



UNIVERSIDADE
LUSÓFONA

Bitcoin Forecasting

Trabalho Final de Curso

Francisco Miguel Calado Pinto (aluno)

João Pedro Carvalho (orientador)

Daniel Fernandes (orientador)

Trabalho Final de Curso | LCiD | 27/06/2025

Direitos de cópia

Bitcoin Forecasting, Copyright de Francisco Miguel Calado Pinto, Universidade Lusófona.

A Escola de Comunicação, Arquitectura, Artes e Tecnologias da Informação (ECATI) e a Universidade Lusófona (UL) têm o direito, perpétuo e sem limites geográficos, de arquivar e publicar esta dissertação através de exemplares impressos reproduzidos em papel ou de forma digital, ou por qualquer outro meio conhecido ou que venha a ser inventado, e de a divulgar através de repositórios científicos e de admitir a sua cópia e distribuição com objectivos educacionais ou de investigação, não comerciais, desde que seja dado crédito ao autor e editor.

Este documento foi gerado com o processador (pdf/Xe/Lua)LaTeX e o modelo ULThesis (v1.0.0) [1].

Conteúdo

Conteúdo	2
Lista de Figuras	4
Lista de Tabelas	5
Abstract	6
1 Identificação do Problema	8
2 Estado de Arte	11
2.1 Modelo ARIMA	11
2.2 SARIMA	11
2.3 Modelos de Redes Neurais Recorrentes (RNNs)	12
2.4 Métricas:	13
2.5 Loss	14
3 Benchmarking	16
3.1 Análise dos Artigos e Comparação com o Trabalho Realizado	17
4 Viabilidade e Pertinência	19
4.1 Viabilidade	19
4.1.1 Viabilidade Técnica	19
4.1.2 Viabilidade Económica	19
4.1.3 Viabilidade Operacional	19
4.1.4 Viabilidade Social	20
4.1.5 Viabilidade Cultural	20
4.2 Pertinência	20
5 Solução Proposta	21
6 Metodologia e Planeamento	22
6.1 Resultados Parciais e Progresso Técnico	22
6.2 Ligação ao Repositório Git	23
6.3 Planeamento Gantt	23
6.3.1 Fluxo Metodológico do Projeto	24
6.3.2 Validação e Qualidade dos Dados	25
7 Calendário	27
7.1 Estrutura do Planeamento	27
7.2 Tarefas Detalhadas da Fase Seguinte	27
7.2.1 Modelagem e Testes Finais	27
7.2.2 Documentação e Redação do Estado da Arte	27
7.2.3 Desenvolvimento da Análise de Resultados	27
7.2.4 Elaboração de Conclusões e Propostas Futuras	27
8 Resultados	29

Resultados	29
Bibliografia	34

Lista de Figuras

6.1	Cronograma Gantt simplificado do desenvolvimento do projeto, com fases e tarefas	24
6.2	Pipeline do processo de previsão de preços da Bitcoin	25
8.1	Evolução do modelo LSTM ao longo de dezembro 2023	31
8.2	Evolução do modelo TFT ao longo de dezembro 2023	31
8.3	Evolução do modelo NBEATS ao longo de dezembro 2023	32
8.4	Evolução do modelo NHITS ao longo de dezembro 2023	32
8.5	Evolução do modelo RNN ao longo de dezembro 2023	32
8.6	Evolução do modelo KAN ao longo de dezembro 2023	32
8.7	Comparação entre os valores reais e as previsões do modelo NHITS com hiperparâmetros modificados (gráfico Streamlite)	33

Lista de Tabelas

6.1	Planeamento de atividades	22
8.1	Resultados dos modelos com hiperparâmetros por defeito	30
8.2	Resultados dos modelos após ajuste de hiperparâmetros	30
8.3	Comparação entre valores reais da BTC e previsões dos modelos (dezem- bro de 2023)	31

Abstract

Cryptocurrency price forecasting is one of the most complex and rapidly evolving areas in the field of time series modeling. The extreme volatility of cryptocurrency markets, coupled with their reliance on multiple influencing factors—such as historical data, market sentiment, trading volume, and external events (e.g., regulatory decisions or technological advancements)—creates a uniquely challenging environment for predictive modeling.

Over the years, researchers have employed a wide range of approaches to tackle this problem. Traditional statistical methods, such as ARIMA, provide a solid foundation for modeling linear patterns but often fall short when dealing with the non-linear complexities typical of cryptocurrency data. On the other hand, deep learning techniques, including LSTM, GRU, and Transformers, have demonstrated significant improvements in capturing these complex patterns and adapting to rapid market changes. Additionally, hybrid models and the integration of alternative data sources—such as sentiment analysis from social media or search engine trends—have emerged as cutting-edge methods to enhance prediction accuracy.

Resumo

A previsão de preços de criptomoedas é uma das áreas mais complexas e em rápida evolução no campo da modelagem de séries temporais. A extrema volatilidade dos mercados de criptomoedas, juntamente com a sua dependência de múltiplos fatores influentes tais como dados históricos, sentimento de mercado, volume de negociação e eventos externos (por exemplo, decisões regulatórias ou avanços tecnológicos) onde se cria um ambiente de modelagem preditiva particularmente desafiador.

Ao longo dos anos, os investigadores têm utilizado uma vasta gama de abordagens para enfrentar este problema. Métodos estatísticos tradicionais, como o ARIMA, fornecem uma base sólida para modelar padrões lineares, mas muitas vezes falham ao lidar com as complexidades não lineares típicas dos dados de criptomoedas. Por outro lado, técnicas de deep learning, como LSTM (Long Short Term Memories), GRU e Transformers, demonstraram melhorias significativas na captura desses padrões complexos e na adaptação às rápidas mudanças do mercado. Além disso, modelos híbridos e a integração de fontes de dados alternativas como a análise de sentimento a partir de redes sociais ou tendências de pesquisa em motores de busca têm surgido como métodos de ponta para melhorar a precisão das previsões.

1 - Identificação do Problema

A previsão de preços da Bitcoin é um desafio complexo que envolve múltiplos fatores. Para lidar com essa complexidade, os modelos preditivos usados no mercado de criptomoedas devem ser capazes de capturar padrões de longo e curto prazo, lidar com grandes volumes de dados e adaptar-se a rápidas mudanças no comportamento do mercado. Para atingir esses objetivos, a utilização de técnicas avançadas de machine learning e deep learning tem sido cada vez mais essencial. Entre os modelos que têm demonstrado um desempenho notável, destacam-se as redes neurais LSTM, os modelos Transformers, NBEATS, NHiTS, TFT, RNN e outros.

As redes neurais LSTM são um tipo de rede neural recorrente (RNN) projetada para lidar com o problema de desvanecimento e explosão do gradiente, um problema comum em RNNs tradicionais. Esse problema ocorre quando as redes tentam aprender dependências de longo prazo, o que é especialmente relevante quando se trabalha com séries temporais, como as de preços de criptomoedas. As LSTMs têm a capacidade de reter informações por períodos mais longos, o que as torna ideais para capturar padrões de longo prazo em dados financeiros. No contexto da previsão de preços da Bitcoin, as LSTMs conseguem identificar padrões sazonais, tendências de preços de longo prazo e influências externas que afetam o comportamento do mercado.

Essas redes neurais têm uma estrutura composta por células de memória que ajudam a armazenar e acessar informações de períodos anteriores, enquanto ajustam as conexões para permitir que a rede aprenda com dados passados e se adapte ao comportamento dos dados temporais. Com isso, as LSTMs podem ser eficazes na previsão de preços, ajustando-se às flutuações e volatilidade da Bitcoin.

Os modelos Transformers apresentam uma arquitetura de rede neural que foi inicialmente desenvolvida para tarefas de processamento de linguagem natural, mas que tem se mostrado extremamente poderosa também em tarefas de séries temporais. A principal inovação dos Transformers é o mecanismo de atenção, que permite que o modelo foque em diferentes partes da entrada de forma dinâmica, ao invés de processar as informações sequencialmente como as redes neurais tradicionais. Esse mecanismo de atenção possibilita que o modelo capture relações entre elementos distantes na sequência de dados, sendo especialmente útil para dados financeiros, onde influências de longo prazo e eventos externos podem afetar os preços.

Estes modelos podem ser ajustado para lidar com múltiplas variáveis de entrada, como dados históricos de preços, volumes de transações, indicadores técnicos e até mesmo fontes externas de dados, como notícias e sentimentos de redes sociais. No contexto da previsão de preços da Bitcoin, os Transformers podem integrar essas diversas fontes de informação para melhorar a precisão das previsões, ajustando-se a padrões dinâmicos que são comuns no mercado de criptomoedas.

Passando agora para modelos como o NBEATS e NHiTS que são abordagens baseadas em desagregação e reconstrução hierárquica que têm ganhado destaque em tarefas de previsão de séries temporais. O NBEATS é uma rede neural profunda que utiliza um modelo de arquitetura de block-wise, permitindo que o modelo capture características específicas dos dados temporais. O NBEATS não exige pré-processamento de dados complexos e é capaz de lidar com séries temporais de diferentes frequências e características.

O NHiTS, por outro lado, é uma extensão do NBEATS, introduzindo a ideia de redes neurais hierárquicas para capturar de forma mais eficiente os padrões temporais de múl-

tiplas escalas. Esses modelos têm sido particularmente eficazes para séries temporais complexas, como a previsão de preços de ativos financeiros, onde as flutuações podem ocorrer em múltiplos níveis e intervalos de tempo.

O TFT (Transformer for Time-Series Forecasting) é uma abordagem híbrida que combina a capacidade de aprendizado profundo do Transformer com a automação no ajuste de hiperparâmetros e na engenharia de características. O AutoTFT integra um mecanismo de atenção temporal com a capacidade de lidar com variáveis multivariadas, o que significa que pode lidar não só com dados temporais, mas também com dados externos que influenciam o comportamento do mercado. Além disso, o modelo ajusta automaticamente os parâmetros para otimizar a previsão, sem a necessidade de intervenção manual, o que torna o processo de modelagem mais eficiente e menos sujeito a erros humanos.

Ao ser aplicado à previsão de preços da Bitcoin, o TFT pode processar grandes volumes de dados, identificar padrões complexos e integrar diferentes fontes de dados, como o sentimento social ou indicadores macroeconômicos, para melhorar as previsões. Este modelo permite que o sistema seja mais flexível e adaptável, ajustando-se rapidamente às mudanças no mercado e fornecendo previsões mais precisas, mesmo quando o mercado está em períodos de alta volatilidade.

O modelo RNN é uma técnica de aprendizado automático que foca na otimização automática dos hiperparâmetros de redes neurais recorrentes, o que pode ser crucial na previsão de séries temporais, especialmente em mercados voláteis como o da Bitcoin. Em vez de depender de ajustes manuais de parâmetros, o RNN usa algoritmos de otimização para encontrar a melhor configuração possível para as redes neurais, onde ocorre uma economia de tempo e esforço do analista.

Este modelo se destaca pela sua capacidade de automatizar o processo de treinamento e ajustes, o que é vantajoso quando se lida com grandes volumes de dados e dados dinâmicos. No caso da previsão de preços de Bitcoin, o RNN pode ser configurado para otimizar continuamente o modelo à medida que novos dados se tornam disponíveis, permitindo uma previsão mais precisa e eficiente.

A Integração de Sentimento Social e Dados Externos A previsão de preços de criptomoedas não se limita apenas aos dados históricos de preços e volumes de transações. Fatores externos, como o sentimento social (extraído de notícias, redes sociais e fóruns) e indicadores econômicos globais, também desempenham um papel fundamental na determinação do preço. Modelos modernos, como o TFT, permitem integrar essas fontes externas diretamente no processo de previsão, aumentando a precisão do modelo.

O sentimento social pode influenciar de forma significativa o comportamento do mercado, especialmente em mercados tão sensíveis à especulação e às notícias como o de criptomoedas. Por exemplo, uma declaração de um regulador financeiro ou uma notícia sobre a adoção de Bitcoin por uma grande empresa pode causar um aumento ou queda no preço da criptomoeda. Ao integrar esses dados no modelo, é possível prever melhor as reações do mercado a eventos externos.

A Importância da Robustez a Outliers Os mercados financeiros, especialmente os de criptomoedas, são conhecidos por sua volatilidade extrema e por movimentos de preços anômalos ou outliers. O tratamento adequado de outliers é crucial para evitar que esses dados distorçam as previsões. Métricas como a HuberMQLoss, que combina características do erro quadrático médio (MSE) e do erro absoluto médio (MAE), são eficazes nesse contexto, ajustando-se automaticamente ao grau de desvio de outliers. Isso ajuda a suavizar os erros extremos e melhora a robustez do modelo, garantindo previsões mais confiáveis mesmo em situações de alta volatilidade.

Conclusão O uso de modelos avançados de machine learning e deep learning, como LSTM, Transformers, TFT e RNN, tem o potencial de melhorar significativamente a pre-

cisão das previsões de preços da Bitcoin, lidando eficazmente com a volatilidade e complexidade do mercado de criptomoedas. A integração de diferentes fontes de dados, a automação do processo de modelagem e o tratamento adequado de outliers são fundamentais para criar modelos robustos e confiáveis que possam ajudar os investidores a tomar decisões informadas em um mercado altamente dinâmico e imprevisível. A evolução desses modelos e sua capacidade de adaptação a mudanças rápidas nos padrões do mercado torna-os uma ferramenta poderosa na previsão de preços e na gestão de riscos no ambiente financeiro atual.

2 - Estado de Arte

No âmbito deste Trabalho Final de Curso, propõe-se uma abordagem abrangente e metodologicamente robusta para resolver o problema da previsão dos preços da Bitcoin, com recurso a técnicas avançadas de machine learning e deep learning. Estas soluções foram selecionadas com base na capacidade de lidar com a complexidade inerente das séries temporais financeiras e na sua aplicação comprovada em contextos semelhantes.

2.1 Modelo ARIMA

O modelo ARIMA (AutoRegressive Integrated Moving Average) constitui uma das abordagens estatísticas mais consolidadas e amplamente utilizadas na modelação e previsão de séries temporais. A sua relevância estende-se a inúmeros domínios, desde a macroeconomia à engenharia, passando pelos mercados financeiros e pela meteorologia, onde a capacidade de capturar padrões temporais recorrentes e evolutivos é de importância crítica. O ARIMA distingue-se pela sua aptidão para modelar dados que exibem comportamentos não estacionários — isto é, séries cuja média, variância ou estrutura de autocorrelação variam ao longo do tempo — através de um processo de diferenciação sistemática. Tecnicamente, este modelo é descrito por três parâmetros principais: p , d e q . O parâmetro p representa a componente auto-regressiva (AR), onde o valor atual da série depende linearmente de observações anteriores. O parâmetro d refere-se ao número de vezes que a série deve ser diferenciada para se tornar estacionária, sendo esta a componente de integração (I). Por fim, o parâmetro q designa a média móvel (MA), que modela os erros de previsão como uma combinação linear dos erros passados. A modelação ARIMA assenta, portanto, na premissa de que os dados se podem transformar numa série estacionária, onde os componentes determinísticos e estocásticos estão suficientemente estabilizados para permitir uma análise robusta. Uma das grandes forças do ARIMA reside na sua versatilidade. Apesar de ser um modelo linear, é capaz de capturar uma vasta gama de padrões temporais, nomeadamente tendências suaves, ciclos curtos e correlações de curto prazo. No entanto, esta capacidade depende fortemente da escolha apropriada dos parâmetros p , d e q , que geralmente são identificados através de métodos heurísticos, como a análise dos gráficos de autocorrelação (ACF) e autocorrelação parcial (PACF), ou através de critérios de informação, como o AIC (Akaike Information Criterion) e o BIC (Bayesian Information Criterion). Apesar da sua popularidade, o ARIMA apresenta algumas limitações, nomeadamente a sua incapacidade de lidar com efeitos sazonais e não-linearidades. No contexto da previsão de preços de criptomoedas — um domínio caracterizado por elevada volatilidade, forte presença de outliers e dependência de múltiplos fatores exógenos — o ARIMA pode revelar-se limitado, especialmente se aplicado de forma ingénua ou sem uma análise exploratória cuidada. Ainda assim, a sua simplicidade interpretativa, aliada ao rigor matemático, faz do ARIMA uma ferramenta de referência e um ponto de partida robusto para abordagens mais avançadas ou híbridas.

2.2 SARIMA

O modelo SARIMA (Seasonal AutoRegressive Integrated Moving Average) constitui uma extensão do tradicional modelo ARIMA, concebida para incorporar e modelar explicitamente padrões sazonais presentes em séries temporais. Esta evolução é de particular relevância em contextos onde os dados manifestam variações cíclicas regulares ao longo

do tempo — como, por exemplo, flutuações mensais, trimestrais ou anuais — cuja ignorância comprometeria gravemente a precisão e a fiabilidade das previsões. Assim, o SARIMA representa uma solução robusta para modelar simultaneamente a componente regular (não sazonal) e a componente periódica (sazonal) das séries temporais.

Matematicamente, o SARIMA é caracterizado por sete parâmetros: os três parâmetros clássicos do ARIMA (p, d, q) e quatro adicionais que descrevem a componente sazonal (P, D, Q, s), onde s representa a periodicidade do ciclo (por exemplo, 12 para dados mensais). O modelo completa-se com as componentes de autorregressão sazonal (SAR), diferenciação sazonal (I) e média móvel sazonal (SMA), que trabalham em paralelo com as respetivas componentes não sazonais. Esta estrutura hierárquica permite ao SARIMA capturar simultaneamente dependências de curto e de longo prazo, respeitando a estrutura rítmica subjacente aos dados.

A implementação eficaz de um modelo SARIMA exige uma análise cuidadosa da série, começando geralmente pela deteção de sazonalidade através de métodos gráficos (como decomposição STL), autocorrelação e espectrogramas. Uma vez identificada a sazonalidade, procede-se à diferenciação (estacionarização), seguida da estimativa dos parâmetros ótimos com base em técnicas como a máxima verosimilhança, validação cruzada temporal e otimização de métricas de penalização (AIC, BIC).

O SARIMA destaca-se não só pela sua capacidade de previsão em séries com padrões sazonais pronunciados, mas também pela sua transparência interpretativa, especialmente valorizada em ambientes de decisão e controlo estatístico. No entanto, tal como o ARIMA, o SARIMA é um modelo linear e univariado, o que significa que não considera variáveis externas que possam influenciar a dinâmica da série — uma limitação relevante em domínios como os mercados financeiros ou o comércio eletrónico. No caso das criptomoedas, onde a volatilidade é exacerbada por fatores externos como sentimento do mercado, eventos geopolíticos ou regulação, o SARIMA pode ser usado como modelo de base, mas beneficia claramente de ser complementado com abordagens multivariadas ou híbridas.

Em suma, o SARIMA oferece uma poderosa estrutura para modelação de séries com sazonalidade bem definida, mantendo a elegância matemática e interpretativa do ARIMA, mas ampliando significativamente o seu campo de aplicação.

2.3 Modelos de Redes Neurais Recorrentes (RNNs)

As Redes Neurais Recorrentes (RNNs) são especialmente adequadas para a modelagem de séries temporais, uma vez que são desenhadas para processar dados sequenciais. Entre os subtipos de RNNs, destaco as seguintes:

O Temporal Fusion Transformer (TFT) é uma arquitetura baseada em Transformers que incorpora mecanismos de atenção para identificar relações complexas entre diferentes pontos da série temporal. Ao contrário das RNNs e das LSTM, o TFT processa os dados de forma não sequencial, permitindo capturar dependências de longo alcance com elevado paralelismo computacional. A sua estrutura inclui um codificador e um decodificador, interligados por camadas de atenção multi-cabeças, redes feedforward e mecanismos de normalização, que em conjunto produzem representações internas ricas e dinâmicas. O TFT destaca-se ainda pela capacidade de fundir informação contextual, integrando variáveis endógenas e exógenas — como preços históricos e sentimento social — num fluxo temporal coerente. A sua componente de automação para ajuste de hiperparâmetros reduz significativamente o esforço manual. No entanto, este modelo tem um custo computacional elevado e requer grandes volumes de dados para evitar o sobreajustamento, o que pode ser um entrave em contextos com menos capacidade computacional ou com datasets reduzidos.

As RNNs tradicionais, embora mais simples, continuam a ser uma solução eficaz para a aprendizagem de dependências sequenciais, especialmente em séries temporais de curta duração. A sua estrutura permite ajustar automaticamente parâmetros como o número de células e camadas, o que simplifica o processo de modelação. São ideais para conjuntos de dados mais pequenos e menos complexos, beneficiando de um baixo custo computacional. Contudo, enfrentam sérias dificuldades na captação de padrões de longo prazo, e o seu desempenho tende a ser inferior quando aplicadas a dados com alta não linearidade.

O modelo KAN surge como uma abordagem híbrida e altamente flexível, combinando arquiteturas como LSTM e GRU com uma camada de automação para seleção de hiperparâmetros. É particularmente eficaz na integração de dados heterogêneos — incluindo texto, séries temporais e indicadores externos — e destaca-se pela sua adaptabilidade. Contudo, a flexibilidade do KAN tem como contrapartida um tempo de treino elevado, decorrente da pesquisa intensiva de configurações ótimas, e uma maior complexidade na interpretação dos seus resultados.

As redes LSTM (Long Short-Term Memory) são uma das evoluções mais populares das RNNs, concebidas especificamente para ultrapassar o problema dos gradientes desaparecidos. Utilizam três portas — entrada, esquecimento e saída — que regulam o fluxo de informação, permitindo que a rede retenha ou esqueça dados ao longo do tempo. São particularmente eficazes na identificação de padrões complexos e de longo prazo, e revelam-se bastante robustas em contextos com elevada não linearidade. Todavia, tal como os Transformers, as LSTM exigem maior capacidade computacional e uma afinação precisa dos seus parâmetros para evitar o sobreajustamento.

O modelo NBEATS (Neural Basis Expansion Analysis) foi desenvolvido para realizar previsões diretas com elevada precisão, através de uma estrutura composta por blocos especializados em capturar padrões sazonais e tendências. A sua abordagem baseada em decomposição torna-o altamente eficaz em séries com padrões cíclicos bem definidos. No entanto, a sua limitação prende-se com a dificuldade em integrar variáveis exógenas, o que pode reduzir o seu desempenho em sistemas multivariados.

Por fim, o NHITS (Neural Hierarchical Interpolation Temporal Smoother) representa uma evolução do NBEATS, com uma arquitetura hierárquica que permite interpolar séries temporais em múltiplas escalas. Esta capacidade torna-o particularmente adequado para séries com elevada volatilidade e estruturas multi-escala, ao mesmo tempo que permite um treino mais eficiente quando comparado com modelos como a LSTM. No entanto, o NHITS é sensível à presença de outliers e ruído nos dados, e requer dados de alta frequência para garantir uma performance otimizada.

Cada uma destas arquiteturas oferece vantagens e desvantagens distintas, e a sua escolha deve ser cuidadosamente ponderada em função do tipo de série temporal, da qualidade e quantidade de dados disponíveis, dos recursos computacionais existentes e dos objetivos específicos do projeto de previsão.

2.4 Métricas:

A avaliação de modelos preditivos é um componente crucial de qualquer projeto de previsão, especialmente em contextos financeiros, onde a precisão e a robustez das previsões têm impacto direto nas decisões tomadas pelos utilizadores. No âmbito deste trabalho, as métricas de avaliação desempenham um papel central na análise comparativa do desempenho dos modelos implementados, permitindo identificar não apenas a sua capacidade de prever valores futuros, mas também a forma como lidam com condições desafiadoras, como a presença de outliers ou a elevada volatilidade característica do mercado de criptomoedas.

A escolha das métricas deve refletir a complexidade dos dados e os objetivos específicos do projeto. No caso da previsão de preços da Bitcoin, é essencial utilizar métricas que avaliem a precisão global das previsões, a robustez dos modelos face a variações extremas e a capacidade de capturar tendências em séries temporais não lineares. Por esse motivo, foram selecionadas métricas amplamente reconhecidas e utilizadas na literatura, como o Erro Absoluto Médio (MAE), o Erro Percentual Absoluto Médio (MAPE), o Erro Quadrático Médio da Raiz (RMSE) e a HuberMQLoss, cada uma com características específicas que contribuem para uma análise mais detalhada do desempenho dos modelos.

Nesta subsecção descrevem-se as métricas utilizadas, destacando as suas características, vantagens e limitações. Adicionalmente, será explorado o impacto das escolhas das métricas nos resultados obtidos, com uma análise detalhada sobre a adequação de cada métrica às particularidades do mercado de criptomoedas e às arquiteturas dos modelos implementados neste trabalho.

O MAE (Mean Absolute Error) mede a média das diferenças absolutas entre os valores reais e os valores previstos. É uma métrica intuitiva, de fácil interpretação e que não penaliza fortemente os outliers. No entanto, uma das suas limitações é o facto de não distinguir entre erros pequenos e grandes, tratando-os todos com o mesmo peso, o que pode não ser ideal em contextos financeiros onde grandes desvios são mais críticos. A expressão do MAE é dado por 2.1.

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

O MAPE (Mean Absolute Percentage Error) expressa o erro médio em termos percentuais, permitindo comparar o desempenho do modelo em diferentes escalas e facilitando a interpretação em cenários práticos, como variações de preços. Ainda assim, esta métrica apresenta uma limitação importante: pode ser distorcida por valores reais muito próximos de zero, o que afeta a sua fiabilidade em séries com grande amplitude de variação.

$$\text{MAPE} = \frac{100}{n} \sum_{i=1}^n \left| \frac{y_i - \hat{y}_i}{y_i} \right| \quad (2.2)$$

O RMSE (Root Mean Squared Error) representa a raiz quadrada da média dos erros ao quadrado e é particularmente útil quando se pretende penalizar erros maiores, sendo por isso bastante empregue em contextos financeiros. Reflete de forma mais agressiva o impacto de grandes desvios, o que pode ajudar a detetar falhas graves nos modelos. Contudo, a sua elevada sensibilidade a outliers pode também distorcer a avaliação global do desempenho em séries voláteis como as criptomoedas.

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

2.5 Loss

Tanto para o treino como teste dos modelos de previsão baseados em redes neuronais, nomeadamente o Temporal Fusion Transformer (TFT) e variantes do AutoML providas pela biblioteca NeuralForecast, optou-se pela utilização da função de perda HuberMQLoss. Esta decisão foi fundamentada na necessidade de conjugar robustez estatística com a capacidade de modelar distribuições de probabilidade assimétricas, frequentemente observadas em séries temporais financeiras como o preço do Bitcoin.

A HuberMQLoss resulta da combinação da função de perda de Huber, conhecida pela sua resistência a outliers, com a quantile loss, permitindo que o modelo aprenda não apenas valores médios, mas também estimativas intervalares (quantis) da variável de interesse. Esta abordagem é particularmente relevante no contexto de previsão financeira, onde desvios abruptos e comportamentos extremos são comuns, podendo distorcer significativamente modelos baseados em erros quadráticos médios (MSE) ou absolutos (MAE).

Adicionalmente, ao permitir a modelação direta de quantis, a HuberMQLoss oferece maior flexibilidade na avaliação de risco e na análise de incerteza das previsões, o que representa uma mais-valia face a funções de perda tradicionais. Por conseguinte, a sua aplicação neste trabalho visa melhorar a qualidade preditiva e a robustez dos modelos em cenários de elevada variabilidade e ruído nos dados. Por fim a escolha da HuberMQLoss revela-se adequada face às características dos dados e aos objetivos do presente estudo. A sua capacidade de mitigar a influência de valores extremos, aliada à flexibilidade na modelação de quantis, proporciona uma abordagem preditiva mais robusta, precisa e alinhada com as exigências do domínio financeiro. Esta função de perda contribui, assim, de forma significativa para a estabilidade e desempenho geral dos modelos utilizados neste trabalho.

$$\text{HuberMQLoss} = \sum_{i=1}^n \begin{cases} \tau \cdot L_{\delta}(y_i - \hat{y}_i) & \text{se } y_i \geq \hat{y}_i \\ (1 - \tau) \cdot L_{\delta}(y_i - \hat{y}_i) & \text{se } y_i < \hat{y}_i \end{cases} \quad (2.4)$$

Em suma, a utilização combinada destas métricas permite obter uma avaliação mais completa e equilibrada dos modelos testados, respondendo de forma eficaz às exigências de precisão, estabilidade e interpretação no contexto da previsão de ativos digitais.

3 - Benchmarking

Este capítulo apresenta uma análise comparativa entre a solução desenvolvida no âmbito deste Trabalho Final de Curso e outras abordagens existentes, tanto científicas como comerciais, com o intuito de contextualizar o projeto no estado da arte atual. O objetivo é destacar os pontos fortes e fracos de cada alternativa, identificando as inovações introduzidas, bem como a viabilidade, pertinência e impacto da solução proposta.

A nível comercial, destacam-se plataformas como a QuantConnect e a CryptoCompare, que oferecem APIs e ferramentas avançadas para traders e investidores. Estas plataformas disponibilizam funcionalidades como acesso a dados históricos, análise técnica e execução automatizada de estratégias de trading. A principal vantagem reside na facilidade de integração e acessibilidade dos seus recursos, permitindo uma rápida implementação de estratégias num ambiente real de mercado. Contudo, estas soluções tendem a operar com modelos genéricos, pouco ajustados às especificidades de dados financeiros mais voláteis, como os das criptomoedas. Além disso, existe frequentemente uma falta de transparência quanto aos algoritmos subjacentes, o que compromete a interpretabilidade e personalização das previsões. Adicionalmente, estas plataformas raramente incorporam fatores exógenos relevantes, como o sentimento social, o que limita o seu potencial preditivo em contextos mais complexos.

Relativamente às abordagens estatísticas tradicionais, os modelos ARIMA e SARIMA continuam a ser amplamente utilizados para a análise de séries temporais. Estes modelos baseiam-se em padrões de autocorrelação e sazonalidade, sendo particularmente eficazes quando aplicados a séries estacionárias com estruturas regulares. São valorizados pela sua simplicidade, facilidade de implementação e baixo custo computacional, o que os torna acessíveis mesmo em contextos com recursos limitados. No entanto, apresentam várias limitações quando aplicados a domínios como o das criptomoedas. Em particular, têm dificuldade em capturar padrões não lineares ou comportamentos estocásticos complexos, característicos dos mercados financeiros digitais. Além disso, exigem um pré-processamento rigoroso para tornar os dados estacionários, o que pode introduzir enviesamentos na análise. Por fim, não estão concebidos para integrar fatores externos, como volume de transações ou indicadores de sentimento do mercado, o que compromete a sua capacidade de fornecer previsões contextualmente informadas.

No que toca à modelação de volatilidade, o modelo GARCH (Generalized Autoregressive Conditional Heteroskedasticity) destaca-se pela sua especialização na previsão de variabilidade em séries temporais financeiras. Este modelo é especialmente útil na gestão de risco, permitindo estimar a volatilidade futura com elevada precisão, e apresenta também uma boa eficiência computacional, sendo relativamente rápido mesmo em grandes volumes de dados. Contudo, o GARCH não é um modelo de previsão de valores diretamente, mas sim de variância condicional, o que limita a sua aplicabilidade quando o objetivo é prever o preço absoluto de ativos. Além disso, apresenta uma arquitetura que não suporta bem dados multivariados, tornando-se inadequado em contextos onde diferentes fatores interagem e influenciam simultaneamente o comportamento da série.

Em suma, enquanto as soluções comerciais oferecem conveniência e aplicabilidade imediata, e os modelos estatísticos clássicos fornecem um ponto de partida sólido, a complexidade dos dados financeiros modernos exige abordagens mais flexíveis e adaptáveis — como aquelas baseadas em redes neurais profundas — para alcançar um desempenho preditivo robusto e relevante.

Dando continuidade à análise comparativa, é importante considerar os modelos ba-

seados em Machine Learning, que têm vindo a ganhar destaque no domínio da previsão de séries temporais financeiras pela sua capacidade de lidar com dados complexos, heterogêneos e não lineares. Entre os mais utilizados encontram-se os algoritmos Random Forests, XGBoost e Support Vector Machines (SVM).

Os algoritmos de Random Forests e XGBoost são métodos supervisionados de ensemble learning amplamente aplicados em finanças. São particularmente eficazes na manipulação de dados tabulares e na incorporação de variáveis categóricas e numéricas de forma simultânea. Estes modelos lidam bem com datasets heterogêneos, apresentando uma menor sensibilidade a pequenas variações nos dados, o que os torna úteis para séries menos voláteis ou com ruído limitado. Além disso, possuem mecanismos internos que previnem overfitting, como regularização e subsampling. Contudo, uma das principais limitações destes modelos reside na sua inadequação para capturar dependências temporais de forma nativa. Isto significa que, para serem aplicados eficazmente a séries temporais, requerem um extenso trabalho de engenharia de features, como a criação manual de variáveis lag, médias móveis, diferenças e outras transformações temporais — tarefas que modelos de deep learning, como LSTM ou Transformers, realizam de forma automática e integrada.

O Support Vector Machines (SVM), embora originalmente desenvolvido para classificação binária, também pode ser aplicado a problemas de regressão, sendo especialmente eficaz em situações onde a fronteira de decisão entre diferentes estados do mercado é clara. O SVM apresenta uma boa precisão quando aplicado a séries com comportamento linear ou ligeiramente não linear e é particularmente eficaz em conjuntos de dados de pequena dimensão. Contudo, o seu desempenho degrada-se significativamente em contextos com elevada volatilidade e não linearidade acentuada, como é o caso do mercado de criptomoedas. Além disso, o SVM não é naturalmente adequado para problemas de séries temporais contínuas, exigindo transformações prévias que podem limitar a eficácia e interpretabilidade das previsões.

Em síntese, embora os modelos de Machine Learning tradicional ofereçam boas capacidades de previsão em determinados contextos, a sua eficácia em ambientes altamente dinâmicos e não estacionários depende fortemente da qualidade da engenharia de features e do conhecimento prévio sobre a estrutura dos dados. Como tal, no contexto específico da previsão de preços da Bitcoin, modelos baseados em deep learning ou estruturas híbridas com capacidade de autoaprendizagem e integração de variáveis exógenas tendem a revelar-se mais promissores e adaptados.

3.1 Análise dos Artigos e Comparação com o Trabalho Realizado

Para contextualizar e validar a abordagem adotada neste Trabalho Final de Curso, foram analisados artigos científicos recentes que exploram modelos de previsão no domínio financeiro, com especial foco em séries temporais aplicadas a mercados voláteis como o das criptomoedas. A comparação entre estas propostas e o trabalho desenvolvido permite evidenciar as inovações introduzidas, assim como os seus pontos fortes e limitações relativas.

O primeiro artigo analisado, *“Forecasting the Bitcoin price using the various Machine Learning”* [2], apresenta uma comparação entre modelos clássicos de machine learning como regressão linear, Random Forest e SVM. O artigo destaca a limitação destas abordagens na captação de padrões não lineares e de alta volatilidade. Em contraste, o TFC desenvolvido aposta em modelos sofisticados como o AutoTFT, LSTM e NHITS, capazes de integrar variáveis exógenas como o sentimento social e o volume de transações, oferecendo uma solução mais robusta e adaptada ao contexto cripto.

O segundo artigo, *“A Review of Bitcoin Price Prediction Based on Deep Learning Algorithms”* [3], analisa arquiteturas como LSTM, GRU e CNN, concluindo que estas superaram os modelos clássicos na previsão de séries temporais financeiras. O estudo salienta ainda que arquiteturas bidirecionais como Bi-LSTM oferecem vantagens na modelação de padrões complexos. No entanto, limita-se a séries univariadas e não incorpora fatores exógenos. O presente trabalho vai além dessa limitação, ao integrar múltiplas variáveis contextuais e comparar diferentes modelos com validação robusta.

O terceiro artigo, *“Deep learning for Bitcoin price direction prediction: models and trading strategies empirically compared”* [4], investiga o uso de CNN-LSTM, TCN e ARIMA para prever a direção do mercado de Bitcoin, com avaliação simultânea de métricas preditivas e retorno financeiro em estratégias de trading. Embora forneça uma análise prática valiosa, o artigo não foca a integração com dados externos nem a otimização automatizada de hiperparâmetros, aspetos abordados no presente TFC.

Além destes, destacam-se também os estudos de *“Predicting Bitcoin (BTC) Price in the Context of Economic Theories”* [5], que combinam modelos como SVR, MLP e regressão OLS para integrar variáveis macroeconómicas, e o trabalho em [6], que compara GRU e LSTM em tarefas de previsão cripto, revelando diferenças importantes em termos de desempenho e estabilidade.

Por fim, o capítulo *“A Comparative Study: LSTM, GRU, VGG16, VGG19 para previsão de Bitcoin”* [7], explora a aplicação de arquiteturas híbridas entre redes neurais convolucionais e recorrentes, salientando o potencial de modelos visuais aplicados ao domínio financeiro. Esta ideia, embora promissora, contrasta com a abordagem deste TFC, que prioriza a modelação temporal e interpretabilidade.

Em suma, os artigos analisados oferecem contributos relevantes no que respeita à eficiência computacional, análise de arquiteturas recorrentes e avaliação de desempenho em trading. Contudo, apresentam limitações na integração de múltiplos fatores contextuais e na adaptação a cenários multivariados. O TFC aqui apresentado distingue-se pela sua abordagem abrangente, escalável e alinhada com os desafios reais enfrentados por traders e analistas no atual mercado de criptomoedas.

4 - Viabilidade e Pertinência

4.1 Viabilidade

A viabilidade e pertinência de aplicar RNNs ao trading e Bitcoin pode ser analisada a partir de vários pontos.

4.1.1 Viabilidade Técnica

A abordagem técnica adotada neste projeto é altamente sofisticada, posicionando-se na vanguarda da pesquisa em machine learning aplicado a finanças. A escolha de arquiteturas como LSTM e Transformers é justificada pela sua capacidade de capturar padrões temporais complexos e relacionamentos multivariados.

A aplicação de métricas avançadas, como a HuberMQLoss, destaca-se como uma inovação técnica ao lidar com os extremos característicos do mercado de criptomoedas. Esta métrica permite reduzir o impacto de outliers, produzindo previsões mais robustas e confiáveis. Adicionalmente, o uso de outras métricas, como RMSE e MAE, proporciona uma avaliação abrangente da precisão dos modelos.

Um aspecto técnico de destaque é a análise comparativa de modelos, que permite não apenas identificar o melhor desempenho, mas também explorar limitações intrínsecas de cada arquitetura. Esta abordagem aumenta a viabilidade das conclusões e justifica a escolha final dos modelos mais adequados para a previsão dos preços da Bitcoin.

4.1.2 Viabilidade Económica

O mercado de criptomoedas tem-se tornado uma força disruptiva no sistema financeiro global, com a Bitcoin como protagonista. Este ativo digital, com uma capitalização de mercado frequentemente acima de 1 trilhão de dólares, apresenta um comportamento altamente volátil e complexo. A pertinência económica deste projeto está enraizada na necessidade de ferramentas avançadas de previsão que permitam antecipar os movimentos deste mercado.

Por um lado, investidores institucionais, como fundos de investimento e bancos, procuram cada vez mais modelos preditivos para mitigar riscos associados à volatilidade. Por outro, pequenos investidores, que muitas vezes carecem de conhecimento técnico ou acesso a soluções robustas, também podem beneficiar das previsões como um meio de maximizar retornos.

Além disso, o trabalho ganha relevância no atual cenário macroeconómico, marcado por desafios como inflação global, instabilidade cambial e mudanças nas políticas monetárias. A Bitcoin, vista por alguns como "ouro digital", é cada vez mais utilizada como hedge contra esses fatores, reforçando a necessidade de análises preditivas mais precisas.

4.1.3 Viabilidade Operacional

Operacionalmente, este projeto apresenta uma excelente viabilidade devido à acessibilidade dos dados e às tecnologias disponíveis. Os dados de preços históricos da Bitcoin, volume de transações e indicadores adicionais, como sentimento social, estão amplamente disponíveis através de APIs públicas e bases de dados comerciais.

Os modelos escolhidos, como LSTM, Transformers e AutoRNN, oferecem flexibilidade para lidar com a natureza não linear e multivariada do problema. Ferramentas de código aberto, como PyTorch, TensorFlow e a biblioteca NeuralForecast, reduzem os custos operacionais e permitem replicabilidade. A utilização de hardware acessível, como GPUs comerciais, torna o treino de modelos eficiente em termos de tempo e custo.

Por outro lado, a escalabilidade deste projeto é um ponto de destaque. Uma vez desenvolvidos, os modelos podem ser ajustados para outros ativos ou até mesmo para previsões em mercados financeiros tradicionais, ampliando o impacto prático da solução.

4.1.4 Viabilidade Social

O impacto social deste projeto é significativo, sobretudo em dois aspectos principais: acessibilidade e inclusão financeira. As criptomoedas já transformaram o modo de como muitos indivíduos, especialmente em economias emergentes, gerem e investem o seu capital. Este trabalho contribui para essa transformação ao oferecer ferramentas preditivas que permitem decisões mais informadas e com uma maior margem de segurança.

Além disso, o trabalho reforça a literacia financeira, capacitando investidores de diferentes perfis a compreender e atuar em mercados complexos. Esta inclusão é particularmente relevante no contexto atual, onde há uma crescente procura de criptomoedas em regiões desenvolvidas e subdesenvolvidas como alternativa a sistemas bancários tradicionais.

No entanto, é importante considerar os riscos sociais associados, como a possibilidade de uso de previsões para manipulação de mercados. Este desafio reforça a necessidade de desenvolver modelos éticos e transparentes.

4.1.5 Viabilidade Cultural

Embora o impacto cultural seja menos tangível, é impossível ignorar a influência das criptomoedas na cultura moderna. A Bitcoin, em particular, tornou-se um símbolo de resistência contra os sistemas financeiros tradicionais. Este projeto pode ser visto como parte dessa narrativa cultural, posicionando-se como uma ponte entre tecnologia emergente e adoção cultural. A longo prazo, a criação de ferramentas preditivas robustas pode contribuir para a normalização das criptomoedas como instrumentos financeiros legítimos, superando resistências culturais e desconfiança por parte de setores mais tradicionais.

4.2 Pertinência

A pertinência deste trabalho baseia-se no facto de ser uma ferramenta de auxílio para os traders na toma de decisões isto é dar uma maior confirmação quando devem executar um buy ou sell.

5 - Solução Proposta

A solução proposta neste trabalho visa a previsão dos preços da Bitcoin, recorrendo a métodos avançados de machine learning e deep learning, com uma abordagem multi-variada que integra variáveis exógenas e dados históricos de forma estruturada. Este projeto destaca-se pela utilização combinada de modelos de elevada sofisticação, como as Redes LSTM (Long Short-Term Memory), o TFT (Temporal Fusion Transformer) e o N-BEATS, cada um explorando diferentes capacidades para lidar com as especificidades e complexidades inerentes às séries temporais financeiras.

A primeira etapa da proposta consiste na coleta e pré-processamento dos dados, envolvendo a recolha de informações históricas de preços e volumes de transação a partir de fontes credíveis, como a Binance ou a CoinMarketCap. Adicionalmente, são incorporados indicadores macroeconómicos e variáveis relacionadas com o sentimento social, extraídas de redes sociais e fontes de notícias financeiras. Após a coleta, os dados são submetidos a um processo de limpeza, normalização e estruturação em séries temporais, adequadas para a modelação preditiva.

Na fase de modelação, são implementadas as diferentes arquiteturas de deep learning. As Redes LSTM são empregues pela sua comprovada eficácia na captura de padrões temporais de longo prazo. O TFT, por sua vez, utiliza mecanismos de atenção para integrar múltiplas variáveis exógenas e explorar relações complexas entre estas. Já o N-BEATS é utilizado para decompor os dados em componentes hierárquicos, como tendência e sazonalidade, permitindo uma análise detalhada dos padrões subjacentes. A robustez e eficiência dos modelos são reforçadas através do ajuste automatizado de hiperparâmetros, recorrendo a técnicas avançadas como a busca em grelha (grid search) ou algoritmos genéticos, com o objetivo de otimizar o desempenho de cada modelo.

A precisão das previsões é assegurada através da aplicação da métrica HuberMQ-Loss, que combina as propriedades das métricas tradicionais de erro quadrático médio (MSE) e erro absoluto médio (MAE), promovendo uma penalização equilibrada de valores extremos (outliers) e atenuando o seu impacto no treino dos modelos. Complementarmente, outras métricas, como o MAPE (Erro Percentual Absoluto Médio), o RMSE (Raiz do Erro Quadrático Médio) e o MAE, são utilizadas para avaliar a eficácia e a consistência dos modelos, garantindo uma análise abrangente do desempenho preditivo.

Os modelos são validados através de validação cruzada, uma técnica que evita o overfitting e assegura que os resultados obtidos são generalizáveis para diferentes condições de mercado. Para avaliar a sua robustez, os modelos são testados em cenários que simulam a elevada volatilidade característica do mercado de criptomoedas. Os resultados desta análise são apresentados através de gráficos e tabelas comparativas que permitem avaliar a adequação de cada modelo aos diversos cenários.

Finalmente, realiza-se uma análise interpretativa dos resultados, com o objetivo de identificar os modelos mais adequados para cada tipo de contexto e discutir as limitações observadas durante a execução do projeto. Este processo culmina na elaboração de propostas para melhorias futuras, bem como na entrega de modelos preditivos treinados, prontos para aplicação em novos conjuntos de dados.

A presente proposta de solução apresenta-se como uma abordagem robusta, inovadora e escalável para enfrentar os desafios associados à previsão de preços da Bitcoin. A sua singularidade reside na combinação de inovação técnica, integração de variáveis exógenas e análise comparativa de desempenho entre modelos, respondendo de forma eficaz às exigências dos mercados financeiros contemporâneos.

6 - Metodologia e Planeamento

A abordagem metodológica adotada neste trabalho segue uma estratégia iterativa de desenvolvimento e experimentação com base nos princípios do ciclo CRISP-DM (Cross Industry Standard Process for Data Mining), adaptado ao contexto de previsão de séries temporais com machine learning.

As fases principais incluem:

1. **Compreensão do domínio:** Estudo aprofundado sobre o funcionamento dos mercados de criptomoedas, com foco na Bitcoin, bem como análise das necessidades de previsão por parte de traders e investidores.
2. **Recolha de dados:** Obtenção de dados históricos de preços e volumes de transações de fontes como a Binance e a CoinMarketCap, bem como dados alternativos (como sentimento social).
3. **Preparação dos dados:** Processamento dos dados em séries temporais multivariadas, com tratamento de valores nulos, normalização, criação de variáveis adicionais (ex. médias móveis, RSI, volatilidade) e segmentação em conjuntos de treino, validação e teste.
4. **Modelação:** Aplicação de diferentes modelos preditivos (LSTM, AutoTFT, NBEATS, NHITS), utilizando a biblioteca `NeuralForecast`. Foram aplicadas estratégias de ajuste automático de hiperparâmetros e validação cruzada temporal.
5. **Avaliação e validação:** Avaliação dos modelos com recurso a métricas como MAE, RMSE, MAPE e HuberMQLoss, com análise comparativa dos resultados.
6. **Documentação e iteração:** Os resultados foram documentados e usados para refinar a modelação, permitindo ajustar a abordagem consoante os insights obtidos.

O planeamento global do projeto encontra-se na Tabela 6.1, com as tarefas organizadas por semana e fase.

Tabela 6.1: Planeamento de atividades

Semana(s)	Atividade
S1-S2	Análise do problema, definição de objetivos
S3-S5	Levantamento de soluções e estudo do estado da arte
S6-S7	Recolha e análise exploratória dos dados
S8-S9	Pré-processamento dos dados e geração de features
S10-S12	Implementação e treino dos primeiros modelos (LSTM, NBEATS)
S13-S14	Implementação e afinação do TFT e NHITS
S15-S16	Avaliação de modelos, métricas e testes
S17	Consolidação dos resultados e documentação técnica

6.1 Resultados Parciais e Progresso Técnico

Até ao momento, foi concluída a preparação dos dados e o treino inicial de três modelos principais: LSTM, NBEATS e TFT. Os dados históricos foram organizados em séries tem-

porais com frequência diária e enriquecidos com variáveis técnicas como médias móveis e volume ajustado.

Os modelos foram avaliados com base em subconjuntos de treino e teste com `TimeSeriesSplit`, e os primeiros resultados indicam que o **NBEATS** obteve melhor desempenho em termos de MAE e MAPE, enquanto o **TFT** foi mais robusto a outliers com a métrica `HuberMQLoss`.

Gráficos de previsão já foram gerados para os três modelos, permitindo visualização clara da tendência, ciclos e desvios entre valores reais e previstos.

O código encontra-se em repositório Git e a estrutura modular do projeto já permite facilmente a inclusão de novos modelos ou fontes de dados.

6.2 Ligação ao Repositório Git

O código-fonte do projeto encontra-se disponível no repositório Git institucional, onde estão organizados todos os scripts e ficheiros relevantes para a preparação, treino, avaliação e visualização dos modelos preditivos.

- **Link do repositório:** <https://github.com/Fpinto99/TFC>

- **Organização do repositório:**

- `/data`: Scripts e datasets para pré-processamento
- `/models`: Treino e inferência dos modelos
- `/results`: Gráficos e ficheiros de métricas
- `/notebooks`: Experimentos interativos (Jupyter)
- `/docs`: Documentação auxiliar e estrutura do relatório

O repositório será mantido atualizado durante todas as fases do projeto, facilitando a colaboração entre membros da equipa, a reprodutibilidade dos resultados e a entrega final.

6.3 Planeamento Gantt

O planeamento foi inicialmente estruturado por semanas, com uma abordagem incremental e iterativa. A Tabela 6.1 resume as fases principais do projeto. O cronograma Gantt simplificado é apresentado abaixo, indicando o início e fim estimado de cada fase.




Figura 6.1: Cronograma Gantt simplificado do desenvolvimento do projeto, com fases e tarefas

6.3.1 Fluxo Metodológico do Projeto

A Figura 6.2 ilustra o pipeline metodológico seguido ao longo do desenvolvimento deste trabalho. O processo teve início com a recolha de dados históricos da Bitcoin, obtidos de fontes públicas fidedignas, que foram posteriormente sujeitos a um rigoroso processo de pré-processamento.

Esta fase incluiu a limpeza dos dados, tratamento de valores nulos, normalização e criação de variáveis auxiliares (ex.: médias móveis, RSI, volatilidade). Após a preparação, os dados foram segmentados em subconjuntos de treino e teste, respeitando a ordem temporal de modo a evitar *data leakage*.

Seguidamente, procedeu-se à definição dos modelos de previsão, entre os quais se destacam o LSTM, o AutoTFT e o NHITS, sendo cada um treinado individualmente com diferentes conjuntos de hiperparâmetros. O desempenho preditivo de cada arquitetura foi avaliado com base em métricas como o MAE, RMSE, MAPE e HuberMQLoss.

Por fim, as previsões obtidas foram analisadas tanto estatisticamente como visualmente, permitindo tirar conclusões sobre a robustez, estabilidade e adequação dos modelos ao contexto da Bitcoin.

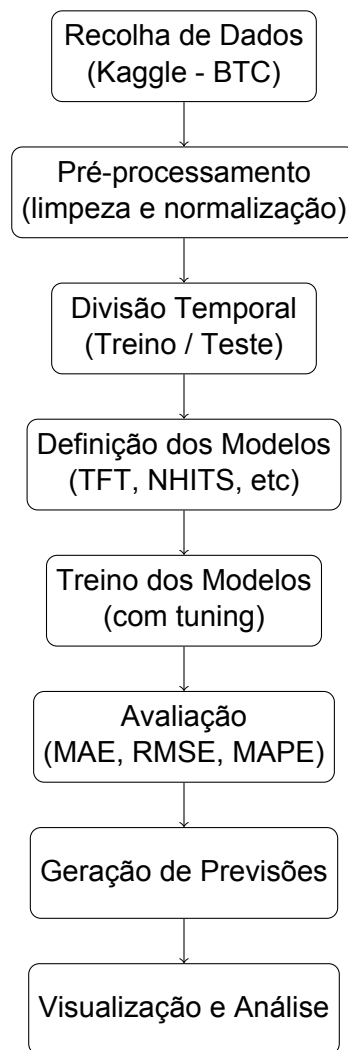


Figura 6.2: Pipeline do processo de previsão de preços da Bitcoin

6.3.2 Validação e Qualidade dos Dados

Os dados utilizados neste projeto foram obtidos através da plataforma pública Kaggle, nomeadamente do conjunto “Bitcoin Historical Data”, amplamente utilizado em estudos académicos na área da previsão financeira. Esta escolha baseou-se na sua elevada disponibilidade, reputação e consistência temporal.

Antes de qualquer etapa de modelação, os dados foram submetidos a um processo de verificação e preparação. Foram removidos registos nulos e duplicados, a coluna temporal foi convertida para o formato *datetime* e os valores foram ordenados cronologicamente. Esta sequência de passos visou garantir a integridade estrutural da série temporal.

Adicionalmente, os dados foram normalizados e enriquecidos com variáveis técnicas derivadas, como médias móveis e indicadores de volume, o que permitiu explorar relações multivariadas durante o treino dos modelos. A presença de outliers foi igualmente analisada de forma visual e estatística, tendo-se optado por uma abordagem robusta a essas anomalias, nomeadamente através do uso da função de perda HuberMQLoss.

A divisão entre treino e teste foi feita de forma sequencial, respeitando a natureza temporal dos dados. Assim, assegurou-se que os modelos foram treinados apenas com informação passada, evitando qualquer contaminação da fase de teste (*data leakage*).

A confiabilidade dos dados foi assumida com base na reputação da fonte e na consis-

tência interna dos registros após o processo de validação, tornando-os adequados para os objetivos de previsão de curto e médio prazo definidos neste trabalho.

7 - Calendário

7.1 Estrutura do Planeamento

Este plano de trabalho foca-se na organização das tarefas remanescentes do projeto, estruturadas em etapas com base nos princípios de gestão de projetos e inclui um detalhamento das tarefas a realizar na fase seguinte.

Estimativas de alto nível para as atividades até a conclusão. Indicadores de progresso, dificuldades enfrentadas e ajustes ao plano inicial.

7.2 Tarefas Detalhadas da Fase Seguinte

7.2.1 Modelagem e Testes Finais

Descrição

Realizar ajustes finais nos modelos de previsão, otimizando parâmetros, métricas e dados de entrada.

Subtarefas

Refinar o modelo TFT com hiperparâmetros ajustados. Incorporar variáveis exógenas, como sentimento social e dados de volume. Comparar os resultados entre modelos (LSTM, NBEATS, RNN, NHITS, KAN) para validação final. Testar a robustez dos modelos em cenários de alta volatilidade.

7.2.2 Documentação e Redação do Estado da Arte

Descrição

Expandir e finalizar a revisão bibliográfica, enfatizando a inovação técnica e comparações com a literatura existente.

Subtarefas

Revisar e integrar referências adicionais relevantes. Estruturar a análise comparativa detalhada. Escrever as secções de benchmarking e justificar as escolhas do trabalho.

7.2.3 Desenvolvimento da Análise de Resultados

Descrição

Realizar análise quantitativa e qualitativa dos resultados obtidos, comparando métricas e validando hipóteses.

Subtarefas

Calcular métricas como RMSE, MAE, MAPE e HuberMQLoss para cada modelo. Produzir gráficos comparativos e tabelas de desempenho. Interpretar os resultados em termos práticos e acadêmicos.

7.2.4 Elaboração de Conclusões e Propostas Futuras

O presente Trabalho Final de Curso permitiu evidenciar, com base em fundamentos teóricos e experimentais, o potencial das abordagens de *machine learning* e *deep learning* na previsão dos preços da Bitcoin — um ativo altamente volátil, influenciado por fatores endógenos e exógenos, e cuja modelação constitui um dos maiores desafios no domínio das séries temporais financeiras.

Através da implementação e avaliação de diversos modelos — nomeadamente LSTM, TFT, NHITS, KAN, NBEATS e RNN — foi possível analisar o seu desempenho preditivo sob duas perspetivas distintas: com hiperparâmetros por defeito e com configurações ajustadas manualmente. Os resultados demonstraram que a afinação dos hiperparâmetros desempenha um papel determinante na eficácia dos modelos, com destaque para o NHITS, que após calibração apresentou os melhores resultados globais em métricas como MAE, RMSE, MAPE e HuberMQLoss.

Verificou-se, também, que a escolha da função de perda HuberMQLoss contribuiu significativamente para a robustez dos modelos face à presença de *outliers*, sendo especialmente relevante num contexto financeiro caracterizado por eventos extremos e variações imprevisíveis. Por outro lado, modelos como o TFT, que inicialmente apresentaram um desempenho promissor, mostraram-se sensíveis a ajustes manuais, revelando a necessidade de estratégias de otimização mais robustas e automatizadas.

Neste sentido, com base nas limitações e aprendizagens identificadas, propõem-se as seguintes linhas de desenvolvimento futuro:

- **Automatização da otimização de hiperparâmetros**, recorrendo a frameworks como o *Optuna*, de modo a minimizar a intervenção manual e explorar sistematicamente combinações ótimas de parâmetros;
- **Integração de variáveis exógenas mais diversificadas**, tais como indicadores macroeconómicos, métricas de sentimento social ou dados de volume provenientes de fontes alternativas, enriquecendo assim o contexto informacional dos modelos;
- **Aplicação de técnicas de *ensemble***, como o *stacking* ou o *blending*, que combinem os pontos fortes de diferentes arquiteturas e contribuam para uma previsão mais estável e precisa;
- **Implementação de pipelines de previsão contínua**, com recurso a validação por janela deslizante (*rolling window*), possibilitando simulações em tempo real mais representativas da dinâmica dos mercados;
- **Desenvolvimento de interfaces de visualização interativas**, com recurso a ferramentas como o *Streamlit* ou *Dash*, de forma a disponibilizar previsões, métricas e gráficos de forma acessível a utilizadores finais;
- **Extensão da abordagem a outros ativos financeiros**, como outras criptomoedas (ex. Ethereum, Solana) ou instrumentos tradicionais (ações, índices), permitindo validar a generalização dos modelos propostos;
- **Exploração futura de algoritmos de aprendizagem por reforço**, com o intuito de integrar as previsões num sistema de tomada de decisão sequencial para estratégias automatizadas de *trading*.

Em suma, o trabalho aqui desenvolvido contribui não só com uma análise comparativa entre múltiplas arquiteturas preditivas, mas também com uma base metodológica sólida para a construção de sistemas de previsão robustos, escaláveis e orientados para a tomada de decisão em ambientes financeiros altamente dinâmicos.

8 - Resultados

Com o objetivo de avaliar o desempenho dos modelos preditivos utilizados neste trabalho, foram realizadas duas experiências distintas. A primeira considerou os modelos com os seus hiperparâmetros por defeito, enquanto a segunda aplicou valores modificados manualmente, com o intuito de melhorar a capacidade preditiva.

Na configuração por defeito, os modelos TFT e KAN apresentaram os melhores resultados em termos globais, com valores reduzidos de MAE, MAPE, RMSE e HuberMQ-Loss, o que indica uma boa capacidade de adaptação às características da série temporal analisada. O TFT, em particular, destacou-se como o modelo mais equilibrado, com o menor MAE (1614.44) e uma das HuberMQLoss mais baixas (807.09), sinalizando um forte desempenho no cenário inicial.

Modelos como o RNN e o NHITS, por sua vez, registaram os piores resultados nesta fase, com erros significativamente mais elevados. Estes resultados sugerem que, sem qualquer ajuste, estas arquiteturas não são tão eficazes para o tipo de dados utilizados, podendo estar a sofrer de sobreajuste ou subajuste, conforme a natureza da arquitetura e profundidade da rede.

Após a modificação dos hiperparâmetros, observou-se uma inversão no desempenho relativo dos modelos. O NHITS, que inicialmente apresentava resultados desfavoráveis, passou a ser o modelo com os melhores valores globais, destacando-se com um MAE de 1590.67 e uma HuberMQLoss de apenas 795.21. Esta melhoria é indicativa de uma afinação eficaz dos hiperparâmetros, evidenciando o potencial da arquitetura quando corretamente calibrada.

Em contraste, o TFT, que inicialmente liderava, registou um decréscimo significativo no desempenho após a modificação dos hiperparâmetros, com um aumento considerável em todas as métricas. Este fenómeno sugere que a arquitetura TFT é sensível a alterações nos parâmetros de configuração, exigindo uma estratégia de otimização mais robusta e talvez mais automatizada (por exemplo, via Optuna ou GridSearch).

Os modelos LSTM, KAN e RNN também apresentaram melhorias subtis, mas nenhum deles conseguiu ultrapassar o NHITS otimizado. Esta constatação é relevante, pois demonstra que modelos clássicos de séries temporais, como LSTM e RNN, embora mais simples, ainda beneficiam de ajustes manuais e podem competir com modelos mais recentes em determinados cenários.

A ausência de resultados modificados para o modelo NBEATS limita a análise da sua performance otimizada, ficando a avaliação restrita à sua configuração por defeito. Ainda assim, os seus valores iniciais indicam uma performance mediana, com espaço para melhorias em experiências futuras.

Em síntese, os resultados obtidos demonstram que a escolha dos hiperparâmetros desempenha um papel crucial no desempenho dos modelos. O processo de afinação não é uniforme e pode ter efeitos altamente positivos (como no NHITS) ou negativos (como no TFT), dependendo da arquitetura e da natureza dos dados. Esta análise reforça a importância da experimentação sistemática e da validação cruzada no desenvolvimento de soluções robustas de previsão.

Tabela 8.1: Resultados dos modelos com hiperparâmetros por defeito

Modelo	MAE	MAPE	RMSE	HuberMQLoss
TFT	1614.44	0.0380	1985.61	807.09
NHITS	3882.17	0.0925	4619.43	1940.96
KAN	1643.40	0.0388	2085.79	821.58
LSTM	2561.74	0.0605	2864.41	1280.75
RNN	4431.55	0.1052	4788.94	2215.65
NBEATS	4936.35	0.1174	5851.52	2468.05

Tabela 8.2: Resultados dos modelos após ajuste de hiperparâmetros

Modelo	MAE	MAPE	RMSE	HuberMQLoss
TFT	3867.11	0.0917	4116.66	1933.43
NHITS	1590.67	0.0378	2083.42	795.21
KAN	3735.15	0.0891	4418.10	1867.45
LSTM	3076.11	0.0729	3548.85	1537.93
RNN	3992.64	0.0952	4559.34	1996.19
NBEATS	1888.07	0.045	2376.54	943.91

Com o intuito de avaliar a eficácia preditiva dos modelos implementados neste trabalho, foi realizada uma comparação detalhada entre os **valores reais de fecho da Bitcoin durante o mês de dezembro de 2023** e os valores previstos por seis modelos distintos: **TFT, RNN, LSTM, KAN, NBEATS e NHITS**, considerando tanto a configuração de *hiperparâmetros por defeito* como a configuração *modificada manualmente*.

A Tabela 8.3 apresenta, para cada um dos 31 dias do mês, o valor real da Bitcoin e as respetivas previsões de cada modelo. Esta abordagem permite uma avaliação granular da consistência e precisão dos modelos ao longo do tempo, destacando eventuais padrões de subajuste, sobreajuste ou instabilidade preditiva.

Observa-se que os modelos exibem comportamentos distintos ao longo do mês. O **modelo NHITS com hiperparâmetros modificados**, por exemplo, apresenta previsões frequentemente mais próximas do valor real, especialmente nos dias de maior oscilação. Este desempenho é sustentado pelas métricas quantitativas obtidas na avaliação global, onde o NHITS modificado alcançou um **MAE de 1590.67, MAPE de 0.0378, RMSE de 2083.42 e HuberMQLoss de 795.21**, destacando-se como o mais eficaz após afinação dos parâmetros.

Em contraste, o **modelo RNN com configuração por defeito** registou os piores valores, com **MAE de 4431.55, MAPE de 0.1052, RMSE de 4788.94 e uma HuberMQLoss de 2215.65**, demonstrando uma tendência sistemática para subestimar os valores reais da Bitcoin. Esta limitação é coerente com a natureza da arquitetura, mais sensível à propagação de gradientes e menos robusta em séries temporais financeiras de elevada volatilidade.

O modelo **TFT**, apesar de ter exibido o melhor desempenho na configuração por defeito (**MAE de 1614.44, HuberMQLoss de 807.09**), apresentou uma degradação acentuada com os hiperparâmetros modificados (**MAE de 3867.11, MAPE de 0.0917**), o que evidencia a sua sensibilidade à afinação manual e à possível necessidade de estratégias mais sofisticadas de otimização (como o uso de *Optuna* ou *Grid Search*).

Além disso, a comparação permite observar que em certos dias — como a 7, 14 ou 28 de dezembro — a discrepância entre os valores reais e algumas previsões é particularmente acentuada. Estes desvios podem estar associados a **eventos exógenos** no

mercado cripto, não contemplados pelos modelos univariados implementados, sugerindo que a inclusão de variáveis externas poderá melhorar a capacidade preditiva.

Em suma, a análise da série de previsões ao longo de um mês completo mostra não apenas a **precisão média dos modelos**, mas também a **sua estabilidade temporal**, a capacidade de adaptação a variações abruptas e a coerência com o comportamento real do ativo. Estas observações complementam a análise estatística feita anteriormente e devem ser ponderadas na seleção do modelo final a ser utilizado num ambiente de previsão em tempo real.

Tabela 8.3: Comparação entre valores reais da BTC e previsões dos modelos (dezembro de 2023)

ds	y	TFT_Default	TFT_Modificado	RNN_Default	RNN_Modificado	LSTM_Default	LSTM_Modificado	KAN_Default	KAN_Modificado	NBEATS_Default	NBEATS_Modificado	NHITS_Default	NHITS_Modificado
2023-12-01	37629.36	38932.06	36928.14	36948.82	34585.28	38909.37	36713.81	39147.97	39012.85	37794.79	37956.14	37937.14	37640.19
2023-12-02	38652.59	39039.06	37211.72	36366.13	34593.75	39052.54	36585.90	39177.69	39637.55	37874.70	38590.28	37887.03	37903.29
2023-12-03	39298.16	39124.36	37424.24	35955.84	34736.20	39093.80	36436.13	39451.87	39986.96	37625.79	38033.18	38438.09	37719.87
2023-12-04	39978.63	39196.89	37428.20	35556.01	34634.50	39078.91	36242.00	38502.21	40294.46	38210.66	38081.86	39065.44	37493.28
2023-12-05	41421.15	39265.16	37326.06	35418.06	34833.69	39033.91	36191.12	38794.44	40734.94	38619.27	38524.00	39420.94	37697.28
2023-12-06	43478.08	39342.94	37237.87	35408.49	35020.25	38954.09	36216.41	38813.87	40334.23	38559.46	38087.98	39966.11	38191.67
2023-12-07	42880.65	39434.70	37224.95	35501.04	35208.80	38849.21	36334.93	39849.80	41226.24	39544.11	38622.64	40343.01	38718.20
2023-12-08	43125.30	39537.44	37273.17	35522.04	35161.70	38722.09	36671.33	39247.62	41071.95	40297.50	38551.61	41221.16	39473.86
2023-12-09	43627.60	39647.85	37325.47	35742.36	35491.44	38630.69	37407.14	39652.83	42671.01	41358.79	39304.84	41869.89	39774.47
2023-12-10	43593.29	39765.81	37371.21	36163.96	36106.75	38600.91	38222.07	39475.62	42815.52	41627.96	38622.03	42334.72	40346.03
2023-12-11	40234.58	39890.62	37426.02	36894.40	37040.43	38707.54	38628.85	38815.59	42710.10	42315.61	39342.28	42811.86	40877.39
2023-12-12	40667.56	40020.00	37503.18	37665.33	37995.52	38914.61	39453.18	40238.65	43277.11	42888.84	40173.93	43241.76	41464.88
2023-12-13	40676.87	40147.94	37563.39	38217.86	38657.72	39103.06	39607.20	40083.53	43908.51	44318.06	40223.52	43887.76	41911.14
2023-12-14	41767.09	40268.43	37607.35	38383.92	38839.54	39240.09	39505.64	40061.23	44290.04	44626.51	40888.21	43965.19	42462.56
2023-12-15	41692.97	40378.12	37646.09	37821.13	37920.66	39283.84	39298.80	40332.20	44962.07	44945.18	41056.46	44124.83	42705.07
2023-12-16	41723.11	40477.55	37682.83	37246.12	37352.51	39291.29	39172.84	40387.91	45098.81	45227.13	41328.13	44303.89	43117.17
2023-12-17	41274.54	40570.68	37721.21	36903.00	37268.17	39278.45	39115.59	41054.88	45331.44	45678.72	42354.72	44818.26	42886.36
2023-12-18	40530.26	40660.92	37767.54	36865.38	37550.02	39267.13	39120.29	40697.18	45409.98	46414.35	42892.91	45255.51	42943.42
2023-12-19	41826.34	40742.94	37832.32	37095.04	38033.81	39273.03	39170.19	40891.94	46246.10	46706.30	43094.48	45581.45	43108.28
2023-12-20	42223.82	40805.60	37918.38	37427.25	38508.77	39300.36	39244.74	40951.15	46517.89	46603.63	43520.62	46359.13	43126.10
2023-12-21	43330.05	40847.10	38005.51	37876.90	39125.53	39365.41	39353.08	40165.91	47146.66	48215.92	44028.82	47043.77	43541.03
2023-12-22	43441.97	40872.82	38086.08	37858.10	38908.55	39398.12	39400.54	40528.04	46809.01	49215.98	44281.79	47459.43	42942.12
2023-12-23	43351.36	40886.99	38170.49	37596.94	38454.17	39401.76	39433.48	41460.35	47635.79	49511.22	44570.11	48048.09	42833.89
2023-12-24	42786.92	40892.14	38267.57	37775.97	38996.81	39447.00	39537.69	40859.70	48139.20	50047.66	44777.81	48189.22	42852.22
2023-12-25	42765.77	40890.23	38378.09	38222.62	39819.44	39530.96	39666.26	41168.81	48590.28	50932.01	43866.77	48618.16	42702.59
2023-12-26	41676.49	40882.84	38494.40	38738.69	40545.75	39651.08	39814.44	41038.67	49287.68	50925.28	44161.88	48886.75	42682.50
2023-12-27	42167.58	40871.29	38615.42	38970.62	40758.23	39766.64	39939.18	40362.97	49540.55	51414.77	44246.28	49352.61	42989.68
2023-12-28	42318.55	40856.63	38743.74	38882.95	40596.96	39855.26	40042.19	41915.65	48718.25	52614.77	43555.72	50242.42	42852.56
2023-12-29	41424.06	40839.70	38880.15	38753.58	40528.74	39931.86	40154.62	41240.85	49697.80	52034.14	43674.62	50172.94	43284.52
2023-12-30	41598.23	40821.17	38890.78	38890.78	40904.73	40021.92	40099.68	41219.01	49315.63	52361.71	43719.58	50565.64	43235.82
2023-12-31	41998.25	40801.58	39156.42	39059.92	41170.90	40110.06	40470.40	41316.14	50035.98	53050.97	44342.80	51039.09	43316.56




Figura 8.1: Evolução do modelo LSTM ao longo de dezembro 2023




Figura 8.2: Evolução do modelo TFT ao longo de dezembro 2023




Figura 8.3: Evolução do modelo NBEATS ao longo de dezembro 2023




Figura 8.4: Evolução do modelo NHITS ao longo de dezembro 2023




Figura 8.5: Evolução do modelo RNN ao longo de dezembro 2023




Figura 8.6: Evolução do modelo KAN ao longo de dezembro 2023

Prova de Conceito (PoC)

Para além da avaliação estatística e visual do desempenho dos modelos preditivos, foi desenvolvida uma Prova de Conceito (PoC) com o objetivo de demonstrar a aplicabilidade prática das soluções propostas. Esta PoC foi baseada no modelo NHITS, uma vez que este apresentou o melhor desempenho global após a afinação manual de hiperparâmetros.

A PoC consiste num protótipo interativo construído com recurso à biblioteca *Streamlit*, permitindo ao utilizador final aceder a previsões geradas pelo modelo, visualizar a evolução dos dados históricos da Bitcoin e comparar, em tempo real, os valores reais com os valores previstos. O painel desenvolvido permite ainda consultar as métricas de erro associadas a cada previsão, fornecendo uma visão clara da fiabilidade do modelo.

As principais funcionalidades da PoC incluem:

- Visualização dos dados históricos de fecho da Bitcoin;
- Seleção de janelas temporais para previsão;
- Comparação gráfica entre previsões e valores reais;
- Apresentação das métricas MAE, RMSE, MAPE e HuberMQLoss por período;
- Interface acessível e adaptável a possíveis expansões futuras.

Este protótipo reforça a utilidade prática dos modelos desenvolvidos, servindo como base para uma possível aplicação comercial ou institucional. A arquitetura modular da aplicação permite a sua adaptação a outros ativos financeiros, integração com APIs de dados em tempo real (como Yahoo Finance ou Binance) e inclusão de lógica de alerta automatizada para apoio à tomada de decisão em ambientes de investimento.

A PoC demonstra, assim, que os modelos não apenas apresentam desempenho robusto em ambiente experimental, como também possuem aplicabilidade real e valor acrescentado para utilizadores que operam em contextos de elevada volatilidade e incerteza.




Figura 8.7: Comparação entre os valores reais e as previsões do modelo NHITS com hiperparâmetros modificados (gráfico Streamlite)

Bibliografia

- [1] João P. Matos-Carvalho. *The Lusófona L^AT_EX Template User's Manual*. Lusófona University. 2024. URL: <https://github.com/jpmcarvalho/UL-Thesis>.
- [2] "Forecasting the Bitcoin price using the various Machine Learning". Em: *Journal of Machine Learning Research* (2025). Accessed: 2025-06-14. URL: <https://www.sciencedirect.com/science/article/pii/S2772941925000274>.
- [3] Abdullah Alshamsi e Andrey Andryushechkin. "A Review of Bitcoin Price Prediction Based on Deep Learning Algorithms". Em: *ResearchGate* (2024). Accessed: 2025-06-14. URL: https://www.researchgate.net/publication/382963643_A_Review_of_Bitcoin_Price_Prediction_Based_on_Deep_Learning_Algorithms.
- [4] Md Zahangir Alom e Tarek M. Taha. "Deep learning for Bitcoin price direction prediction: models and trading strategies empirically compared". Em: *Financial Innovation* (2024). Accessed: 2025-06-14. DOI: 10.1186/s40854-024-00643-1. URL: <https://doi.org/10.1186/s40854-024-00643-1>.
- [5] "Predicting Bitcoin (BTC) Price in the Context of Economic Theories". Em: *PMC* (2022). Accessed: 2025-06-14. URL: <https://www.ncbi.nlm.nih.gov/pmc/articles/PMC9601835/>.
- [6] R. Karthik e A. Sinha. *Comparative Study of Bitcoin Price Prediction*. arXiv preprint arXiv:2405.08089. Accessed: 2025-06-14. 2024. URL: <https://arxiv.org/abs/2405.08089>.
- [7] Shivani Kumari, Richa Sharma e Ekta Khurana. "A Comparative Study: LSTM, GRU, VGG16, VGG19 para previsão de Bitcoin". Em: *Proceedings of Advanced Computational Intelligence*. Accessed: 2025-06-14. Springer, 2025. URL: https://link.springer.com/chapter/10.1007/978-981-96-1348-9_13.