórica dos dados, também chamada de série temporal, pode ser definida como um conjunto de informações coletadas em intervalos regulares, que são organizadas ao longo do tempo e permitem analisar o comportamento de determinada variável durante um

período específico (LATORRE; CARDOSO, 2001). Elas podem ser aplicadas em áreas distintas, permitindo a análise de dados para identificar padrões, tendências e variações ao longo do tempo (NASCIMENTO et al., 2017).

No contexto financeiro, as séries temporais são utilizadas principalmente como variáveis de entrada nos modelos de ML, como realizado por Jadhav et al. (2024), onde eles fizeram a utilização das séries para que os modelos implementados em seu estudo pudessem identificar padrões e determinar o comportamento dos ativos. Já no estudo de Milicevic e Marasovic (2023), as séries temporais foram utilizadas para calcular alguns indicadores técnicos, que posteriormente foram empregados como entrada para os modelos de classificação.

No estudo de Wolff e Echterling (2024), as séries temporais foram obtidas com a frequência semanal em um intervalo superior a dezenove anos. O autor segmentou os dados coletados e construiu conjuntos temporais contínuos, definindo janelas de três anos para treinamento e um ano para teste. Dessa forma, o modelo foi treinado e avaliado por meio de deslizes sucessivos dessas janelas ao longo dos conjuntos temporais criados.

2.5.1 Modelos

Para classificar a tendência de um ativo, segue-se a abordagem de comparar o preço de fechamento com o preço de abertura em um determinado período. Nesse contexto, são utilizados critérios de classificação binária, onde é atribuído a classificação 1 para os ativos que encerram um período analisado com o preço de fechamento maior do que o preço de abertura (característica de alta), e classificação -1 para os ativos que apresentam um valor de fechamento menor ou igual ao valor de abertura naquele período (característica de baixa) (AKYILDIRIM; GONCU; SENSOY, 2021).

Estudos publicados nos últimos anos apresentam a utilização de diferentes algoritmos de classificação aplicados a previsão de tendências nos ativos financeiros. Entre eles, destacam-se três modelos amplamente explorados na literatura de acordo com suas características: o *Random Forest* (RF), por sua capacidade de identificar relações não lineares entre os indicadores técnicos (KHANDAGALE et al., 2023), o *K-Nearest Neighbors* (KNN), pela capacidade de encontrar cenários de similaridade entre o passado recente e o comportamento atual do mercado (NABIPOUR et al., 2020), e o *Long Short Term Memory* (LSTM), por sua capacidade de encontrar padrões de longo prazo em séries temporais (PATIL et al., 2024).

Um exemplo de aplicação dos modelos, pode ser observado como apresentado no trabalho

de Khandagale et al. (2023), no qual é utilizado o modelo RF, baseado em árvores de decisão para identificar padrões complexos no comportamento do mercado. Nesse estudo são utilizados indicadores técnicos como variáveis de entrada para o modelo e seu objetivo foi prever a tendência do preço de fechamento dos ativos analisados.

O modelo de RF também foi utilizado por Mahjouby et al. (2024) para prever e classificar tendências na taxa de câmbio entre o euro e o dólar. Nesse estudo, o algoritmo foi treinado com base nas séries históricas dos preços e variáveis econômicas, e seus resultados foram comparados aos de outros modelos implementado através da avaliação por meio da acurácia.

Outros tipos de modelo de ML também foram abordados em estudos recentes, como o KNN que é baseado na proximidade entre pontos. Em Mamoudan et al. (2023), esse algoritmo foi utilizado para classificar sinais no mercado do ouro, utilizando a similaridade entre os pontos para distinguir sinais de predição verdadeiros de sinais falsos. Seus resultados foram comparados com outros modelos implementados para avaliar o desempenho entre eles.

O estudo de Phuoc et al. (2024), utilizou o modelo de LSTM como principal ferramenta para realizar as previsões de preço no mercado do Vietnã, para isso, alimentou o algoritmo com uma série histórica dos preços em frequência diária, juntamente com indicadores técnicos e avaliou seus resultados através da acurácia. Já o estudo de Cheng (2024), aplicou o LSTM para prever a tendência do preço de fechamento de ativos no mercado de ação chinês e para buscar padrões temporais complexos, além de, comparar o desempenho do LSTM com outros modelos.

Na sessão a seguir, são apresentadas as principais características de cada um dos modelos mostrados nessa sessão, assim como a explicação do seu funcionamento.


2.5.1.1 *Random Forest*

O algoritmo RF é um modelo de aprendizado de máquina utilizado em tarefas de classificação ou regressão. Sua abordagem é baseada na combinação de múltiplas árvores de decisão, que são geradas a partir de um subconjunto dos dados e das variáveis, para realizar previsões e classificações (KHANDAGALE et al., 2023). Os resultados de cada árvore, individualmente, são combinados para produzir uma saída. No caso das classificações é selecionado como saída o resultado mais votado. Já nos casos das regressões é realizada uma média de todas as previsões (WOLFF; ECHTERLING, 2024).

A Figura 2.2, adaptada de Khandagale et al. (2023), apresenta uma representação do

modelo de aprendizado RF. Nela, pode ser observado a utilização de três árvores de decisão, onde a primeira e a terceira classificam como cenário de alta e a segunda classifica como cenário de baixa, com base no conjunto de dados de entrada. Após isso, é realizado processo de votação entre as árvores, e a classificação final atribuída é definida pela maioria dos votos.

Figura 2.2 – Representação do modelo Random Forest



Fonte: Adaptada de Khandagale et al. (2023)

2.5.1.2 *K-Nearest Neighbours*

O algoritmo de aprendizado KNN é um modelo utilizado para tarefas de classificação e regressão, baseando-se no princípio de que amostras semelhantes tendem a possuir a mesma classificação. Para isso, o modelo atribui a classificação de um novo ponto a partir da análise de seus K vizinhos mais próximos, considerando medidas de distância para determinar essa proximidade (PAGLIARO, 2023).


Seu funcionamento consiste em seguir alguns passos: define-se o valor de K e a métrica de distância que será utilizada. Em seguida, para cada novo ponto a ser classificado é calculado

a sua distância em relação a todos os outros pontos no conjunto de treinamento. Após o cálculo, as distâncias são ordenadas para que os K vizinhos mais próximos possam ser selecionados e com isso a classificação atribuída ao novo ponto é determinada por meio da votação entre os K vizinhos selecionados (NABIPOUR et al., 2020).

Entre as principais métricas de distância utilizadas no KNN, destaca-se a distância Euclidiana, que corresponde à distância em linha reta entre dois pontos e é calculada pela raiz quadrada da soma dos quadrados das diferenças entre suas coordenadas (NABIPOUR et al., 2020).

A Figura 2.3, apresentada por Nabipour et al. (2020) ilustra o funcionamento do KNN. Nela, pode ser observado um novo ponto (*sample*) sendo incluído no conjunto, e a partir dele são traçadas diferentes circunferências que correspondem aos valores de $K = 3$ e $K = 7$. Essas circunferências, são utilizadas para englobar os K vizinhos mais próximos desse ponto a ser adicionado.

Figura 2.3 – Ilustração do modelo K-Nearest Neighbors



Fonte: (NABIPOUR et al., 2020)

2.5.1.3 Long Short Term Memory

O modelo de aprendizado LSTM é um tipo de rede neural recorrente utilizado para realizar previsões em séries temporais, principalmente em contextos onde é necessário identificar padrões de curto e longo prazo. Nele é possível selecionar, armazenar e descartar informações

ao longo da sequência temporal, o que contribui para um melhor desempenho na detecção de tendências em dados financeiros (PHUOC et al., 2024).

A utilização da LSTM em diversos estudos ocorre devido ao seu mecanismo de controle interno, que permite aprender dependências de longo prazo. Esse mecanismo possibilita que ela corrija limitações encontradas nas redes neurais recorrentes tradicionais, como o problema de desaparecimento do gradiente e memória de longo prazo insuficiente (LANDI et al., 2021).

A estrutura interna da LSTM é composta por três portas principais: uma porta de esquecimento, onde é decidido quais informações devem ser descartadas; uma porta de entrada, que controla a inserção de informações relevantes; e uma porta de saída, que é responsável por definir quais informações serão passadas adiante (SANG; LI, 2024). Além disso, ela utiliza dois estados internos: o estado da célula, que é responsável por armazenar as informações de longo prazo ao longo da sequência temporal; e o estado oculto, que guarda informações de curto prazo utilizadas em cada instante da série temporal (SANG; LI, 2024).

Na próxima seção, são apresentadas as principais métricas utilizadas para a avaliação de desempenho dos modelos.

2.6 Métricas de desempenho

A avaliação da performance de um modelo de aprendizado de máquina é realizada através das métricas de desempenho. No contexto da previsão de ativos financeiros, a escolha das métricas adequadas se faz necessário, pois diferentes objetivos exigem formas distintas de avaliação, ou seja, as métricas utilizadas com o objetivo de prever as tendências de movimento do preço de um ativo são diferentes das métricas utilizadas quando o objetivo é prever o valor exato do preço desse ativo (LEE; HA; HWANGBO, 2022 apud LING; MOHAMAD; KELVIN, 2022).

2.6.1 Métricas de Regressão

As métricas de regressão são utilizadas para avaliar o desempenho de modelos que realizam previsões numéricas, elas quantificam o erro entre os valores previstos pelo modelo e o valores reais. Portanto, elas são utilizadas quando o objetivo é prever o valor exato dos preços de um ativo financeiro (CHENG, 2024).

Nas equações (2.17), (2.18), (2.19) e (2.20), são utilizadas as variáveis P_i , $\dot{P}_i$, e n , que

representam respectivamente, o valor real do preço de um ativo, o valor encontrado com a predição do modelo e o número total de avaliações.

2.6.1.1 Erro Absoluto Médio

O Erro Absoluto Médio (*Mean Absolute Error*) (MAE) é uma métrica de avaliação de desempenho que mede o erro médio absoluto entre a predição dos modelos e o valor real do preço do ativo (LING; MOHAMAD; KELVIN, 2022). Quanto menor o valor dessa métrica, melhor é a avaliação do modelo.

A Equação (2.17) representa a forma como MAE é calculada.

$$MAE = \frac{1}{n} \sum_{i=1}^n |P_i - \dot{P}_i| \quad (2.17)$$

2.6.1.2 Erro Quadrático Médio

O Erro Quadrático Médio (*Mean Squared Error*) (MSE) é a métrica responsável por calcular a média dos erros ao quadrado, garantindo que diferenças discrepantes entre os valores previstos e os valores reais tenham um maior impacto na avaliação final (CHICCO; WARRENS; JURMAN, 2021).

O MSE é calculado de acordo com a Equação (2.18).

$$MSE = \frac{1}{n} \sum_{i=1}^n (P_i - \dot{P}_i)^2 \quad (2.18)$$

2.6.1.3 Erro Quadrático Médio da Raiz

O Raiz do Erro Quadrático Médio (*Root Mean Squared Error*) (RMSE) é a métrica que representa a raiz quadrada do MSE, o que permite expressar o erro médio em unidades comparáveis às do dado original e manter as características do MSE (CHENG, 2024).

A Equação (2.19) representa a fórmula para calcular o RMSE.

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (P_i - \dot{P}_i)^2} \quad (2.19)$$

2.6.1.4 Erro Percentual Absoluto Médio

O Erro Percentual Absoluto Médio (*Mean Absolute Percentage Error*) (MAPE) é a métrica utilizada para indicar o percentual médio de erro do modelo em relação aos valores reais. Dessa forma, ele facilita a interpretação e a comparação do desempenho entre diferentes ativos

ou períodos. Valores menores de MAPE indicam maior precisão preditiva (MOHAPATRA et al., 2022).

O MAPE é obtido através da fórmula apresentada na Equação (2.20).

$$MAPE = \frac{100}{n} \sum_{i=1}^n \left| \frac{P_i - \dot{P}_i}{P_i} \right| \quad (2.20)$$

2.6.2 Métricas de Classificação

As métricas de classificação são utilizadas para quantificar a qualidade das previsões realizadas pelos algoritmos responsáveis por prever tendências financeiras. Para essa avaliação, utiliza-se a matriz de confusão, que organiza os resultados em quatro categorias: Verdadeiros Positivos (TP), Verdadeiros Negativos (TN), Falsos Positivos (FP) e Falsos Negativos (FN). A partir desses valores, é possível avaliar diferentes aspectos do modelo, como taxa de acerto e a confiabilidade das previsões positivas (ANANTHAKUMAR; SARKAR, 2017).

Para que a matriz de confusão possa ser utilizada na avaliação dos modelos, é importante destacar o significado apresentado por Saetia e Yokrattanasak (2022) para cada uma das categorias. Os TP representam os casos em que o modelo classificou corretamente ativos que tiveram tendência de alta. Os TN representam os casos em que o modelo classificou corretamente os ativos que tiveram tendência de baixa. Já os FP apresentam a situação onde o modelo prediz tendência de alta, para ativos que apresentaram tendência de baixa. E por fim, os FN representam os casos em que o modelo prediz uma tendência de baixa, mas na realidade, o ativo apresenta uma tendência de alta (SAETIA; YOKRATTANASAK, 2022).

A matriz de confusão pode ser visualizada na Tabela (2.1):

Tabela 2.1 – Matriz de confusão

	Realidade Positiva	Realidade Negativa
Predição Positiva	TP	FP
Predição Negativa	FN	TN

Fonte: (SAETIA; YOKRATTANASAK, 2022)

2.6.2.1 Acurácia

A acurácia é a métrica que representa a proporção de previsões corretas feitas pelo modelo em relação ao número total de previsões avaliadas, indicando o percentual geral de acertos do modelo de classificação (DEY; NAHAR; HOSSAIN, 2020).

A acurácia é calculada a partir da Equação (2.21), onde *Total* é o somatório de todas métricas da matriz de confusão.

$$Acuracia = \frac{TP + TN}{Total} \quad (2.21)$$

A Equação (2.22) representa o cálculo do total.

$$Total = TP + FP + FN + TN \quad (2.22)$$

2.6.2.2 Precisão

A precisão é uma métrica que indica a confiabilidade das previsões dos modelos para o cenário de alta, ou seja, avalia proporção de ativos em que o modelo previu corretamente com cenário de alta, com todos que foram classificados com esse cenário (SAETIA; YOKRATTANASAK, 2022).

A precisão é calculada de acordo com a Equação (2.23).

$$Precisao = \frac{TP}{TP + FP} \quad (2.23)$$

2.6.2.3 Revocação

A métrica revocação (no inglês *Recall*), é utilizada para medir a capacidade do modelo identificar corretamente todos os casos em que o cenário for de alta, ou seja, é utilizado para indicar a proporção de ativos que apresentaram tendência de alta e que foram corretamente avaliadas pelo modelo (PAGLIARO, 2023).

A Equação (2.24) descreve como calcular a revocação.

$$Revocacao = \frac{TP}{TP + FN} \quad (2.24)$$

2.6.2.4 Medida F1

A medida F1 (no inglês *F1-Score*) é uma métrica que representa uma média harmônica entre as métricas de Revocação e Precisão, oferecendo um equilíbrio entre ambas em situações onde uma delas apresenta um resultado muito inferior a outra. Dessa forma, o F1-Score é utilizado em cenários onde existe esse desbalanceamento entre essas duas métricas (PAGLIARO, 2023).

A métrica F1-Score é calculada de acordo com a Equação (2.25).

$$F1Score = 2 * \frac{Precisao * Revocacao}{Precisao + Revocacao} \quad (2.25)$$

3 MÉTODOS

Nesse capítulo é explicado todos os passos utilizados para o desenvolvimento e realização desta pesquisa.

3.1 Experimento

Para o experimento, foram selecionadas três criptomoedas com características distintas de mercado. O BTC foi incluído por ser a criptomoeda de maior capitalização e volume de negociação, sendo o principal ativo explorado em estudos da área (MILICEVIC; MARASOVIC, 2023; AKYILDIRIM; GONCU; SENSOY, 2021). O Ethereum (ETH) foi escolhido por se destacar como a segunda maior criptomoeda em capitalização de mercado e volume de negociação, representando um cenário consolidado e de alta liquidez. Por fim, a Cardano (ADA) foi selecionada por apresentar menor capitalização de mercado e menor volume de negociação quando comparada às demais, representando um cenário de menor liquidez e maior volatilidade. Além disso, sua escolha também foi motivada pela disponibilidade de um histórico de dados superior a cinco anos, período adotado neste estudo.

Os dados sobre a série histórica dos preços dos ativos são disponibilizados pela plataforma Yahoo Finance, e foram obtidos por meio do pacote Python yfinance. A escolha dessa ferramenta se justifica pela gratuidade das informações, assim como, pela ampla utilização em estudos que analisam preços e tendências de ativos financeiros (YU, 2025; BITTO et al., 2022). Os dados disponíveis pela ferramenta são os valores de abertura, fechamento, máxima, mínima e volume de negociação, além de ser possível definir o período e a frequência dos dados.

O primeiro passo do experimento foi realizar a coleta dos dados da série histórica financeira dos preços de cada um dos ativos. No estudo de Akyildirim, Goncu e Sensoy (2021), foi utilizado um intervalo de aproximadamente cinco anos, com dados em frequência de 10 minutos, uma vez que o trabalho realizava tanto previsões diárias quanto intradiárias (15, 30 e 60 minutos). Já em seu trabalho, Patil et al. (2024) utilizou um período de 60 dias, porém em frequência diária, compatível com seu horizonte de predição, que também era diário. Dessa forma, o presente estudo utilizou o período de cinco anos adotado por Akyildirim, Goncu e Sensoy (2021), partindo de 01/01/2020 até 31/12/2025, com frequência diária como Patil et al. (2024), e buscou verificar o melhor horizonte de predições entre 1 dia, 3 dias ou 7 dias.

O horizonte de previsão selecionado foi o de 3 dias, e a escolha foi fundamentada na

análise comparativa dos resultados obtidos para o ativo base BTC após a realização de 10 execuções experimentais. Foram avaliados os três modelos de aprendizado de máquina, para cada um dos três horizontes distintos de previsão, onde o horizonte de 3 dias apresentou a melhor precisão entre os horizontes. A Tabela 3.1 mostra os resultados médios de precisão para cada algoritmo após 10 execuções.

Tabela 3.1 – Precisão média para os algoritmos em diferentes horizontes

Modelo	1 dia	3 dias	7 dias
RF	49,46%	57,26%	54,95%
KNN	49,21%	55,66%	50,49%
LSTM	50,46%	58,13%	58,82%

Fonte: autor (2026)


Após a coleta, os dados foram pré-processados para garantir o tratamento de valores ausentes, cálculo correto dos indicadores técnicos e para criar as janelas temporais necessárias para a previsão das tendências. A etapa de tratamento incluiu a verificação de datas ausentes na série histórica, de modo a garantir a continuidade temporal dos dados, bem como a conferência dos tipos de dados de cada coluna (datas, valores de abertura, fechamento, máxima, mínima e volume), assegurando que estivessem no formato numérico ou temporal adequado para os cálculos dos indicadores técnicos. Não foram identificadas datas ausentes nos períodos coletados para nenhum dos três ativos analisados.

Seguindo a estrutura adotada por Wolff e Echterling (2024), os dados foram segmentados em janelas temporais consecutivas, de modo que cada janela fosse utilizada para compor um conjunto independente para treinamento e teste. Cada uma das janelas contém nove meses de dados para treinamento e três meses de dados para testes, mantendo a proporção utilizada por Wolff e Echterling (2024) em seu estudo, onde cerca de três quartos das janelas são utilizadas para treinamento e um quarto é utilizado para teste. Durante a etapa de teste, para cada dia, o modelo recebe como entrada os indicadores técnicos calculados para aquele dia e gera uma predição de forma independente, sem acesso a informações futuras. O *target* de cada dia foi definido com base no preço de fechamento três dias à frente.

A figura (3.1) representa uma adaptação da estrutura proposta por Wolff e Echterling (2024) para o formato proposto no presente estudo, adicionando etapas de otimização de hiperparâmetros entre as janelas. Nela, o eixo horizontal (eixo x) representa o avanço do

tempo ao longo dos cinco anos e o eixo vertical (eixo y) representa a disposição das janelas temporais contínuas.

Figura 3.1 – Estrutura das janelas temporais de treinamento e testes



Fonte: Adaptada de Wolff e Echterling (2024)

Além dos dados fundamentais sobre a série histórica dos preços, também foram calculados indicadores técnicos a partir das janelas temporais criadas, assim como feito por Milicevic e Marasovic (2023). Foram selecionados os principais indicadores encontrados na literatura, utilizando as categorias: tendência, *momentum* e volatilidade. Foram utilizados todos indicadores técnicos apresentados na Seção (2.3) como entrada para cada uma dessas categorias.

A forma de classificação adotada foi baseada nos estudos de Akyildirim, Goncu e Sensoy (2021) e Saetia e Yokrattanasak (2022), onde foi atribuído a classificação 1 para os ativos que encerraram o período analisado com o preço de fechamento maior do que o preço de fechamento do dia atual e a classificação -1 para os ativos que encerraram o período com o valor de fechamento menor ou igual ao valor de fechamento do dia atual.

Para realizar as previsões, foram escolhidos os modelos mais utilizados na literatura para diferentes tipos de abordagens, onde o primeiro modelo escolhido foi o *Random Forest*, que é baseado em árvores de decisão. O segundo modelo é o *K-Nearest Neighbors*, que se baseia na proximidade entre pontos. E por fim, o terceiro modelo é o *Long Short Term Memory*, que é baseado em redes neurais recorrentes. Os conjuntos de hiperparâmetros utilizados pelos

algoritmos, foram definidos com base em valores encontrados na literatura. Posteriormente, esses valores foram organizados em uma grade de busca e submetidos a uma etapa de otimização, com o objetivo de identificar a melhor combinação de hiperparâmetros que proporcionasse o melhor desempenho para cada modelo. As Tabelas (3.2), (3.3) e (3.4) apresentam as grades de busca para os modelos RF, KNN e LSTM, respectivamente.

Tabela 3.2 – Grade de busca - RF

Hiperparâmetros	Valores
Quantidade de árvores	10, 30, 50, 100, 200
Profundidade das árvores	3, 4, 5, 10, 20, 50, 80
Mínimo de amostras	2, 5, 8, 10, 12, 14, 16

Fonte: (MILICEVIC; MARASOVIC, 2023; PAGLIARO, 2023)

Tabela 3.3 – Grade de busca - KNN

Hiperparâmetros	Valores
Quantidade de vizinhos	3, 5, 7, 11, 15
Ponderação dos vizinhos	<i>uniform, distance</i>
Métrica	<i>euclidean</i>

Fonte: (SAETIA; YOKRATTANASAK, 2022)

Tabela 3.4 – Grade de busca - LSTM

Hiperparâmetros	Valores
Passo temporal	30, 60
Quantidade de neurônios	32, 64
Taxa de desligamento	0.1
Número de camadas	1
Número de épocas	20, 50

Fonte: (WOLFF; ECHTERLING, 2024)

A partir do conjunto de dados preparados e da estrutura de cada janela temporal, a execução dos modelos seguiu um fluxo de duas etapas alternadas. Nas janelas ímpares, foi realizado a otimização dos hiperparâmetros utilizando o método *GridSearchCV* da biblioteca *scikit-learn*, nela foram testados todas as combinações possíveis dentro da grade de busca definida para cada algoritmo. Nas janelas pares subsequentes, o modelo foi retreinado com

os hiperparâmetros otimizados na janela temporal anterior e avaliado sobre o período de teste correspondente na janela.

Para a avaliação do desempenho dos modelos de aprendizado de máquina, foram utilizadas as métricas de classificação, onde foi definido como principal métrica a Precisão, por indicar o quanto das predições positivas foram acertadas pelo modelo, o que no contexto financeiro significa maximizar a acurácia nas quais é esperada uma tendência de alta.. No entanto, outras métricas de classificação como, Acurácia, Revocação e Medida F1 também foram analisadas. As comparações foram baseadas na análise estatística após os modelos serem simulados por trinta vezes, garantindo robustez estatística.

De forma complementar, foi realizada uma análise financeira com o objetivo de verificar se a precisão obtida pelos modelos apresentaria ganhos reais. Nessa análise, cada previsão de alta gerada pelo modelo foi entendida como uma operação de compra, calculando o retorno percentual obtido entre o preço de fechamento do dia da previsão e o preço de fechamento três dias à frente. Os resultados foram comparados com a estratégia de *buy and hold*, que consiste em adquirir o ativo no início do período e mantê-lo até o final.

Por fim, foi verificado a significância estatística dos retornos financeiros utilizando o teste Z para cada modelo e ativo analisado, com exceção do KNN, por se tratar de um modelo determinístico. Dessa forma, foi comparado o retorno médio obtido nas trinta execuções com o retorno da estratégia *buy and hold*.

4 RESULTADOS

Nesse capítulo são apresentados os resultados obtidos a partir da execução dos experimentos descritos no capítulo de métodos. Os modelos RF, KNN e LSTM foram avaliados sobre três criptomoedas com características distintas de mercado: BTC, ETH e ADA. Para cada ativo, os modelos foram executados por trinta simulações independentes, permitindo a análise estatística dos resultados.

4.1 Bitcoin

Os resultados gerais obtidos para o BTC, considerando os três modelos avaliados (RF, KNN e LSTM) em relação a cada uma das métricas de avaliação, são apresentados na Tabela 4.1, onde são exibidas as médias das métricas e o desvio padrão ao longo das trinta execuções para cada algoritmo.

Tabela 4.1 – Resumo das médias das métricas para o Bitcoin

Modelo	Precisão	Acurácia	Revocação	Medida F1
RF	57,66% $\pm$ 1,84%	52,75% $\pm$ 1,37%	41,88% $\pm$ 3,40%	42,52% $\pm$ 3,00%
KNN	55,66% $\pm$ 0,00%	51,82% $\pm$ 0,00%	46,02% $\pm$ 0,00%	49,34% $\pm$ 0,00%
LSTM	58,41% $\pm$ 1,81%	53,71% $\pm$ 1,61%	44,44% $\pm$ 4,20%	43,21% $\pm$ 3,81%

Fonte: autor (2026)

A Tabela 4.1 mostra que todos modelos tiveram precisão superior a 55%, indicando que a maior parte das predições de alta foi acertada. Entre os algoritmos, o LSTM foi o que apresentou a maior média de precisão, com 58,41% de acurácia, seguido pelo RF com 57,66% e pelo KNN com 55,66%.

O desvio padrão encontrado nos algoritmos RF e LSTM mostra que os resultados foram consistentes ao longo das trinta execuções, pois não houve variações muito grandes entre elas. Para o KNN o desvio padrão apresentado é nulo para todas as métricas, pois o algoritmo é determinístico.

Em relação as demais métricas, o LSTM também apresentou o melhor desempenho para a acurácia com 53,71%, seguido pelo RF com 52,75% e pelo KNN com 51,82%. Os valores de revocação e medida F1 foram inferiores, o que reflete o comportamento esperado por modelos otimizados pela precisão, uma vez que ao priorizar a confiabilidade das predições de alta, os

modelos tendem a ser mais conservadores e preverem alta somente em momentos que existe uma maior certeza.

A Tabela 4.2 apresenta a análise financeira realizada para o BTC, nela são apresentados os retornos médios obtidos por cada modelo ao longo das trinta execuções, e o resultado do retorno utilizando a estratégia de *buy and hold* como referência.

Tabela 4.2 – Resumo dos retornos para o Bitcoin

Modelo	Retorno	Buy and Hold
RF	117, 72% $\pm$ 45, 40%	139, 18%
KNN	70, 82% $\pm$ 0, 00%	
LSTM	205, 86% $\pm$ 65, 69%	

Fonte: autor (2026)

A Tabela 4.2 mostra que o LSTM foi o único modelo a superar a estratégia de *buy and hold* para o BTC, obtendo um retorno média de 205, 86%, cerca de 66, 68% a mais do que o percentual de 139, 18% do *buy and hold*. O RF obteve um retorno médio de 117, 72%, o que representa lucro, mas com um retorno financeiro inferior a simplesmente comprar e manter o ativo. Já o KNN foi o que apresentou o menor retorno entre os modelos, com 70, 82%, ficando com um retorno de 68, 36% abaixo do retorno obtido pelo *buy and hold*.

O desvio padrão para os retornos indica uma instabilidade financeira entre as execuções, ainda que a precisão dos modelos esteja estável, o retorno financeiro sofre grandes alterações de acordo com o dia que o modelo acerta ou não a predição.

Os resultados detalhados de cada execução para o BTC são apresentados na Tabela A.1, localizada no Apêndice A.

4.2 Ethereum

Os resultados gerais obtidos para o ETH são apresentados na Tabela 4.3, seguindo a mesma estrutura adotada para o BTC.

A Tabela 4.3 mostra que a média das precisões de 50, 82% para o RF e 52, 29% para o LSTM ficaram bem próximas do limiar aleatório, que é de 50% para problemas com classificação binária. Enquanto isso, a precisão do modelo KNN foi de 46, 75% ficando abaixo do aleatório e indicando que a maior parte das suas previsões de alta foi incorreta.

Tabela 4.3 – Resumo das médias das métricas para o Ethereum

Modelo	Precisão	Acurácia	Revocação	Medida F1
RF	50,82% $\pm$ 1,60%	49,02% $\pm$ 1,49%	47,92% $\pm$ 3,49%	44,60% $\pm$ 2,76%
KNN	46,75% $\pm$ 0,00%	44,85% $\pm$ 0,00%	49,11% $\pm$ 0,00%	47,07% $\pm$ 0,00%
LSTM	52,29% $\pm$ 1,80%	50,66% $\pm$ 1,89%	55,19% $\pm$ 4,54%	49,02% $\pm$ 4,14%

Fonte: autor (2026)

O desvio padrão da precisão permaneceu baixo para cada um dos modelos, confirmando uma estabilidade entre as execuções. Assim como no BTC, o desvio padrão esperado para o modelo KNN é nulo, pois se trata de um modelo determinístico.

Na Tabela 4.4 é mostrado a análise financeira para o ETH, sendo apresentado os retornos médios obtidos por cada modelo e o resultado do retorno utilizando a estratégia de *buy and hold*.

Tabela 4.4 – Resumo dos retornos para o Ethereum

Modelo	Retorno	Buy and Hold
RF	-22,97% $\pm$ 46,92%	9,98%
KNN	-129,85% $\pm$ 0,00%	
LSTM	51,39% $\pm$ 84,31%	

Fonte: autor (2026)

A Tabela 4.4 reforça os resultados das métricas de classificação avaliadas, mostrando um retorno de -22,97% para o RF e um retorno de -129,85% para o KNN. Comparando com o valor de 9,98% de retorno na estratégia *buy and hold*, o LSTM foi o único modelo que conseguiu superar a estratégia, alcançando 51,39% de retorno para o ETH. No entanto, o desvio padrão de 84,31% indica instabilidade financeira entre as execuções, o que torna os resultados das previsões pouco confiáveis para o ETH.

Os resultados detalhados de cada execução para o ETH são apresentados na Tabela B.1, localizada no Apêndice B.

4.3 Cardano

Os resultados gerais obtidos para o ADA são apresentados na Tabela 4.5, seguindo a mesma estrutura adotada para o BTC e para o ETH.

Tabela 4.5 – Resumo das médias das métricas para o Cardano

Modelo	Precisão	Acurácia	Revocação	Medida F1
RF	53,72% $\pm$ 1,37%	51,95% $\pm$ 1,13%	46,55% $\pm$ 3,54%	41,89% $\pm$ 3,22%
KNN	56,25% $\pm$ 0,00%	53,65% $\pm$ 0,00%	43,98% $\pm$ 0,00%	43,01% $\pm$ 0,00%
LSTM	50,58% $\pm$ 1,47%	49,32% $\pm$ 1,53%	56,79% $\pm$ 6,03%	45,28% $\pm$ 3,80%

Fonte: autor (2026)

A Tabela 4.5 mostra que o KNN apresentou a maior precisão entre os modelos, com 56,25%, seguido pelo RF com 53,72%. No caso da ADA, o modelo LSTM apresentou a pior precisão entre os modelos, com 50,58%, bem próximo do limiar aleatório de 50% para problemas de classificação binária.

Com relação ao desvio padrão encontrados para a precisão, os modelos RF e LSTM apresentaram os valores de 1,37% e 1,47%, respectivamente. Já para a revocação, o LSTM apresentou o maior desvio padrão, com 6,03%, indicando maior variabilidade para prever dias reais de alta.

A Tabela 4.6 mostra a análise financeira para ADA, sendo apresentado os retornos médios obtidos por cada modelo e o resultado do retorno utilizando a estratégia de *buy and hold*, assim como feito para os ativos anteriores.

Tabela 4.6 – Resumo dos retornos para o Cardano

Modelo	Retorno	Buy and Hold
RF	164,24% $\pm$ 85,73%	-41,38%
KNN	255,81% $\pm$ 0,00%	
LSTM	76,34% $\pm$ 91,61%	

Fonte: autor (2026)

A análise financeira da ADA produziu os resultados mais expressivos com relação ao retorno. Como o *buy and hold* apresentou retorno negativo de -41,38% no período analisado, os modelos conseguiram evitar os piores momentos do ativo e superar a estratégia de *buy and hold*. Dessa forma, o KNN obteve o maior retorno, com 255,81%, seguido pelo RF com 164,24% e pelo LSTM com 76,34%.

Assim como para os outros ativos, o desvio padrão para os retornos foi elevado para os modelos RF e LSTM, pois o retorno está diretamente ligado ao dia ao qual a previsão é

acertada. Do mesmo modo, o KNN permanece com o desvio padrão nulo, pois é um modelo determinístico.

Os resultados detalhados de cada execução para o ADA são apresentados na Tabela C.1, localizada no Apêndice C.

4.4 Comparação entre os modelos

A Tabela 4.7 apresenta a comparação da precisão média obtida por cada modelo nos três ativos avaliados, onde o BTC foi utilizado como ativo de referência por ser a principal criptomoeda em volume de negociações, valor de mercado e exploração na literatura. O ETH representa o cenário de maior estabilidade e liquidez no estudo, e a ADA representa o cenário de maior volatilidade e menor volume de negociações.

Tabela 4.7 – Comparação da precisão entre os ativos

Modelo	BTC	ETH	ADA
RF	57,66% $\pm$ 1,84%	50,82% $\pm$ 1,60%	53,72% $\pm$ 1,37%
KNN	55,66% $\pm$ 0,00%	46,75% $\pm$ 0,00%	56,25% $\pm$ 0,00%
LSTM	58,41% $\pm$ 1,81%	52,29% $\pm$ 1,80%	50,58% $\pm$ 1,47%

Fonte: autor (2026)

Representando o cenário mais estável, o ETH apresentou os piores resultados de precisão entre os três ativos. Nele, o KNN ficou abaixo do limiar aleatório de 50%, com apenas 46,75% de precisão e os modelos RF e LSTM ficaram bem próximos da aleatoriedade com 50,82% e 52,29%, respectivamente. Dessa forma, apesar de ser um ativo mais estável e com maior volume de negociações, os modelos não foram capazes de encontrar padrões preditivos com os indicadores técnicos utilizados.

Para o cenário de maior volatilidade, a ADA apresentou resultados superiores ao do ETH para os modelos RF e KNN, enquanto para o LSTM apresentou uma média de precisão menor. O modelo KNN obteve a sua melhor precisão comparando todos ativos e foi o modelo mais preciso para ADA, com 56,25%. Logo em seguida, o modelo RF apresentou uma precisão de 53,72% e o LSTM apresentou uma precisão de 50,58%.

Já para o BTC, os modelos RF e LSTM conseguiram apresentar os melhores resultados dentre todos modelos e todos ativos, com 57,66% e 58,41% de precisão, respectivamente. Milicevic e Marasovic (2023), ao avaliar algoritmos de aprendizado de máquina para a previsão

diária do BTC, também obtiveram resultados acima do limiar aleatório de 50% com o RF, o que reforça que o nível de desempenho preditivo alcançado neste estudo está alinhado com o observado na literatura para esse ativo.

O desvio padrão da precisão de cada modelo, para cada ativo, indica a estabilidade do desempenho dos modelos ao longo das trinta execuções e a capacidade dos modelos serem utilizados em diferentes ativos.

A Tabela 4.8 apresenta a comparação dos retornos financeiros médios obtidos por cada modelo para cada um dos três ativos em relação a estratégia *buy and hold*.

Tabela 4.8 – Comparação dos retornos entre os ativos

Modelo	BTC (BH = 139,18%)	ETH (BH = 9,98%)	ADA (BH = -41,38%)
RF	117,72% $\pm$ 45,40%	-22,97% $\pm$ 46,92%	164,24% $\pm$ 85,73%
KNN	70,82% $\pm$ 0,00%	-129,85% $\pm$ 0,00%	255,81% $\pm$ 0,00%
LSTM	205,86% $\pm$ 65,69%	51,39% $\pm$ 84,31%	76,34% $\pm$ 91,61%

Fonte: autor (2026)

A Tabela 4.8 mostra que para o cenário mais estável, o ETH apresentou os piores retornos financeiros. Nele, os modelos RF e KNN obtiveram retornos negativos de -22,97% e -129,85% respectivamente, ambos abaixo do valor de 9,98% da estratégia de *buy and hold*. O LSTM foi o único modelo a atingir retornos superiores ao do *buy and hold* para o ETH, apresentando o retorno médio de 51,39% entre as execuções, porém com o desvio padrão elevado, demonstrando instabilidade entre os retornos de cada execução.

No cenário de maior volatilidade, a ADA produziu resultados expressivos para todos os modelos. Como o *buy and hold* apresentou resultado negativo de -41,38% no período analisado, todos os modelos conseguiram ser superiores a estratégia. Entre os modelos, o KNN apresentou o maior retorno com 255,81%, seguido pelo RF com 164,24% e pelo LSTM com 76,34%.

Dentre os modelos analisados, o LSTM foi o único que foi capaz de superar a estratégia de *buy and hold* para todos os ativos analisados, demonstrando maior capacidade de ser utilizado em diferentes cenários de mercado.

Os resultados mostram que o cenário baseado em maior volatilidade, representado pela ADA, obteve retornos mais favoráveis para os modelos de aprendizado de máquina, enquanto o cenário mais estável, representado pelo ETH, apresentou maior dificuldade preditiva e retornos

financeiros inferiores, mostrando que as características e momento dos ativos influenciam a eficácia dos modelos.

A Tabela 4.9 apresenta os valores da estatística Z obtidos para cada modelo em cada ativo, utilizando como referência o retorno da estratégia de *buy and hold*. O KNN foi excluído da análise por ser um modelo determinístico, apresentando o mesmo valor em todas as execuções. Para o RF e LSTM, os valores de Z maiores que 1,96 indicam que o retorno médio foi significativamente acima do *buy and hold*, enquanto valores menores que $-1,96$ significam que o retorno médio foi significativamente abaixo.

Tabela 4.9 – Valores da estatística Z para comparação dos retornos médios com a estratégia *buy and hold*

Modelo	BTC	ETH	ADA
RF	-2,59	-3,85	13,14
LSTM	5,56	2,69	7,04

Fonte: autor (2026)

Os resultados apresentados na tabela 4.9 mostram que para o BTC, o RF apresentou $Z = -2,59$, confirmando que seu retorno médio de 117,72% ficou significativamente abaixo do *buy and hold*. Enquanto o LSTM, com $Z = 5,56$, confirmou que seu retorno médio de 205,86% ficou significativamente acima.

Para o ETH, o RF apresentou $Z = -3,85$, confirmando que o retorno médio de $-22,97\%$ ficou significativamente abaixo da estratégia *buy and hold*. O LSTM apresentou um resultado de $Z = 2,69$, superando novamente a estratégia de *buy and hold*.

Por fim, para a ADA, tanto o RF quanto o LSTM superaram significativamente o *buy and hold*, com $Z = 13,14$ e $Z = 7,04$, respectivamente. O LSTM foi o único modelo a superar a estratégia de *buy and hold* em todos os ativos avaliados, demonstrando maior consistência entre os diferentes cenários de mercado.

5 CONCLUSÃO

O presente estudo teve como objetivo avaliar o desempenho de diferentes algoritmos de aprendizado de máquina na previsão de tendências, utilizando criptomoedas diferentes para representar características distintas do mercado, verificando como essas características influenciam na eficiência dos modelos. Para isso, foram avaliados os modelos RF, KNN e LSTM, utilizando os principais indicadores técnicos encontrados na literatura e aplicados ao BTC, ETH e ADA.

Com relação aos objetivos específicos, todos foram alcançados ao longo do desenvolvimento do estudo. Os dados históricos de preços do BTC, ETH e ADA foram coletados, organizados e pré-processados a partir da plataforma Yahoo Finance, os indicadores técnicos foram calculados e utilizados como entrada para cada um dos modelos, os algoritmos RF, KNN e LSTM foram implementados e treinados utilizando janelas temporais deslizantes com etapas de otimização de hiperparâmetros, as métricas de precisão, acurácia, revocação e medida F1 foram definidas e aplicadas para avaliar o desempenho de cada modelo, além de ser realizado a análise financeira dos retornos e o teste estatístico Z. Por fim, o desempenho dos modelos foi comparado entre os três ativos, permitindo verificar como as características de cada criptomoeda influenciam na eficácia dos algoritmos avaliados.

Os resultados encontrados mostram que as características dos ativos influenciam diretamente o desempenho dos modelos de aprendizado de máquina, tanto com relação a precisão, quanto em relação aos retornos financeiros. O ETH, representando o cenário de maior estabilidade e volume, apresentou piores resultados de precisão entre os três ativos analisados. O teste Z confirmou estatisticamente esse resultado, com o RF ficando significativamente abaixo do *buy and hold* com $Z = -3,85$ e o LSTM sendo o único a superá-lo com $Z = 2,69$. Enquanto o ADA, representando o cenário de maior volatilidade e menor volume obteve resultados melhores, com todos os algoritmos superando o *buy and hold*, resultado confirmado pelo teste Z com $Z = 13,14$ para o RF e $Z = 7,04$ para o LSTM.

O BTC, que foi utilizado como ativo de referência, apresentou os melhores resultados de precisão para o RF e para o LSTM, com valores semelhantes aos encontrados na literatura para esse ativo. Para o BTC, o LSTM foi o único modelo a superar o *buy and hold*, resultado confirmado pelo teste Z com $Z = 5,56$, enquanto o RF ficou significativamente abaixo com $Z = -2,59$. O LSTM foi também o único modelo a superar o *buy and hold* para todas outras

criptomoedas analisadas, demonstrando maior capacidade de utilização em cenários distintos.

Dessa forma, conclui-se que as diferentes características dos ativos como volatilidade e volume de negociação, influenciam na eficácia dos modelos de aprendizado de máquina. Onde os modelos demonstraram melhores resultados no cenário mais volátil e mais dificuldade no cenário mais estável. No entanto, os resultados obtidos não podem ser generalizados para outras criptomoedas, outros períodos de mercado ou outros horizontes de previsão, uma vez que o comportamento de ativos financeiros é influenciado por uma multiplicidade de fatores que variam ao longo do tempo e entre diferentes mercados.

5.1 Limitações

A análise apresentada no presente estudo, foi realizada somente para três ativos financeiros e um único horizonte de previsão de três dias, o que limita a generalização dos resultados encontrados para outros ativos. Além disso, os indicadores técnicos utilizados embora sejam os principais encontrados na literatura são somente alguns dos disponíveis para a análise de séries temporais financeiras, de modo que a inclusão de diferentes indicadores poderia impactar nos resultados alcançados e desempenho dos modelos.

5.2 Trabalhos Futuros

Como sugestão para trabalhos futuros, recomenda-se utilizar um conjunto amplo de ativos com diferentes características no mercado, incluindo criptomoedas de menor capitalização e maior volatilidade, a fim de verificar se os padrões observados se generalizam para outros cenários. Também é recomendado a avaliação de diferentes horizontes de previsão e de diferentes frequência de dados. Outra sugestão é a combinação de diferentes modelos de aprendizado de máquina, visando melhorar a capacidade preditiva final. Por fim, utilizar não somente a análise técnica, mas também a análise fundamentalista para contribuir com a capacidade preditiva dos modelos.

REFERÊNCIAS

- AKYILDIRIM, E.; GONCU, A.; SENSOY, A. Prediction of cryptocurrency returns using machine learning. **Annals of Operations Research**, Springer, v. 297, n. 1, p. 3–36, 2021.
- AMIRZADEH, R. et al. Modelling determinants of cryptocurrency prices: A bayesian network approach. **arXiv preprint arXiv:2303.16148**, 2023.
- ANANTHAKUMAR, U.; SARKAR, R. Application of logistic regression in assessing stock performances. In: IEEE. **2017 IEEE 15th Intl Conf on Dependable, Autonomic and Secure Computing, 15th Intl Conf on Pervasive Intelligence and Computing, 3rd Intl Conf on Big Data Intelligence and Computing and Cyber Science and Technology Congress (DASC/PiCom/DataCom/CyberSciTech)**. [S.l.], 2017. p. 1242–1247.
- BITTO, A. K. et al. Cryptoar: scrutinizing the trend and market of cryptocurrency using machine learning approach on time series data. **Indonesian Journal of Electrical Engineering and Computer Science**, v. 28, n. 3, p. 1684–1696, 2022.
- BUSTOS, O.; POMARES-QUIMBAYA, A. Stock market movement forecast: A systematic review. **Expert Systems with Applications**, Elsevier, v. 156, p. 113464, 2020.
- CERVELLO-ROYO, R.; GUIJARRO, F. Forecasting stock market trend: A comparison of machine learning algorithms. **Finance, Markets and Valuation**, Asociación para la Formación y la Investigación en Ciencias Económicas y ..., v. 6, n. 1, p. 37–49, 2020.
- CHANG, V. et al. How blockchain can impact financial services—the overview, challenges and recommendations from expert interviewees. **Technological forecasting and social change**, Elsevier, v. 158, p. 120166, 2020.
- CHENG, S. Heterogeneity in stock price forecasting-based on the arima-garch model and pca-lstm model. **Miscellaneous**, v. 88, p. 39, 2024.
- CHICCO, D.; WARRENS, M. J.; JURMAN, G. The coefficient of determination r-squared is more informative than smape, mae, mape, mse and rmse in regression analysis evaluation. **PeerJ computer science**, PeerJ Inc., v. 7, p. e623, 2021.
- CHIKAMI, A. C.; SOUZA, R. M. de. Estrutura e funcionamento do novo mercado de capitais brasileiro: Análise de risco e retorno sobre investimentos. **UNIFUNEC CIENTÍFICA MULTIDISCIPLINAR**, v. 1, n. 1, 2011.
- DEY, P. P.; NAHAR, N.; HOSSAIN, B. Forecasting stock market trend using machine learning algorithms with technical indicators. **International Journal of Information Technology and Computer Science**, Modern Education and Computer Science Press, v. 12, n. 3, p. 32–38, 2020.
- FERREIRA, F. G. D. C.; GANDOMI, A. H.; CARDOSO, R. T. N. Financial time-series analysis of brazilian stock market using machine learning. In: IEEE. **2020 IEEE Symposium Series on Computational Intelligence (SSCI)**. [S.l.], 2020. p. 2853–2860.
- GAMBOGI, J. A. **Aplicação de redes neurais na tomada de decisão no mercado de ações**. Tese (Doutorado) — Universidade de São Paulo, 2013.

- GOUTTE, S. et al. Deep learning and technical analysis in cryptocurrency market. **Finance Research Letters**, Elsevier, v. 54, p. 103809, 2023.
- GUO, D.; ZHOU, P. **The evolution of financial market infrastructure: from digitalization to tokenization**. [S.l.], 2023.
- GUPTA, H.; CHAUDHARY, R. An empirical study of volatility in cryptocurrency market. **Journal of Risk and Financial Management**, MDPI, v. 15, n. 11, p. 513, 2022.
- HARIKRISHNAN, R. et al. Machine learning based model to predict stock prices: A survey. In: IOP PUBLISHING. **IOP Conference Series: Materials Science and Engineering**. [S.l.], 2021. v. 1084, n. 1, p. 012019.
- HOLZMANN, G.; SCOTTI, M. Bitcoin: a inovação de investimentos em criptomoedas. **Academia de Direito**, v. 4, p. 1451–1475, 2022.
- IGARASHI, W.; VALDEVIESO, G. S.; IGARASHI, D. C. C. Análise de sentimentos e indicadores técnicos: Uma análise da correlação dos preços de ativos com a polaridade de notícias do mercado de ações. **Brazilian Journal of Business**, v. 3, n. 1, p. 470–486, 2021.
- IJEGWA, A. D. et al. A predictive stock market technical analysis using fuzzy logic. **Computer and information science**, Canadian Center of Science and Education, v. 7, n. 3, p. 1, 2014.
- JADHAV, B. et al. Survey on stock price forecasting. **Miscellaneous**, v. 08, n. 03, p. 1, 2024.
- KANAT, E. The validity of technical analysis in the cryptocurrency market: evidence from machine learning methods. **Journal of Business Economics and Finance**, PressAcademia, v. 12, n. 3, p. 102–109, 2023.
- KHANDAGALE, H. P. et al. Predicting stock prices with machine learning using comparative analysis of random forest algorithm. **Miscellaneous**, v. 8, n. 6, p. 60, 2023.
- LANDI, F. et al. Working memory connections for lstm. **Neural Networks**, Elsevier, v. 144, p. 334–341, 2021.
- LATORRE, M. d. R. D. d. O.; CARDOSO, M. R. A. Time series analysis in epidemiology: an introduction to methodological aspects. **Revista Brasileira de Epidemiologia**, SciELO Brasil, v. 4, p. 145–152, 2001.
- LEE, Y.; HA, B.; HWANGBO, S. Generative model-based hybrid forecasting model for renewable electricity supply using long short-term memory networks: A case study of south korea's energy transition policy. **Renewable Energy**, Elsevier, v. 200, p. 69–87, 2022.
- LI, F.; PEREZ-SAIZ, H. Measuring systemic risk across financial market infrastructures. **Journal of Financial Stability**, Elsevier, v. 34, p. 1–11, 2018.
- LING, P. S.; MOHAMAD, J.; KELVIN, L. Y. M. New approach for e-commerce stock prices prediction: combination of machine learning and technical analysis. **International Journal of Academic Research in Accounting, Finance and Management Sciences**, Human Resource Management Academic Research Society, v. 12, n. 3, p. 653–665, 2022.
- LOURES, S. A.; JÚNIOR, M. R.; KALILI, R. M. Análise de sentimentos: Como a inteligência artificial pode auxiliar no processamento de grandes volumes de dados? **Revista Contemporânea**, v. 4, n. 12, p. e6887–e6887, 2024.

LUDERMIR, T. B. Inteligência artificial e aprendizado de máquina: estado atual e tendências. **Estudos avançados**, SciELO Brasil, v. 35, p. 85–94, 2021.

LUPI, A. L. P. B.; KNOERR, V. C. d. S.; OLIVEIRA, J. S. d. Anotações acerca do sistema financeiro brasileiro: mercado de capitais ea regulamentação do invested-based crowdfunding no brasil. **Brazilian Business Law Journal**, v. 3, n. 17, 2019.

MAHJOUBY, M. E. et al. Machine learning algorithms for forecasting and categorizing euro-to-dollar exchange rates. **IEEE Access**, IEEE, v. 12, p. 74211–74217, 2024.

MAMOUDAN, M. M. et al. Hybrid neural network-based metaheuristics for prediction of financial markets: a case study on global gold market. **Journal of computational design and engineering**, Oxford University Press, v. 10, n. 3, p. 1110–1125, 2023.

MILICEVIC, T. K.; MARASOVIC, B. What factors influence bitcoin’s daily price direction from the perspective of machine learning classifiers? **Croatian operational research review**, v. 14, n. 2, p. 163–177, 2023.

MITCHELL, T. M. **The discipline of machine learning**. [S.l.]: Carnegie Mellon University, School of Computer Science, Machine Learning ..., 2006. v. 9.

MOHAPATRA, S. et al. Can ensemble machine learning methods predict stock returns for indian banks using technical indicators? **Journal of Risk and Financial Management**, MDPI, v. 15, n. 8, p. 350, 2022.

NABIPOUR, M. et al. Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis. **Ieee Access**, IEEE, v. 8, p. 150199–150212, 2020.

NASCIMENTO, L. A. et al. Geração automatizada de séries temporais de dados posicionais utilizando o ibge-ppp. **Boletim de Ciências Geodésicas**, SciELO Brasil, v. 23, n. 1, p. 150–165, 2017.

PAGLIARO, A. Forecasting significant stock market price changes using machine learning: Extra trees classifier leads. **Electronics**, MDPI, v. 12, n. 21, p. 4551, 2023.

PAIXÃO, G. M. d. M. et al. Machine learning na medicina: revisão e aplicabilidade. **Arquivos Brasileiros de Cardiologia**, SciELO Brasil, v. 118, n. 1, p. 95–102, 2022.

PATIL, R. et al. Stock market and cryptocurrency price prediction. **Miscellaneous**, p. 396, 2024.

PHUOC, T. et al. Applying machine learning algorithms to predict the stock price trend in the stock market—the case of vietnam. **Humanities and Social Sciences Communications**, Palgrave, v. 11, n. 1, p. 1–18, 2024.

RUSSELL, S.; NORVIG, P.; INTELLIGENCE, A. A modern approach. **Artificial Intelligence. Prentice-Hall, Egnlewood Cliffs**, v. 25, n. 27, p. 79–80, 1995.

SAETIA, K.; YOKRATTANASAK, J. Stock movement prediction using machine learning based on technical indicators and google trend searches in thailand. **International Journal of Financial Studies**, MDPI, v. 11, n. 1, p. 5, 2022.

SANG, S.; LI, L. A novel variant of LSTM stock prediction method incorporating attention mechanism. **Mathematics** 2024; 12: 945. 2024.

THAKURDESAI, A. Stock price prediction using machine learning. **Int. J. Res. Appl. Sci. Eng. Technol**, v. 12, n. 10, p. 1432–1438, 2024.

VASCONCELOS, G. A. S. de et al. Desafios e oportunidades das criptomoedas na contabilidade brasileira: uma revisão literária. **REVISTA DELOS**, v. 17, n. 61, p. e2845–e2845, 2024.

VIDOTTO, R. S.; MIGLIATO, A. L. T.; ZAMBON, A. C. O moving average convergence-divergence como ferramenta para a decisão de investimentos no mercado de ações. **Revista de Administração Contemporânea**, SciELO Brasil, v. 13, p. 291–309, 2009.

WOLFF, D.; ECHTERLING, F. Stock picking with machine learning. **Journal of Forecasting**, Wiley Online Library, v. 43, n. 1, p. 81–102, 2024.

YOO, S. Blockchain based financial case analysis and its implications. **Asia Pacific Journal of Innovation and Entrepreneurship**, Emerald Publishing Limited, v. 11, n. 3, p. 312–321, 2017.

YU, Y. Lstm-based time series prediction model: A case study with yfinance stock data. In: EDP SCIENCES. **ITM Web of Conferences**. [S.l.], 2025. v. 70, p. 03015.

ZUBAIR, M. et al. An improved machine learning-driven framework for cryptocurrencies price prediction with sentimental cautioning. **IEEE Access**, IEEE, v. 12, p. 51395–51418, 2024.

A RESULTADOS DETALHADOS PARA O BITCOIN

Tabela A.1 – Resultados do Bitcoin por execução

Modelo	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
1	RF	161	105	0,605	0,546	0,416	0,438	5,977	-4,295	1,682
1	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
1	LSTM	157	120	0,567	0,520	0,405	0,406	6,024	-4,308	1,716
2	RF	137	116	0,542	0,498	0,354	0,374	5,164	-4,326	0,838
2	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
2	LSTM	174	114	0,604	0,551	0,452	0,475	6,694	-3,705	2,989
3	RF	165	120	0,579	0,531	0,430	0,430	5,943	-4,765	1,178
3	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
3	LSTM	177	127	0,582	0,538	0,454	0,444	7,206	-4,796	2,410
4	RF	143	99	0,591	0,529	0,375	0,400	4,823	-4,264	0,559
4	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
4	LSTM	159	121	0,568	0,521	0,412	0,382	5,769	-4,323	1,447
5	RF	172	135	0,560	0,520	0,443	0,430	5,897	-4,295	1,603
5	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
5	LSTM	175	124	0,585	0,539	0,457	0,413	6,622	-4,528	2,095

Continua na próxima página

Execução	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
6	RF	148	104	0,587	0,530	0,383	0,399	5,795	-4,341	1,455
6	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
6	LSTM	156	109	0,589	0,534	0,409	0,407	5,712	-3,507	2,205
7	RF	145	112	0,564	0,514	0,384	0,389	5,297	-4,526	0,771
7	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
7	LSTM	166	127	0,567	0,523	0,428	0,399	6,072	-4,777	1,294
8	RF	159	129	0,552	0,510	0,411	0,402	5,577	-4,774	0,803
8	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
8	LSTM	151	101	0,599	0,538	0,391	0,374	5,849	-3,544	2,305
9	RF	174	127	0,578	0,534	0,457	0,457	6,140	-4,873	1,267
9	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
9	LSTM	184	127	0,592	0,547	0,471	0,461	6,811	-4,337	2,474
10	RF	176	134	0,568	0,527	0,458	0,456	6,238	-5,069	1,169
10	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
10	LSTM	147	115	0,561	0,513	0,381	0,387	5,163	-4,384	0,779
11	RF	145	110	0,569	0,517	0,375	0,394	4,953	-4,514	0,439
11	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
11	LSTM	163	120	0,576	0,528	0,421	0,404	6,217	-4,177	2,040
12	RF	186	122	0,604	0,557	0,487	0,495	6,398	-4,801	1,597

Continua na próxima página

Execução	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
12	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
12	LSTM	180	114	0,612	0,559	0,463	0,463	6,547	-4,098	2,449
13	RF	158	119	0,570	0,523	0,412	0,398	5,908	-4,600	1,308
13	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
13	LSTM	161	115	0,583	0,532	0,412	0,415	6,135	-4,288	1,847
14	RF	173	123	0,584	0,538	0,449	0,453	6,061	-4,692	1,369
14	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
14	LSTM	173	118	0,595	0,545	0,442	0,460	6,878	-4,361	2,517
15	RF	160	104	0,606	0,546	0,412	0,441	6,729	-4,133	2,596
15	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
15	LSTM	186	123	0,602	0,555	0,477	0,458	7,385	-4,347	3,038
16	RF	155	104	0,598	0,539	0,406	0,420	5,310	-4,022	1,288
16	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
16	LSTM	192	132	0,593	0,551	0,500	0,483	7,247	-4,616	2,631
17	RF	183	149	0,551	0,516	0,475	0,445	6,256	-5,468	0,788
17	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
17	LSTM	213	134	0,614	0,578	0,554	0,543	8,202	-4,431	3,771
18	RF	167	117	0,588	0,538	0,437	0,449	6,122	-4,571	1,551
18	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708

Continua na próxima página

Execução	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
18	LSTM	177	126	0,584	0,539	0,462	0,443	6,122	-4,290	1,832
19	RF	158	112	0,585	0,532	0,417	0,415	5,527	-4,690	0,838
19	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
19	LSTM	172	147	0,539	0,503	0,444	0,432	6,659	-5,138	1,520
20	RF	153	120	0,560	0,515	0,402	0,408	5,490	-4,565	0,925
20	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
20	LSTM	145	103	0,585	0,527	0,378	0,366	4,990	-3,839	1,151
21	RF	175	132	0,570	0,528	0,457	0,455	5,801	-4,840	0,962
21	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
21	LSTM	171	128	0,572	0,528	0,436	0,427	7,218	-4,829	2,389
22	RF	164	114	0,590	0,538	0,423	0,434	5,993	-4,567	1,426
22	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
22	LSTM	204	139	0,595	0,558	0,525	0,472	7,464	-4,633	2,831
23	RF	160	122	0,567	0,521	0,418	0,425	5,519	-4,606	0,912
23	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
23	LSTM	172	123	0,583	0,536	0,437	0,435	6,527	-4,812	1,715
24	RF	157	118	0,571	0,523	0,407	0,411	5,826	-4,700	1,125
24	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
24	LSTM	193	140	0,580	0,542	0,497	0,440	6,947	-4,939	2,008

Continua na próxima página

Execução	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
25	RF	141	115	0,551	0,505	0,366	0,378	5,635	-5,147	0,488
25	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
25	LSTM	150	105	0,588	0,531	0,388	0,406	5,933	-4,045	1,888
26	RF	157	117	0,573	0,524	0,405	0,395	5,934	-4,784	1,149
26	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
26	LSTM	158	107	0,596	0,539	0,407	0,422	5,436	-3,666	1,770
27	RF	145	105	0,580	0,524	0,376	0,404	4,839	-3,800	1,039
27	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
27	LSTM	186	141	0,569	0,531	0,482	0,453	6,420	-5,248	1,172
28	RF	175	143	0,550	0,513	0,456	0,447	6,015	-5,182	0,832
28	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
28	LSTM	168	136	0,553	0,513	0,432	0,389	6,069	-4,901	1,168
29	RF	177	120	0,596	0,547	0,460	0,487	6,903	-5,020	1,882
29	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
29	LSTM	171	105	0,620	0,560	0,439	0,463	6,300	-3,807	2,493
30	RF	158	103	0,605	0,545	0,414	0,426	5,583	-4,104	1,479
30	KNN	177	141	0,557	0,518	0,460	0,493	5,807	-5,099	0,708
30	LSTM	183	137	0,572	0,532	0,475	0,441	6,735	-4,920	1,815

B RESULTADOS DETALHADOS PARA O ETHEREUM

Tabela B.1 – Resultados do Ethereum por execução

Modelo	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
1	RF	177	174	0,504	0,487	0,490	0,458	7,617	-8,315	-0,698
1	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
1	LSTM	229	200	0,534	0,523	0,626	0,554	10,632	-9,074	1,558
2	RF	176	164	0,518	0,499	0,494	0,440	7,099	-7,088	0,011
2	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
2	LSTM	216	188	0,535	0,522	0,603	0,534	9,780	-8,636	1,144
3	RF	172	168	0,506	0,488	0,486	0,443	7,189	-7,888	-0,699
3	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
3	LSTM	202	196	0,508	0,491	0,570	0,494	8,273	-9,407	-1,134
4	RF	170	164	0,509	0,491	0,466	0,444	8,090	-7,882	0,208
4	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
4	LSTM	193	178	0,520	0,503	0,542	0,485	8,460	-8,023	0,437
5	RF	170	165	0,507	0,490	0,474	0,450	6,855	-7,691	-0,836
5	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
5	LSTM	191	185	0,508	0,491	0,534	0,480	8,259	-8,534	-0,275

Continua na próxima página

Modelo	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
6	RF	162	161	0,502	0,484	0,447	0,442	7,602	-7,858	-0,257
6	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
6	LSTM	206	205	0,501	0,484	0,578	0,504	9,062	-9,705	-0,643
7	RF	153	146	0,512	0,492	0,431	0,420	6,293	-6,976	-0,683
7	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
7	LSTM	206	194	0,515	0,499	0,577	0,508	8,916	-8,748	0,168
8	RF	169	187	0,475	0,458	0,473	0,419	7,458	-8,414	-0,955
8	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
8	LSTM	183	167	0,523	0,505	0,510	0,476	7,862	-8,215	-0,353
9	RF	184	175	0,513	0,495	0,503	0,463	8,284	-8,040	0,245
9	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
9	LSTM	225	201	0,528	0,515	0,627	0,535	10,488	-9,328	1,160
10	RF	158	161	0,495	0,479	0,437	0,421	7,015	-7,367	-0,351
10	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
10	LSTM	168	149	0,530	0,509	0,484	0,424	7,325	-6,527	0,798
11	RF	153	147	0,510	0,491	0,429	0,429	6,637	-7,034	-0,397
11	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
11	LSTM	159	157	0,503	0,486	0,464	0,422	6,787	-7,085	-0,298
12	RF	165	150	0,524	0,503	0,462	0,435	6,814	-7,299	-0,485

Continua na próxima página

Modelo	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
12	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
12	LSTM	189	160	0,542	0,523	0,520	0,502	8,236	-7,346	0,890
13	RF	181	163	0,526	0,508	0,499	0,457	8,109	-7,929	0,180
13	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
13	LSTM	231	201	0,535	0,524	0,633	0,557	10,622	-9,581	1,041
14	RF	199	192	0,509	0,492	0,545	0,511	9,064	-9,411	-0,346
14	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
14	LSTM	214	164	0,566	0,551	0,598	0,547	9,158	-7,426	1,732
15	RF	157	166	0,486	0,471	0,433	0,412	6,733	-7,417	-0,684
15	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
15	LSTM	205	176	0,538	0,523	0,571	0,516	9,702	-8,121	1,581
16	RF	175	158	0,526	0,506	0,494	0,453	7,311	-7,267	0,044
16	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
16	LSTM	218	194	0,529	0,516	0,610	0,523	9,666	-8,971	0,695
17	RF	164	172	0,488	0,472	0,459	0,414	6,935	-7,783	-0,847
17	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
17	LSTM	202	168	0,546	0,529	0,555	0,524	8,755	-7,256	1,499
18	RF	175	166	0,513	0,495	0,490	0,443	7,165	-7,790	-0,625
18	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299

Continua na próxima página

Modelo	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
18	LSTM	181	177	0,506	0,488	0,533	0,431	7,670	-7,837	-0,167
19	RF	158	138	0,534	0,510	0,432	0,434	6,747	-6,553	0,194
19	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
19	LSTM	204	189	0,519	0,504	0,572	0,485	9,046	-7,899	1,147
20	RF	194	173	0,529	0,511	0,519	0,495	8,257	-8,511	-0,254
20	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
20	LSTM	178	161	0,525	0,506	0,504	0,470	7,947	-7,866	0,082
21	RF	176	151	0,538	0,517	0,492	0,450	8,338	-7,266	1,073
21	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
21	LSTM	213	190	0,529	0,514	0,587	0,514	9,729	-8,753	0,976
22	RF	160	165	0,492	0,476	0,450	0,420	7,306	-7,508	-0,202
22	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
22	LSTM	198	200	0,497	0,480	0,547	0,478	8,736	-9,617	-0,881
23	RF	180	178	0,503	0,486	0,508	0,441	8,043	-8,022	0,021
23	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
23	LSTM	201	169	0,543	0,527	0,565	0,513	8,467	-7,397	1,071
24	RF	170	191	0,471	0,454	0,475	0,431	7,814	-8,676	-0,862
24	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
24	LSTM	187	170	0,524	0,506	0,525	0,497	8,098	-7,727	0,371

Continua na próxima página

Modelo	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
25	RF	161	153	0,513	0,494	0,446	0,416	7,195	-6,908	0,286
25	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
25	LSTM	189	169	0,528	0,510	0,528	0,488	8,888	-8,156	0,732
26	RF	162	161	0,502	0,484	0,456	0,423	6,972	-7,475	-0,503
26	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
26	LSTM	174	180	0,492	0,475	0,505	0,419	7,617	-7,236	0,381
27	RF	177	166	0,516	0,498	0,493	0,442	7,852	-7,670	0,181
27	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
27	LSTM	189	198	0,488	0,470	0,543	0,464	8,074	-9,193	-1,119
28	RF	184	169	0,521	0,503	0,507	0,472	8,045	-7,916	0,129
28	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
28	LSTM	172	168	0,506	0,488	0,502	0,447	7,138	-6,611	0,527
29	RF	209	199	0,512	0,496	0,575	0,522	9,267	-9,001	0,267
29	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
29	LSTM	201	166	0,548	0,531	0,566	0,513	9,081	-7,127	1,953
30	RF	189	194	0,493	0,476	0,513	0,479	8,714	-8,758	-0,044
30	KNN	180	205	0,468	0,449	0,491	0,471	7,970	-9,268	-1,299
30	LSTM	166	151	0,524	0,503	0,476	0,402	7,282	-6,939	0,343

C RESULTADOS DETALHADOS PARA O CARDANO

Tabela C.1 – Resultados de Cardano por execução

Execução	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
1	RF	162	147	0,524	0,508	0,443	0,387	9,121	-8,645	0,477
1	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
1	LSTM	238	228	0,511	0,500	0,660	0,540	13,734	-13,129	0,605
2	RF	181	145	0,555	0,537	0,493	0,452	10,779	-8,151	2,628
2	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
2	LSTM	185	195	0,487	0,473	0,516	0,413	10,998	-11,217	-0,219
3	RF	176	144	0,550	0,531	0,477	0,448	10,930	-8,312	2,618
3	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
3	LSTM	215	204	0,513	0,502	0,601	0,466	12,557	-11,430	1,126
4	RF	153	126	0,548	0,524	0,417	0,395	9,009	-7,460	1,549
4	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
4	LSTM	170	185	0,479	0,467	0,475	0,385	10,524	-10,993	-0,468
5	RF	165	148	0,527	0,510	0,448	0,404	10,170	-7,933	2,237
5	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
5	LSTM	203	213	0,488	0,473	0,566	0,415	11,822	-12,224	-0,403

Continua na próxima página

Execução	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
6	RF	164	151	0,521	0,505	0,442	0,365	8,665	-8,253	0,412
6	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
6	LSTM	233	214	0,521	0,513	0,644	0,517	13,698	-12,156	1,542
7	RF	141	129	0,522	0,503	0,383	0,340	7,183	-7,869	-0,686
7	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
7	LSTM	182	176	0,508	0,495	0,504	0,411	10,978	-10,073	0,904
8	RF	154	141	0,522	0,505	0,423	0,384	9,132	-8,177	0,955
8	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
8	LSTM	212	219	0,492	0,477	0,587	0,436	12,476	-12,731	-0,255
9	RF	182	150	0,548	0,531	0,491	0,445	11,197	-8,858	2,339
9	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
9	LSTM	198	189	0,512	0,499	0,551	0,429	12,371	-10,948	1,423
10	RF	181	144	0,557	0,538	0,490	0,454	9,579	-8,271	1,308
10	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
10	LSTM	230	230	0,500	0,487	0,643	0,500	13,687	-12,897	0,790
11	RF	176	137	0,562	0,541	0,478	0,453	10,507	-7,748	2,759
11	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
11	LSTM	196	178	0,524	0,512	0,548	0,458	12,044	-10,864	1,180
12	RF	164	146	0,529	0,512	0,446	0,393	10,474	-9,112	1,362

Continua na próxima página

Execução	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
12	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
12	LSTM	219	213	0,507	0,495	0,610	0,478	12,889	-12,295	0,595
13	RF	191	164	0,538	0,524	0,526	0,454	11,270	-9,286	1,985
13	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
13	LSTM	156	158	0,497	0,484	0,429	0,369	8,230	-8,662	-0,432
14	RF	166	145	0,534	0,516	0,457	0,406	10,041	-7,874	2,166
14	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
14	LSTM	188	156	0,547	0,531	0,524	0,449	11,624	-8,973	2,651
15	RF	171	150	0,533	0,516	0,471	0,416	10,016	-9,053	0,962
15	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
15	LSTM	218	225	0,492	0,477	0,609	0,476	13,029	-12,783	0,246
16	RF	189	169	0,528	0,515	0,513	0,455	11,155	-9,634	1,521
16	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
16	LSTM	229	221	0,509	0,498	0,641	0,483	13,355	-12,627	0,728
17	RF	161	138	0,538	0,519	0,442	0,386	10,029	-7,486	2,543
17	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
17	LSTM	247	257	0,490	0,473	0,688	0,501	14,243	-14,332	-0,090
18	RF	155	118	0,568	0,538	0,423	0,415	9,650	-6,640	3,011
18	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558

Continua na próxima página

Execução	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
18	LSTM	186	179	0,510	0,497	0,517	0,417	11,292	-9,696	1,596
19	RF	180	165	0,522	0,508	0,494	0,438	10,327	-9,633	0,694
19	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
19	LSTM	224	218	0,507	0,496	0,624	0,476	12,940	-11,721	1,219
20	RF	153	127	0,546	0,523	0,416	0,377	9,574	-7,345	2,229
20	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
20	LSTM	197	198	0,499	0,486	0,553	0,437	11,516	-11,321	0,194
21	RF	171	151	0,531	0,515	0,465	0,427	10,336	-8,375	1,960
21	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
21	LSTM	224	216	0,509	0,498	0,623	0,485	13,127	-12,191	0,936
22	RF	162	139	0,538	0,519	0,449	0,401	9,442	-8,023	1,420
22	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
22	LSTM	202	202	0,500	0,487	0,565	0,446	11,367	-11,820	-0,453
23	RF	171	159	0,518	0,504	0,466	0,410	9,771	-9,263	0,508
23	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
23	LSTM	193	202	0,489	0,475	0,538	0,447	11,567	-11,774	-0,207
24	RF	167	141	0,542	0,523	0,458	0,432	9,332	-8,072	1,260
24	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
24	LSTM	210	209	0,501	0,488	0,587	0,459	12,271	-12,062	0,209

Continua na próxima página

Execução	Modelo	TP	FP	Precisão	Acurácia	Revocação	Medida F1	Retornos TP	Retornos FP	Retornos total
25	RF	187	155	0,547	0,531	0,518	0,456	11,083	-8,977	2,105
25	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
25	LSTM	201	202	0,499	0,485	0,562	0,442	12,096	-11,850	0,247
26	RF	171	151	0,531	0,515	0,467	0,424	10,228	-9,012	1,216
26	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
26	LSTM	174	169	0,507	0,494	0,481	0,406	11,050	-9,152	1,898
27	RF	200	181	0,525	0,513	0,545	0,480	11,366	-10,111	1,255
27	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
27	LSTM	214	198	0,519	0,509	0,597	0,474	12,659	-11,491	1,168
28	RF	177	159	0,527	0,512	0,480	0,426	11,140	-9,088	2,052
28	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
28	LSTM	196	192	0,505	0,493	0,546	0,458	11,968	-10,739	1,229
29	RF	173	138	0,556	0,535	0,473	0,437	10,460	-7,703	2,758
29	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
29	LSTM	191	179	0,516	0,504	0,521	0,448	11,671	-9,587	2,084
30	RF	174	154	0,530	0,515	0,470	0,407	10,250	-8,580	1,669
30	KNN	162	126	0,563	0,537	0,439	0,430	9,488	-6,930	2,558
30	LSTM	193	166	0,538	0,524	0,528	0,465	12,089	-9,230	2,859