



Previsão de evolução de criptomoedas

MIGUEL FERNANDO PEREIRA DE ARAÚJO MACHADO

Setembro de 2024

PREVISÃO DE EVOLUÇÃO DE CRIPTOMOEDAS

Miguel Fernando Pereira de Araújo Machado

**Dissertação para obtenção do Grau de Mestre em
Engenharia Informática, Área de Especialização em
Sistemas de Informação e Conhecimento**

Orientador: Doutora Fátima Rodrigues

Júri:

Presidente:

Vogais:

Declaração de Integridade

Declaro ter conduzido este trabalho académico com integridade.

Não plagiei ou apliquei qualquer forma de uso indevido de informações ou falsificação de resultados ao longo do processo que levou à sua elaboração.

Portanto, o trabalho apresentado neste documento é original e de minha autoria, não tendo sido utilizado anteriormente para nenhum outro fim.

Declaro ainda que tenho pleno conhecimento do Código de Conduta Ética do P.PORTO.

ISEP, Porto, 13 de setembro de 2024

Resumo

O mercado das criptomoedas é atualmente uma das áreas de maior interesse de investimento, atraindo investidores desde os mais experientes até aos mais casuais, e embora possa proporcionar elevadas rentabilidades também representam um elevado risco devido à sua elevada volatilidade.

Neste contexto a inteligência artificial, sobretudo através dos algoritmos de aprendizagem profunda e aprendizagem máquina tem assumido um papel preponderante no desenvolvimento de aplicações que permitam aconselhar investidores, tentando maximizar os retornos e reduzir riscos de investimento.

O presente trabalho propõe um sistema de previsão do preço de fecho de dez das principais criptomoedas atualmente presentes no mercado, disponível numa aplicação web, capaz de efetuar previsões de uma até quatro horas. Para tal foram analisados e testados diferentes modelos com diferentes algoritmos de aprendizagem máquina e aprendizagem profunda, como as Redes Neurais Recorrentes, algoritmos de análise temporal como ARIMA e até alguns algoritmos de regressão mais convencionais.

Para comparação dos algoritmos, foram usados os registos ao minuto dos preços da Bitcoin relativos ao período de 30 dias, para a previsão a 60 minutos, e o modelo que apresentou melhor desempenho foi o de Redes Neurais GRU, usando todos os atributos das cotações, obtendo um MAPE = 0,09%, MSE=5954,89, RMSE=77,17 e MAE=60,20 .

Palavras-chave: Previsão, Criptomoeda, Aprendizagem Máquina, Series Temporais

Abstract

The cryptocurrency market is currently one of the most interesting areas for investment, attracting both experienced and casual investors. While it can offer high returns, it also poses significant risks due to its high volatility.

In this context, artificial intelligence, particularly through deep learning and machine learning algorithms, has played a key role in developing applications that provide investment advice, aiming to maximize returns and reduce investment risks.

This study proposes a system for forecasting the closing prices of ten of the leading cryptocurrencies currently available in the market, presented in a web application capable of making predictions ranging from one to four hours. To achieve this, different models using various machine learning and deep learning algorithms were analyzed and tested, including Recurrent Neural Networks, time series analysis algorithms such as ARIMA, and even some more conventional regression algorithms.

For algorithm comparison, minute step Bitcoin price data over a 30-day period was used to forecast prices 60 minutes ahead. The model that showed the best performance was the GRU Neural Networks model, using all quote attributes, achieving a MAPE = 0.09%, MSE = 5954.89, RMSE = 77.17, and MAE = 60.20.

Keywords: Forecasting, Cryptocurrency, Machine Learning, Time Series

Agradecimentos

A realização do presente trabalho requereu para além do esforço, do tempo e dos recursos, o apoio de algumas pessoas às quais pretendo expressar o meu agradecimento.

À orientadora, Professora Doutora Fátima Rodrigues, não só pelos conselhos e ideias a incorporar no presente trabalho, mas também pelos ensinamentos e motivação para a área de aprendizagem máquina obtidos na Unidade Curricular de Descoberta de Conhecimento.

À minha esposa Anabela, por ter-me apoiado incondicionalmente, não só durante a realização deste trabalho, mas também durante todo o curso de mestrado.

Aos meus colegas de curso, sobretudo de grupo de todas as unidades curriculares pela entajuda e pela partilha de experiências e conhecimentos.

E a todos os que de alguma forma contribuíram para realização desta dissertação, o meu mais sincero obrigado!

Índice

1	Introdução	1
1.1	Contexto	1
1.2	Problema	2
1.3	Objetivos	2
1.4	Considerações éticas	3
1.5	Metodologia	3
1.6	Estrutura do documento	4
2	Estado da arte	7
2.1	Bitcoin	7
2.1.1	Séries temporais	9
2.2	Aprendizagem máquina	10
2.2.1	ARIMA (<i>Auto-Regressive Integrated Moving Average</i>)	10
2.2.2	Redes Neurais Recorrentes LSTM (<i>Long Short-Term Memory</i>)	12
2.2.3	Redes Neurais GRU (<i>Gated Recurrent Unit</i>)	14
2.2.4	XGboost	16
2.2.5	Support Vector Machine	17
2.2.6	Random Forest	18
2.2.7	Regressão Linear	20
2.3	Medidas de avaliação dos modelos	20
2.4	Trabalhos Relacionados	21
3	Implementação e avaliação dos modelos	27
3.1	Conjuntos de dados	27
3.2	Limpeza e preparação dos dados	31
3.3	Modelação	31
3.3.1	Redes Neurais LSTM	32
3.3.2	Redes Neurais GRU	33
3.3.3	SARIMA	34
3.3.4	Regressão Linear	35
3.3.5	Random Forest	36
3.3.6	Support Vector Machine	37
3.3.7	XGBoost	38
3.3.8	LightGBM	39
3.4	Comparação do desempenho dos modelos	40
3.5	Comparação com trabalhos relacionados	43
4	Sistema	47
4.1	Estrutura do sistema	48

4.1.1	Dados	48
4.1.2	Modelos	48
4.1.3	Previsões	49
4.2	Aplicação web	49
5	Conclusão e trabalho futuro.....	53

Lista de Figuras

Figura 1 – Metodologia CRISP-DM [5].....	4
Figura 2 – Representação gráfica de séries temporais estacionárias e não estacionárias [10].	10
Figura 3 – Representação gráfica da arquitetura LSTM [6]	14
Figura 4 – Representação gráfica da arquitetura GRU [6]	15
Figura 5 – Estrutura do modelo XGBoost [25]	17
Figura 6 – Distribuição das criptomoedas pelos artigos estudados.....	22
Figura 7 – Tipos de previsão presentes nos artigos estudados	22
Figura 8 – Tipos de atributos usados nos artigos estudados	23
Figura 9 – Distribuição dos períodos dos conjuntos de dados dos artigos estudados	24
Figura 10 – Distribuição dos modelos de aprendizagem máquina nos artigos estudados.....	24
Figura 11 – Distribuição das métricas de desempenho nos artigos estudados.....	25
Figura 12 – Valores de fecho das criptomoedas	30
Figura 13 – Testes e validações do modelo LSTM.....	33
Figura 14 – Testes e validações do modelo GRU	34
Figura 15 – Teste do modelo SARIMA.....	35
Figura 16 – Testes e validações do modelo Regressão Linear	36
Figura 17 – Testes e validações do modelo Random Forest.....	37
Figura 18 – Testes e validações do modelo SVM	38
Figura 19 – Testes e validações do modelo XGBoost.....	39
Figura 20 – Testes e validações do modelo LightGBM.....	40
Figura 21 – Desempenho do modelo GRU para os diferentes horizontes de previsão	41
Figura 22 – Desempenhos do modelo GRU para todas as criptomoedas e diferentes horizontes de previsão.....	43
Figura 23 – Componentes do sistema.....	48
Figura 24 – Estrutura do sistema	48
Figura 25 – Diagrama de uso do sistema	49
Figura 26 – Ecrã da App web.....	50
Figura 27 – Seleção das criptomoedas da App web.....	50
Figura 28 – Atualização de dados na App web	50
Figura 29 – Visualização dos dados na App web.....	51
Figura 30 – Treino dos modelos na App web.....	52
Figura 31 – Previsões na App web	52

Lista de Tabelas

Tabela 1: Variação dos valores das métricas de desempenho dos artigos estudados	25
Tabela 2: Informação e distribuição dos valores de Fecho e Volume de cada criptomoeda	28
Tabela 3: Desempenho do modelo LSTM	33
Tabela 4: Desempenho do modelo GRU	34
Tabela 5: Desempenho do modelo SARIMA	35
Tabela 6: Desempenho do modelo Regressão Linear	36
Tabela 7: Desempenho do modelo Random Forest	37
Tabela 8: Desempenho do modelo SVM.....	38
Tabela 9: Desempenho do modelo XGBoost	39
Tabela 10: Desempenho do modelo LightGBM	39
Tabela 11: Desempenho do modelo GRU para os diferentes horizontes de previsão	41
Tabela 12: Valores de MSE do modelo GRU para as diferentes criptomoedas	42
Tabela 13: Valores de RMSE do modelo GRU para as diferentes criptomoedas.....	42
Tabela 14: Valores de MAE do modelo GRU para as diferentes criptomoedas	42
Tabela 15: Valores de MAPE do modelo GRU para as diferentes criptomoedas	42
Tabela 16: Valores de nRMSE do modelo GRU para as diferentes criptomoedas.....	42
Tabela 17: Valores das métricas de desempenho dos trabalhos relacionados	44

Acrónimos e Símbolos

Lista de Acrónimos

ANN	<i>Artificial Neural Networks</i>
ARIMA	<i>Auto-Regressive Integrated Moving Average</i>
AUC	<i>Area Under Curve</i>
CNN	<i>Convolutional Neural Networks</i>
ELM	<i>Extreme Machine Learning</i>
GRU	<i>Gated Recurrent Unit</i>
KNN	<i>K-Nearest Neighbors</i>
LASSO	<i>Least Absolute Shrinkage and Selection Operator</i>
LINREG	<i>Linear Regression</i>
LOGREG	<i>Logistic Regression</i>
LSTM	<i>Long Short-Term Memory</i>
MAE	<i>Mean Absolute Error</i>
MAPE	<i>Mean Absolute Percentage Error</i>
MLP	<i>Multilayer Perceptron</i>
MSE	<i>Mean Squared Error</i>
RMSE	<i>Root Mean Squared Error</i>
RNN	<i>Recurrent Neural Network</i>
SVC	<i>Support Vector Classifier</i>
SVM	<i>Support Vector Machine</i>
SVR	<i>Support Vector Regressor</i>

1 Introdução

1.1 Contexto

As criptomoedas constituem, atualmente, um mercado de investimento altamente atrativo, mas apresentam um elevado risco devido à sua extrema volatilidade. As criptomoedas não são regulamentadas por nenhuma instituição bancária ou bolsa de valores, nem seguem as mesmas regras dessas entidades. São um capital digital global, descentralizado e permitem a transição de fundos à escala mundial ao segundo sem supervisão prévia. Os investidores enfrentam a questão de 'onde investir?', devido à grande quantidade de criptomoedas disponíveis no mercado, com novos ativos a surgir diariamente e outros a desaparecer. Existem algumas criptomoedas com historial mais consistente, mas a que tem mais relevância e que iniciou toda esta revolução é a Bitcoin, que foi lançada em 2008 [1].

As oscilações de preço das criptomoedas ocorrem minuto a minuto, 24 horas por dia. Por isso, os especialistas precisam estar constantemente atentos às mudanças e bem informados para gerar indicadores de mercado. Nesse contexto, surgiram sistemas informáticos baseados em inteligência artificial, que atuam como sistemas de apoio à decisão, utilizando algoritmos de aprendizagem máquina para elaborar projeções futuras a partir de dados históricos [2]. Este tipo de análise de dados indexados no tempo denomina-se série temporal.

Existe um vasto leque de modelos que podem ser implementados usando várias técnicas de aprendizagem máquina, tais como análise de séries temporais, modelos de regressão e até mesmo modelos de aprendizagem profunda. Os resultados dependerão da quantidade e qualidade dos dados disponíveis, dos atributos utilizados para o treino e do tipo de previsão desejada.

1.2 Problema

Os valores de preço das criptomoedas representam uma série temporal não estacionária, ou seja, os padrões observados não são constantes ao longo do tempo, logo não se irão verificar no futuro, e o desafio de desenvolver um modelo de aprendizagem máquina que possa elaborar projeções fiáveis pode ser uma tarefa bastante difícil de atingir.

Os modelos de aprendizagem máquina atualmente existentes não sendo difíceis de implementar, podem requerer elevados recursos computacionais dependendo da dimensão dos registos e atributos usados no processo de treino.

Se a quantidade de atributos pode ter impacto no desempenho, a seleção desses atributos para o processo de aprendizagem também tem impacto nos resultados, pelo que é necessária uma escolha criteriosa dos atributos que podem refinar as projeções. Nem sempre mais informação ou um número elevado de “atributos” proporciona melhores modelos [3].

Outro fator que pode impactar os resultados é o horizonte temporal dos dados. Comportamentos observados há cinco ou dez anos podem não refletir os padrões atuais. No entanto, um horizonte temporal muito curto pode resultar em dados insuficientes para previsões fiáveis dos modelos [3].

Os resultados dos modelos de aprendizagem máquina também dependerão do tipo de projeção que se pretende, ou seja, se se vai prever uma valorização ou desvalorização no minuto, hora, dia ou dias seguintes, ou qual vai ser o valor do preço no minuto, hora, dia ou dias seguintes.

1.3 Objetivos

O principal objetivo do presente trabalho é analisar o desempenho de diferentes modelos de aprendizagem máquina para previsão de preço de criptomoedas e desenvolver uma aplicação que utilize o modelo de aprendizagem máquina mais capaz para efetuar as projeções futuras de diferentes criptomoedas de alta frequência, ou seja, ao minuto, utilizando diferentes horizontes temporais de previsão que variam de uma até quatro horas. Para tal, foram selecionadas dez das principais criptomoedas atualmente presentes no mercado, mais precisamente Bitcoin, Ethereum, Binance Coin, Cardano, Solana, XRP, Polkadot, USD Coin, Dogecoin e Avalanche. Essa seleção foi feita com base na informação apresentada por uma das principais plataformas de referência, coinmarketcap.com, que disponibiliza as cotações das criptomoedas em tempo real. Pretende-se que a aplicação seja capaz de representar graficamente a evolução do preço para o horizonte temporal selecionado. Para tal foram desenvolvidas as seguintes tarefas:

- Pesquisar bibliografia científica relevante sobre sistemas e modelos de previsão de criptomoedas que recorrem à inteligência artificial e aprendizagem máquina;

- Identificar e obter registos de dados relevantes
- Seleção dos atributos e pré-processamento dos registos;
- Aplicar diferentes algoritmos de aprendizagem máquina sobre os registos selecionados e comparar os modelos obtidos segundo métricas de erro adequadas para problemas de regressão;
- Desenvolver uma interface em formato web, facilmente disponível em diferentes sistemas operativos e dispositivos, para efetuar e apresentar as previsões.

1.4 Considerações éticas

Para garantir a integridade, transparência e responsabilidade deste projeto é essencial identificar e abordar questões éticas. Com base nestes princípios, os utilizadores finais devem ser informados das limitações inerentes ao modelo de previsão, cientes da complexidade das flutuações das criptomoedas e da influência de uma infinidade de fatores imprevisíveis.

A aplicação de software desenvolvida tem como objetivo a apresentação de projeções baseadas em dados históricos e tem uma taxa de incerteza e erro associada.

Trata-se apenas de um trabalho científico que não pretende incentivar investimentos, pois devido à elevada volatilidade do mercado das criptomoedas, por muito bons que sejam os resultados atingidos pelos modelos em termos de precisão e erro, nada garante que as projeções sejam fiáveis e elevados investimentos poderão resultar em perdas consideráveis.

Os métodos de análise de dados adotam uma abordagem transparente, para a qual é disponibilizada a documentação de modo a ser possível replicar os resultados.

Durante todo o processo não foi efetuado qualquer plágio ou uso individual de informação, ou falsificação de resultados. Todas as citações estão devidamente referenciadas e os artigos consultados encontram-se disponíveis para acesso nos portais mencionados no início do capítulo 2.

1.5 Metodologia

Tratando-se de um projeto de investigação sobre modelos de aprendizagem máquina, a metodologia usada é a metodologia CRISP-DM (*Cross-Industry Standard Process for Data Mining*)[4] pois esta descreve as abordagens mais comuns usadas pelos especialistas na ciência de dados e especialmente usada para modelos analíticos [5].

Esta metodologia contempla as fases de compreensão dos dados e do negócio, preparação dos dados, desenvolvimento dos modelos, avaliação dos modelos, e a aplicação dos mesmos, como demonstra a figura 1.

Sendo assim, inicialmente foi feito um estudo sobre o funcionamento do mercado das criptomoedas, que informação é produzida para a sua análise histórica e de que forma podem ser desenvolvidas projeções. Numa segunda fase foram recolhidos os registos de dados necessários para treino dos algoritmos de aprendizagem máquina, em seguida são pré-processados, ou seja, tratados por forma a não existirem registos inválidos ou nulos, formatação e consolidação dos atributos, e escalonamento, se necessário. Os registos são depois divididos em três grupos, um de treino, outro de teste e um de validação para posterior avaliação. Na fase de modelação com base em diferentes algoritmos de aprendizagem máquina são desenvolvidos os modelos para os diferentes tipos de previsão. Nesta fase também são avaliadas diferentes combinações de atributos, para serem seleccionados os atributos que produzirem melhores resultados. Após a execução de cada modelo são registadas as métricas de avaliação de erro.

Após avaliação dos modelos, o melhor é disponibilizado numa aplicação web para serem usados com novos dados, mais atuais.

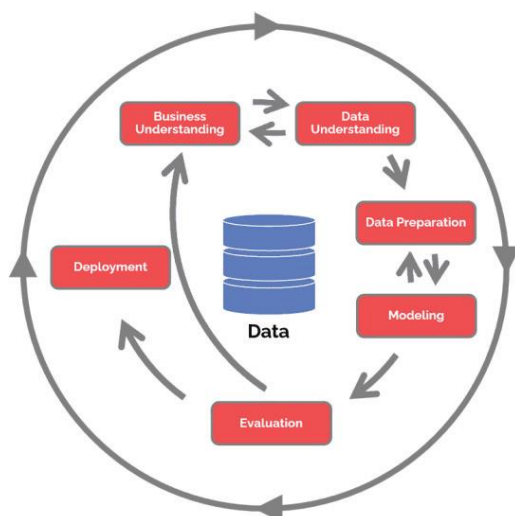


Figura 1 – Metodologia CRISP-DM [5]

1.6 Estrutura do documento

O primeiro capítulo do presente documento destina-se à introdução do tema, contextualização do problema e descrição dos objetivos, bem como da metodologia de trabalho seguida.

No segundo capítulo é apresentada a pesquisa efetuada sobre o estado da arte dos principais conceitos envolvidos, ou seja, da Bitcoin e criptomoedas no geral, o que são e como funcionam os seus mercados, bem como a descrição dos modelos de aprendizagem máquina que utilizados.

Também neste capítulo são apresentados os trabalhos relacionados com este projeto, quais as suas principais características e como se diferenciam.

O terceiro capítulo destina-se à exposição dos modelos de aprendizagem máquina desenvolvidos e apresentação dos resultados obtidos, comparando também os desempenhos com outros trabalhos relacionados. Ainda neste segundo capítulo são apresentados os conjuntos de dados e respetivos atributos usados.

O quarto capítulo contempla a estrutura e design da aplicação e suas funcionalidades, e por fim no quinto capítulo são apresentadas as conclusões e o trabalho futuro a ser desenvolvido.

2 Estado da arte

Para a revisão da literatura foram apenas considerados artigos científicos consultados nas bases de dados Springer e IEEE, usando as palavras-chave *cryptocurrency*, *machine learning*, *forecasting*, publicados entre 2019 e 2023. Este processo foi concluído em Agosto de 2023.

Da análise efetuada aos artigos são apresentados os principais conceitos que envolvem o presente trabalho e o que a literatura apresenta sobre os mesmos.

A Bitcoin é a primeira e principal criptomoeda no mercado, sendo a mais relevante entre as selecionadas para este trabalho. Como se trata de uma previsão baseada em séries temporais, este conceito também será analisado.

São apresentados e explicados os principais algoritmos de aprendizagem máquina utilizados no desenvolvimento deste trabalho.

Foram ainda analisados alguns trabalhos relacionados com o tema, que são expostos ainda que de forma mais resumida, pois trata-se de cinquenta e seis artigos analisados, mas destacando os principais aspetos de cada um, bem como as suas contribuições e conclusões.

2.1 Bitcoin

A Bitcoin foi apresentada em 2008 por um grupo de desconhecidos sob o pseudónimo Satoshi Nakamoto e entrou oficialmente em funcionamento em 2009, quando o seu código ASCII (*American Standard Code for Information Interchange*) foi lançado como uma rede de código aberto. Foi concebido para resolver as lacunas inerentes aos modelos de transações fiáveis e foi inicialmente apresentado simplesmente como um sistema de dinheiro digital de pessoa para pessoa [1].

A Bitcoin abriu caminho para a tecnologia de Blockchain e transações seguras por meio de criptografia avançada. O sucesso da Bitcoin levou à criação de inúmeras criptomoedas baseadas

em diversas tecnologias. Em 2021 a capitalização de mercado global das criptomoedas já era superior a 1,5 mil milhões de dólares americanos, de acordo com o site CoinMarketCap, um dos principais portais de informação sobre criptomoedas. Assim, a previsão de criptomoedas tem aplicações profundas para investidores financeiros e consultores. A maioria do mercado de criptomoedas não é regulamentada por nenhuma autoridade, e a autenticidade e segurança das transações dependem de uma comunicação segura de ponto-a-ponto [6].

A Bitcoin e outras criptomoedas criadas posteriormente ganharam a reputação de serem ativos puramente especulativos. Os seus preços são principalmente idiossincráticos, uma vez que são impulsionados principalmente por fatores comportamentais e não estão correlacionados com as principais classes de ativos financeiros; no entanto, a eficiência da sua informação ainda está em debate. Como resultado, muitos fundos e gestores de ativos começaram a incluir criptomoedas nas suas carteiras, enquanto a comunidade académica dedicou esforços consideráveis à investigação da negociação de criptomoedas, com ênfase em algoritmos de aprendizagem máquina [7].

Em termos de funcionamento, as transações são confirmadas e marcadas com *timestamp* (registo de hora da transação) através de uma base de dados publicamente partilhada, conhecida como Blockchain, pelos participantes chamados *miners* (mineiros). Os *miners* são recompensados com uma percentagem nas suas transações e das Bitcoins recém-criadas. Ao contrário dos sistemas de pagamento eletrónico tradicionais, as transações de Bitcoin são irreversíveis, minimizando assim a fraude. Atualmente, a Bitcoin é considerada "uma moeda ideal para consumidores e comerciantes convencionais" pelos seus apoiantes, possui elevada liquidez, custos reduzidos e velocidade elevada do seu sistema [8].

O conceito de Bitcoin possui três componentes principais: *miners* (mineiros), blockchain e *wallet* (carteira). Os *miners* usam criptografia para adquirir unidades de Bitcoin. As unidades extraídas são identificadas como membros da Blockchain. A Blockchain garante que as unidades não podem ser falsificadas. As unidades recém-geradas são transferidas para a carteira [8].

A Bitcoin, como moeda virtual de ponto-a-ponto, foi inicialmente bem-sucedida porque resolve o problema de gastos duplos com a sua tecnologia baseada em criptografia que elimina a necessidade de uma terceira parte confiável. A Blockchain é a tecnologia chave por trás da Bitcoin, funcionando como um livro digital público (sem permissões), onde as transações entre utilizadores são registadas. Uma vez que não existe uma autoridade central, este livro é replicável entre todos os participantes (nós) da rede, que o mantêm colaborativamente usando software dedicado [7].

O "ecossistema" da Bitcoin possui várias características: é imaterial (sendo um sistema eletrónico baseado em entidades criptográficas sem qualquer representação física ou valor intrínseco), descentralizado (não precisa de uma terceira parte confiável intermediária), acessível e consensual (é de código aberto, com a rede a gerir os saldos e transferências de Bitcoins), total (resolve o problema de gastos duplos), transparente (a informação de todas as transações é conhecida publicamente), global (não tem barreiras geográficas ou económicas à

sua utilização), rápido (confirmar uma transação de Bitcoin demora menos tempo do que uma transferência bancária normal), económico (os custos de transferência são relativamente baixos), irreversível e imutável (as transações de Bitcoin não podem ser revertidas e, uma vez registadas na Blockchain, a transação não pode ser modificada), divisível (a menor unidade de Bitcoin é chamada de satoshi, ou seja, 10^{-8} de uma Bitcoin), resistente (a rede provou ser robusta a ataques), pseudónima (o sistema não revela a identidade dos utilizadores, mas divulga os endereços das suas carteiras), e o fornecimento de Bitcoin está limitado a 21 milhões de unidades [7].

2.1.1 Séries temporais

Os problemas de previsão de séries temporais são considerados como um dos desafios mais exigentes em previsões do mundo real, devido ao elevado número de fatores imprevisíveis envolvidos, resultando em dependências temporais complicadas. Em geral, as séries temporais são encontradas em diversas aplicações populares do mundo real, desde transações de vendas e mercadorias até à econometria e finanças [9].

Os dados de séries temporais consistem numa sequência de pontos de dados discretos, obtidos em intervalos de tempo sucessivos predefinidos e igualmente espaçados. As suas características e propriedades únicas distinguem-nas consideravelmente de outros tipos de dados. A principal diferença entre os dados de séries temporais e outros tipos de dados é que as suas características precisam de ser invariáveis à transição do tempo. A estacionaridade é uma característica fundamental em problemas de séries temporais. No entanto, muitas séries temporais do mundo real são não estacionárias, o que implica que propriedades significativas, como média, frequência, variância e curtose, mudam ao longo do tempo. Como resultado, essas séries possuem alta volatilidade, tendência e são frequentemente caracterizadas por heterocedasticidade [9]. A figura 3 demonstra a diferença gráfica entre séries temporais estacionárias e não estacionárias.

As previsões de séries temporais podem distinguir-se em univariáveis e multivariáveis. Na previsão de séries temporais univariáveis, apenas os valores passados dos dados da série temporal são utilizados para prever os valores futuros. Este tipo de previsão é mais aplicável quando os dados de séries temporais consistem numa única variável dependente do tempo. Nas previsões multivariáveis os dados contêm N características ao mesmo tempo. Estas características podem ter alguma correlação entre si. No caso da previsão do preço de criptomoedas, as diferentes características incluem os valores de abertura (*Open*), fecho (*Close*), máximos (*High*), mínimos (*Low*) num dia (ou intervalo de tempo diferente) de negociação, e o volume de criptomoeda e o montante em dólares americanos negociado no dia [6].




Figura 2 – Representação gráfica de séries temporais estacionárias e não estacionárias [10]

2.2 Aprendizagem máquina

A partir de conjuntos de dados é possível uma máquina (computador) aprender e interpretar padrões para depois poder fazer classificações, cálculos e previsões com base em novos dados. Atualmente existem vários algoritmos de aprendizagem máquina e cada um geralmente é mais orientado, ou produz melhores resultados, para diferentes tipos de problemas.

Da pesquisa efetuada para previsões de comportamentos de criptomoedas, alguns algoritmos destacam-se nos desempenhos obtidos. Por isso, alguns deles foram utilizados neste trabalho para comparação de resultados e posterior implementação numa aplicação de software, capaz de apresentar projeções futuras sobre o valor de criptomoedas.

A previsão de comportamento pode ser feita por classificação, como determinar se o valor vai subir ou descer, ou por regressão, projetando um valor específico para o preço da criptomoeda. Para o presente trabalho foram desenvolvidos modelos de regressão, uma vez que se pretende apresentar graficamente a evolução do preço ao longo do período de previsão.

2.2.1 ARIMA (*Auto-Regressive Integrated Moving Average*)

O algoritmo ARIMA foi apresentado por Box e Jenkins[11] e é um dos métodos de previsão mais populares nas arquiteturas de séries temporais. ARIMA é designado como um modelo autorregressivo de médias móveis diferenciais, onde AR representa autorregressivo, MA representa médias móveis (*Moving Average*). É um modelo de regressão linear que acompanha tendências lineares em séries temporais estacionárias [12].

Trata-se de um modelo de análise estatística, que utiliza dados de séries temporais para prever tendências futuras ou compreender melhor o conjunto de dados. Por exemplo, um modelo ARIMA pode tentar prever o preço futuro de algumas ações com base no seu desempenho passado ou prever os ganhos de uma empresa com base em períodos anteriores [13].

O modelo é aplicado a uma série temporal estacionária. A previsão obtida é expressa como uma regressão linear que inclui características como diferenças temporais e médias móveis. No modelo ARIMA, os dados são diferenciados ao transformar as características de preço na diferença entre os preços. As equações do ARIMA são do tipo:

$$\left(1 - \sum_{k=1}^p \alpha_k L^k\right)(1 - L)^d X_t = \left(1 - \sum_{k=1}^q \beta_k L^k\right)\epsilon_t \quad (1)$$

onde L é considerado como o operador de desfasamento e p, d, q são hiper-parâmetros sobre os quais o operador de desfasamento é otimizado. Em cada momento t , é utilizado o histórico de preços para treinar o modelo e prever o preço [13].

O modelo ARIMA pode ser expresso como $ARIMA(p, d, q)$, onde p é a ordem do componente AR, d é o número de diferenças a realizadas na série temporal e q é a ordem do componente MA [10].

Em geral, as séries temporais são sempre não estacionárias devido a mudanças nos dados. Portanto, as séries temporais não estacionárias são transformadas em séries temporais estacionárias para que o modelo funcione, e isso é chamado de integração, do modelo AR e MA [10].

O modelo ARIMA utiliza séries temporais para identificar tendências passadas e prever tendências futuras. Portanto, pressupõe-se que o futuro possa ser determinado com base no passado. É uma forma de análise de regressão que consegue diferenciar a importância e relevância de uma variável em comparação com outras variáveis inseridas no modelo. Os modelos ARIMA podem ser usados para prever tendências de mercado de criptomoedas, bem como para prever a procura futura, como previsões de vendas e planos de fabrico [14].

Contudo, como os modelos ARIMA trabalham com a premissa de que o futuro pode ser baseado no passado, podem ser imprecisos quando ocorrem choques econômicos, mudanças tecnológicas ou desastres naturais. Além disso, o ARIMA requer uma quantidade significativa de dados históricos para fazer previsões precisas, o que pode ser difícil de obter. No entanto, ele só requer dados de séries temporais do objeto em questão, ao contrário de outros modelos multivariáveis. Também, diferentemente de outros modelos, os modelos ARIMA não se atualizam automaticamente, portanto, quando novos dados precisam ser inseridos, todo o processo deve ser repetido. São muito precisos para previsões de curto prazo, no entanto, menos precisos para previsões de longo prazo. Os modelos ARIMA não conseguem prever pontos de viragem e não podem ser usados para séries temporais sazonais [14].

"Para resolver o problema da sazonalidade, foi desenvolvido o modelo SARIMA (*Seasonal AutoRegressive Integrated Moving Average*), uma extensão do modelo ARIMA que, além de capturar componentes autorregressivos e de médias móveis, também lida com o comportamento sazonal das séries temporais. A principal vantagem do SARIMA sobre o ARIMA é que pode ser utilizado para processar séries temporais sazonais para tornar as previsões a longo prazo mais precisas. No entanto, requer muitos dados, o que poderá ser dispendioso de obter, e só pode extrair relações lineares dentro dos dados das séries temporais. Os modelos SARIMA e ARIMA não podem ser utilizados quando há várias variáveis a considerar [14].

2.2.2 Redes Neurais Recorrentes LSTM (*Long Short-Term Memory*)

Uma Rede Neuronal Artificial (ANN) representa um modelo computacional inspirado no cérebro humano. Assim como o órgão humano, a ANN é composta por muitos neurónios com capacidade de cálculo, dispostos em níveis e ligados entre si através de conexões com pesos.

A rede aprende por adaptação dos pesos das suas conexões, podendo essa aprendizagem ser supervisionada, na qual os dados estão rotulados, não supervisionada, na qual a rede extrai padrões autonomamente dos dados ou semi-supervisionada, uma combinação das duas com uma pequena quantidade de dados rotulados [15].

A primeira rede neuronal desenvolvida foi a Rede Neuronal *Feedforward* (avanço sequencial) (FNN). As conexões entre os nós ocorrem em sequência do anterior para o próximo, de acordo com uma única direção por exemplo, este tipo de rede inclui a perceção, também denominada de aproximador universal. Em contraste, uma classe de redes neuronais normalmente usadas para processar sequências de dados (graças à sua memória) são as Redes Neurais Recorrentes (RNN) [16]. Essencialmente, são redes neuronais com conexões de feedback em que, dada a enorme quantidade de informação gerada, o treino requer consideração de diferentes instantes temporais (o chamado desdobramento no tempo) [15].

Ao treinar a RNN, várias dificuldades surgem quando o algoritmo de retropropagação é utilizado. Problemas de convergência, presença de gradientes que desaparecem, etc.. Estes problemas surgem devido à estrutura cíclica da RNN, sendo incapaz de lidar com dependências de longo prazo em aplicações de previsão de séries temporais. A solução para esse problema está presente na forma de duas outras redes conhecidas como LSTM e GRU [6].

O funcionamento da LSTM [17] é semelhante ao da RNN, mas a sua estrutura repetitiva possui quatro neurónios, permitindo aprender dependências de longo prazo [6]. Enquanto a RNN possui apenas um módulo TANH, que representa a função de ativação e determina como a informação flui, a LSTM estabelece especialmente um módulo independente adicional. É composto por três portas: portas de entrada, de esquecimento e de saída, que controlam o fluxo de informação no bloco de memória e controlam o nível de entrada, armazenam as informações na célula e, em seguida, produzem a saída correspondente [18]:

- Porta de entrada: escolhe que informações inserir e decide quais as tarefas precisam ser atualizadas e quanto mais precisam de ser atualizadas;
- Porta de esquecimento: a LSTM processa dados sequenciais da esquerda para a direita, retendo e descartando dados por meio de processamento de controle de comutação;
- Porta de saída: a saída de informação é determinada pela porta de esquecimento e pela porta de entrada e, finalmente, pela porta de saída.

A capacidade de ajuste dos dados previstos varia com o número de iterações. Quanto maior o número de iterações, melhor a capacidade do modelo de ajustar os dados. Contudo esse número de iterações deverá ser equilibrado a fim de evitar o sobreajustamento, ou seja, memorização de particularidades do conjunto de treino. Ao mesmo tempo, a previsão de dados é melhor nos pontos de viragem, ou seja, quando há mudanças no sentido da evolução do atributo objetivo [18].

O estado da célula representa uma memória de longo prazo. As células são recursivas por natureza, permitindo que os dados sejam armazenados ou memorizados dentro da célula LSTM. O estado da célula é modificado pela porta de esquecimento e também é ajustado pela porta de modulação de entrada. A partir da fórmula, multiplica-se a porta de esquecimento para esquecer o estado da célula anterior, produz a porta de entrada e adiciona-se nova informação [10].

As equações matemáticas das redes LSTM são as seguintes [6]:

$$\begin{aligned}
 \text{Porta de entrada: } i_t &= \sigma(x_t V_i + h_{t-1} W_i) \\
 \text{Porta de esquecimento: } f_t &= \sigma(x_t V_f + h_{t-1} W_o) \\
 \text{Porta de saída: } o_t &= \sigma(x_t V_o + h_{t-1} W_o) \\
 \text{Estado intermédio da célula: } \tilde{C}_t &= \tanh(x_t V_g + h_{t-1} W_g) \\
 \text{Estado da célula (próxima entrada na memória): } C_t &= \sigma(f_t * C_{t-1} + i_y * \tilde{C}_t) \\
 \text{Novo estado: } h_t &= \tanh(C_t) * O_t
 \end{aligned} \tag{2}$$

A entrada é representada por x_t , a saída atual da célula é dada por h_t , h_{t-1} e é fornecida como a saída da célula anterior, C_{t-1} representa a memória da célula anterior, C_t representa a memória da célula atual, e finalmente W , V representam as matrizes de pesos. A entrada do estado oculto anterior e do estado atual é aplicada a uma função sigmoide para gerar estado de esquecimento na saída f_t . Apenas os valores próximos de 1 são retidos. A porta de entrada é utilizada para a atualização do estado da célula. Os dados do estado oculto anterior e do estado atual são combinados e passados por funções sigmoide e tangente hiperbólica, e então essas saídas são multiplicadas. Esse processo garante a retenção da informação importante da secção tangente hiperbólica. O estado da célula anterior e a saída do estado de esquecimento são multiplicados, e o resultado é adicionado à saída da porta de entrada para gerar o novo estado da célula C_t . A porta de saída faz com que o estado oculto anterior e o estado de entrada atual sejam dados como entradas para uma função tangente hiperbólica, e o último estado da célula é obtido por

meio de outra função tangente hiperbólica. Finalmente, as saídas da tangente hiperbólica e da sigmoide são multiplicadas para gerar o novo estado oculto a ser enviado para a próxima etapa. Dessa forma, as portas decidem o fluxo da informação, o que esquecer, o que adicionar e o que manter [6]. A representação gráfica da estrutura genérica de uma rede LSTM é apresentada na figura 4.

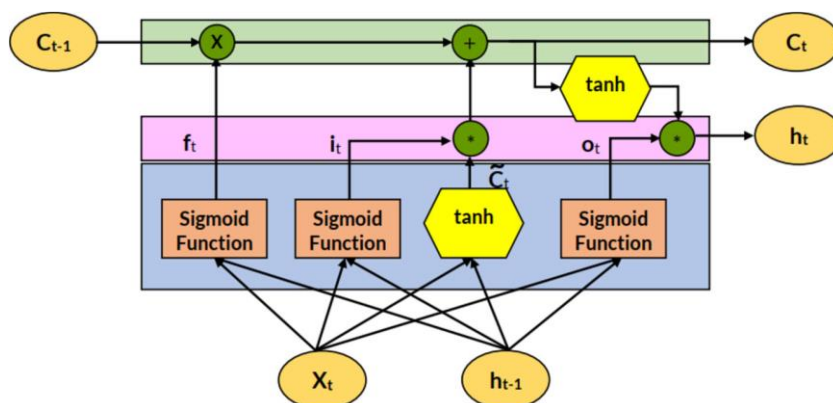


Figura 3 – Representação gráfica da arquitetura LSTM [6]

O modelo LSTM pode ser usado para detetar movimentos humanos, reconhecer caligrafia e fala, prever cotações, prever o tráfego a curto prazo, bem como para projetar medicamentos. Uma vantagem do LSTM é que ele é capaz de usar dados passados para prever tendências futuras, mesmo quando há intervalos de tempo de duração desconhecida afetando a série temporal, uma característica não disponível em modelos ARIMA. Os modelos LSTM também são insensíveis ao comprimento do intervalo, dando-lhes uma vantagem sobre outros modelos RNN. No entanto, os modelos LSTM requerem mais memória, levam mais tempo para treinar e são mais propensos a sobreajustamento [14].

2.2.3 Redes Neurais GRU (*Gated Recurrent Unit*)

Traduzindo do inglês Unidade Recorrente com Portas é um tipo modificado de Rede Neuronal Recorrente (RNN) apresentado por Cho em 2014 [19]. Esta rede visa lidar com o problema do desvanecimento do gradiente em redes RNN convencionais. Para resolver o problema do desvanecimento do gradiente de uma RNN padrão, a GRU utiliza, o que se chama, uma porta de atualização e uma porta de reinicialização (ou esquecimento segundo [6]). A adição destas duas portas permite à rede RNN selecionar quais os dados que serão transmitidos para a saída. Esta capacidade da GRU torna-a uma arquitetura eficaz na previsão de dados com base em dados anteriormente introduzidos, como em problemas de séries temporais. No entanto, o desempenho da GRU também diminui se o conjunto de dados aumentar [12].

A porta de esquecimento determina a quantidade de informação que precisa ser esquecida. Essa disposição mais simples capacita o GRU a identificar dependências de longo prazo, além de lidar eficazmente com o problema do desaparecimento do gradiente [6].

As equações matemáticas que explicam o seu funcionamento são as seguintes [6]:

$$\begin{aligned}
 \text{Porta de atualização: } z_t &= \sigma(U_{zh}x_t + W_{zx}h_{t-1} + b_z) \\
 \text{Porta de reinicialização: } r_t &= \sigma(U_{rh}x_t + W_{rx}h_{t-1} + b_r) \\
 \text{Estado da célula: } h_t &= \tanh(W_x x_t + U_h(r_t \odot h_{t-1}) + b) \\
 \text{Novo estado: } h_t &= (z_t \odot h_t + (1 - z_t) \odot h_{t-1})
 \end{aligned}
 \tag{3}$$

A entrada é representada por x_t e h_t representa a saída, z_t representa a saída da porta de atualização e r_t representa a saída da porta de reinicialização. \odot denota o produto Hadamard, e U , W e b representam a matriz de peso direto, a matriz de peso recorrente e os parâmetros de viés respetivamente [12].

Em termos de componentes a GRU apresenta os seguintes [20]:

1. Porta de Atualização - Essa porta especifica que informação dos passos temporais anteriores deve ser enviada para os próximos passos temporais. Aqui, a primeira equação é aplicada e a função sigmoide é usada para gerar resultados no intervalo de 0 a 1.
2. Porta de Reinicialização - Esta porta determina que informação do passado esquecer, classificando os dados irrelevantes e avançando sem eles.
3. Conteúdo da Memória - Após calcular as portas de atualização e reinicialização, é calculado o vetor de ativação candidato, que é um novo conteúdo da memória.
4. Memória Final - Calcula o vetor oculto usando a porta de atualização.

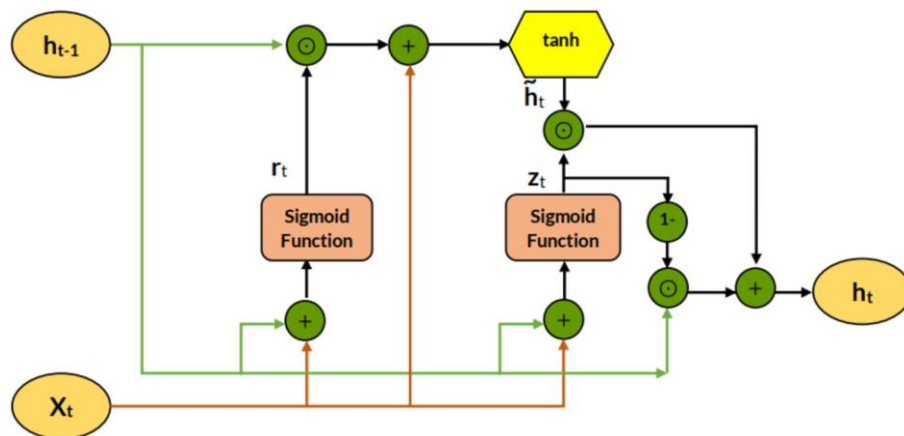


Figura 4 – Representação gráfica da arquitetura GRU [6]

O modelo GRU é semelhante ao LSTM, mas possui menos parâmetros e operações tensoriais, como demonstrado na figura 5. Treina mais rapidamente do que o modelo LSTM e demonstra melhor desempenho em certos conjuntos de dados menores [3].

2.2.4 XGboost

O *Extreme Gradient Boosting* (XGBoost) é um algoritmo de aprendizagem automática de conjunto, desenvolvido em 2016 por Chen e Guestrin [21] para tarefas de regressão e classificação [22]. O XGBoost é um algoritmo de aprendizagem máquina baseado em árvores de decisão que utiliza uma estrutura de impulsão (*boosting*) de gradiente. Trata-se de um modelo de conjunto (*ensemble*), que é uma técnica de aprendizagem máquina que combina vários modelos base para produzir um modelo preditivo ótimo. Um algoritmo é chamado de *boosting* se ele funcionar adicionando modelos uns sobre os outros iterativamente; e os erros do modelo anterior são corrigidos pelo próximo previsor até que os dados de treino sejam previstos ou reproduzidos com precisão pelo modelo. Um método é chamado de impulsão de gradiente se, em vez de atribuir diferentes pesos aos classificadores após cada iteração, ele ajustar o novo modelo aos resíduos da previsão anterior e minimizar a perda ao adicionar a última previsão. Ou seja, se um modelo é atualizado usando a minimização do gradiente, então é chamado de impulsão de gradiente. O XGBoost melhora a estrutura básica de impulsão de gradiente por meio de otimizações de sistema e aprimoramentos algorítmicos. Alguns desses aprimoramentos incluem construção paralela de árvores, e a poda das árvores usando uma abordagem de profundidade, gestão de cache e computação *out-of-core*, regularização para evitar *overfitting*, tratamento eficiente de dados ausentes e capacidade incorporada de validação cruzada [23].

A ideia principal por trás do XGBoost é atribuir a cada variável independente um peso antes de utilizá-la para construir árvores de decisão. Como resultado, o peso das árvores que fornecem resultados errados é aumentado, e o próximo previsor da árvore de decisão é construído progressivamente. O modelo final torna-se num modelo previsor mais forte com a menor taxa de erro quando as variáveis com pesos mais altos são atualizadas mais vezes para corrigir os seus erros. Esses modelos podem, portanto, resolver rapidamente problemas que envolvem classificação, regressão, classificação ordenada, entre outras [24].

Em termos de escalabilidade, o XGBoost supera outros algoritmos de *boosting*. Este algoritmo também emprega métodos mais sofisticados para determinar a melhor árvore, resultando em maior precisão e na capacidade de lidar com grandes conjuntos de dados. Para determinar o limiar de crescimento da árvore, o XGBoost divide o conjunto de dados em quantis e processa cada um separadamente. O XGBoost tem sido tradicionalmente utilizado em desafios que envolvem grandes volumes de dados históricos devido à sua velocidade e escalabilidade no uso de grandes conjuntos de dados. Isso é vantajoso ao lidar com dados históricos de séries temporais para criptomoedas, pois a técnica é mais rápida do que outros modelos de *boosting* [24].

O modelo preditivo do algoritmo XGBoost pode ser expresso da seguinte forma [25]:

$$\hat{y}_t = \sum_{k=1}^k f_k(x_i), f_k \in F \quad (4)$$

A função objetivo do XGBoost é a seguinte, composta por duas partes: a sua própria função de perda e o termo de penalização de regularização:

$$Obj(t) = \sum_{i=1}^n l(y_i, \hat{y}_i^t) + \Omega(f_t) + constante \quad (5)$$

$$\Omega(f_t) = \gamma T_t + \frac{1}{2} \lambda \|W\|^2$$

T_t representa o número de nós (ou folhas) da árvore de regressão, w representa o peso do nó folha, e γ são os coeficientes de intensidade de penalização.

O processo do algoritmo XGBoost é um predictor fraco por iteração, assim a função objetivo pode ser representada da seguinte forma:

$$Obj^{(t)} = \sum_{i=1}^n l(y_i, \hat{y}^{(t-1)} + f_t(x_i)) + \Omega(f_t) + C \quad (6)$$

$\hat{y}^{(t-1)}$ significa as funções a manter adicionadas na ronda anterior e $f_t(x_i)$ significa a nova função. C representa a Constante. A aproximação de expansão de Taylor representa a função de perda do modelo:

$$Obj^{(t)} = \sum_{i=1}^n [l(y_i, \hat{y}^{(t-1)}) + g_i f_t(x_i) + \frac{1}{2} h_i f_t^2(x_i)] + \Omega(f_t) + constante \quad (7)$$

Graficamente o algoritmo apresenta a estrutura representada na figura 6:




Figura 5 – Estrutura do modelo XGBoost [25]

2.2.5 Support Vector Machine

O *Support Vector Machine* (SVM) [26] é um algoritmo de aprendizagem máquina supervisionado usado para tarefas de regressão e classificação. O objetivo do algoritmo é

encontrar um hiperplano num espaço N-dimensional, onde N é o número de características que classificam distintamente os pontos de dados. Hiperplanos podem ser considerados como fronteiras de decisão que classificam os pontos de dados. Pontos de dados que caem em lados diferentes do hiperplano são atribuídos a diferentes classes. Os vetores de suporte são descritos como os pontos de dados que estão mais próximos do hiperplano e influenciam a posição e orientação do hiperplano. A margem do classificador é maximizada usando esses vetores de suporte [27].

O SVM funciona bem com dados de dimensões mais elevadas e, portanto, evita problemas de dimensionamento. Embora a classificação baseada em SVM (em termos de tempo de treino) seja extremamente lenta, o resultado é, no entanto, altamente preciso. Além disso, testar dados desconhecidos é muito rápido. O SVM é menos propenso a sobreajustamento do que outros modelos, permitindo selecionar um modelo que inclua uma margem suave em comparação com uma margem rígida, permitindo que alguns pontos dos dados entrem na margem, mas penalizando para proteger o SVM contra sobreajustamento em comparação com diferentes estratégias. O SVM também oferece a flexibilidade de escolher um hiperplano específico de uma lista variada, capaz de distinguir dados do espaço de atributos. Os SVM encontram o hiperplano mais amplo, ou seja, o hiperplano que maximiza a separação básica do hiperplano até ao ponto mais próximo [28].

O SVM realiza a sua análise criando uma linha reta entre duas classes que distinguem as categorias. Ao lidar com problemas de regressão, a SVM constrói a melhor linha para classificar o ponto de dados, separando os dados e estando o mais distante possível dos pontos de dados próximos. Ao construir um modelo SVM, o resultado pode variar com base nas diferentes funções de *kernel* utilizadas. As funções kernel têm a finalidade de projetar os dados num espaço de características de maior dimensão. Essas funções podem ter tipos diferentes: linear, não linear, polinomial e função de base radial (RBF). Entre todas essas funções, o *kernel* RBF é um *kernel* estacionário que é popularmente usado devido às suas vantagens em superar o problema de complexidade espacial. Matematicamente, o RBF pode ser expresso da seguinte forma [29]:

$$K(X_1, X_2) = \exp\left(-\frac{\|X_1 - X_2\|^2}{2\sigma^2}\right) \quad (8)$$

Onde σ é a variância e $\|x_1 - x_2\|$ representa a distância euclidiana.

2.2.6 Random Forest

Random Forest [30] é um método de aprendizagem que opera construindo múltiplas árvores de decisão. A decisão final escolhida pelo Random Forest é tomada com base na previsão maioritária das árvores. A principal vantagem do uso deste algoritmo é que ele reduz o risco de sobreajustamento e o tempo de treino necessário. O algoritmo Random Forest oferece um alto nível de precisão e funciona eficientemente em grandes conjuntos de dados, sendo aplicável tanto em problemas de classificação quanto de regressão. Árvores de decisão, que são o

componente básico do algoritmo, podem ser usadas para várias aplicações de aprendizagem máquina. No entanto, árvores que crescem profundamente para aprender padrões altamente irregulares tendem a ajustar-se demais aos conjuntos de treino. Um pequeno ruído nos dados pode fazer com que a árvore cresça de maneira completamente diferente. Isso ocorre porque as árvores de decisão têm viés muito baixo e alta variância. O Random Forest supera esse problema treinando múltiplas árvores de decisão em diferentes subespaços do espaço de atributos, ao custo de um viés ligeiramente aumentado. Isso significa que nenhuma das árvores na floresta vê o conjunto de dados completo. Os dados são divididos recursivamente em partições. Em cada nó específico, a divisão é feita fazendo uma pergunta sobre um atributo. A escolha do critério de divisão é baseada em algumas medidas de impureza, como Entropia de Shannon ou impureza de Gini [27].

[23]Embora o uso de Random Forest na classificação de lucro seja menos comum em comparação com SVM ou Redes Neurais Artificiais, foram apresentados resultados promissores para algumas ações do mercado de ações dos EUA [27].

O modelo Random Forest segue os seguintes passos [31]:

1. Escolha aleatória de subconjunto de dados destinado ao treino.
2. Construção de uma árvore de decisão com o subconjunto de dados selecionado.
3. Escolha do número de árvores a serem construídas e repetição dos passos anteriores.
4. Utilização das árvores para prever novos valores

A previsão de uma árvore, com K folhas (partições como nós terminais) e profundidade L , é definida como [32]:

$$g(z_i^t; \theta, K, L) = \sum_{k=1}^k \theta_k 1_{\{z_i^t \in C_k(K)\}} \quad (9)$$

Onde $C_k(L)$ indica a categoria nos nós terminais e ϑ é o parâmetro. A função de perda definida para um ramo C :

$$H(\theta, C) = \frac{1}{|C|} \sum_{r_i^t \in C} (r_i^{t+1} - \theta)^2 \quad (10)$$

$|C|$ representa o número de observações da amostra categorizadas no conjunto C . De seguida, a escolha ótima de ϑ pode ser:

$$\theta = \frac{1}{|C|} \sum_{r_i^t \in C} r_i^{t+1} \quad (11)$$

2.2.7 Regressão Linear

A Regressão Linear [33] demonstra a relação entre duas variáveis ajustando uma condição linear. Exibe uma relação linear entre duas observações, aparentando-se linear ao ajustar uma linha reta que produz um tipo de relação observada constantemente como linear entre duas variáveis, utilizando o valor do coeficiente de correlação de Pearson (r), que serve para medir a direção entre ambas as observações. Supondo que o valor de r seja superior a zero; nesse caso, pode-se observar que ambas as variáveis parecem possuir um resultado intermédio entre si, com a condição de que, ao aumentar constantemente o valor de uma observação, também se observa um aumento na outra observação, indicando um efeito intermédio entre elas por intermédio da apresentação de uma relação linear entre variáveis. Além disso, com a diminuição dos valores de uma observação, os valores das outras observações também diminuem se o valor de r for inferior a zero. O coeficiente m fornece a inclinação da linha, e o termo b indica o ponto de interseção no eixo y . A regressão também estabelece uma ligação entre duas variáveis, criando uma condição na qual os valores podem ser previstos dentro da faixa delimitada pelos dados, processo conhecido como interpolação. Para explorar dados mais a fundo, recorre-se à extrapolação. Por outro lado, outra variável é considerada como dependente. Trata-se de um modelo simples de treino relativamente rápido [28].

A equação da Regressão Linear Simples pode ser expressa da seguinte forma [29]:

$$y = \beta_0 + \beta_1 x + \epsilon \quad (12)$$

Onde β_0 é a interceção, β_1 é o coeficiente ou inclinação, ϵ é a variável de erro, x é a variável independente e y é a variável dependente. Quando o modelo possui múltiplos atributos, a equação da regressão linear polinomial pode ser escrita como:

$$y = \beta_0 + \beta_1 x_1 + \beta_2 x_2 + \dots + \beta_n x_n + \epsilon \quad (13)$$

2.3 Medidas de avaliação dos modelos

Após o treino e teste de cada modelo de aprendizagem máquina desenvolvido são calculadas as métricas tradicionalmente utilizadas para avaliar o desempenho de modelos de regressão, ou seja, métricas de erro.

As métricas de desempenho (medidas de erro) são componentes vitais dos quadros de avaliação em várias áreas. Uma métrica de desempenho pode ser definida como um modelo lógico ou matemático projetado para medir quão próximos estão os resultados reais do que foi esperado ou previsto. Uma vasta variedade de métricas de desempenho tem sido descrita na literatura académica. As métricas mais frequentemente mencionadas em estudos de investigação são o Erro Absoluto Médio (MAE), o Erro Quadrático Médio (MSE), entre outras [34]. Para avaliar o desempenho dos modelos são ainda utilizadas as métricas Raiz do Erro Quadrático Médio (RMSE) e Erro Percentual Absoluto Médio (MAPE).

O Erro Quadrático Médio, (MSE) é dado pela fórmula:

$$MSE = \frac{1}{n} \sum_{i=1}^n | y_i - \hat{y}_i |^2 \quad (14)$$

E a Raiz do Erro Quadrático Médio (RMSE):

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n | y_i - \hat{y}_i |^2} \quad (15)$$

A fórmula do Erro Médio Absoluto (MAE) é a seguinte:

$$MAE = \frac{1}{n} \sum_{i=1}^n | y_i - \hat{y}_i | \quad (16)$$

E por fim o Erro Médio Percentual Absoluto (MAPE):

$$MAPE = \frac{100}{n} \sum_{i=1}^n \frac{| y_i - \hat{y}_i |}{y_i} \quad (17)$$

Onde y_i representa o valor real e \hat{y}_i representa o valor previsto pelo modelo [35].

2.4 Trabalhos Relacionados

Os trabalhos apresentados neste ponto são apenas os que apresentam no seu conteúdo a previsão de comportamento futuro de criptomoedas recorrendo a modelos de aprendizagem máquina.

Outros trabalhos também poderiam ser acrescentados, nomeadamente sobre previsão de comportamentos de mercados de bolsa, mercados imobiliários e outras cotações que também recorressem aos modelos de aprendizagem máquina, até porque alguns artigos como [36] ou [9] entre outros utilizam diferentes objetos para previsão que não só as criptomoedas, contudo as criptomoedas apresentam características diferentes que se traduzem em comportamentos diferentes, derivado da sua natureza descentralizada, não havendo um organismo global para a sua regulamentação.

Da pesquisa efetuada, que inclui 56 artigos, consegue-se perceber claramente que a criptomoeda mais utilizada para estudo é a Bitcoin, uma vez que se trata da criptomoeda de maior relevância e com maior quota de mercado. Como demonstrado no gráfico da figura 6, dos 56 artigos analisados, 26 só utilizam a Bitcoin como objeto de previsão, 21 utilizam a Bitcoin e outras cotações ou outras criptomoedas e apenas 9 utilizam outras criptomoedas que não a Bitcoin, entre as quais a Ethereum, a segunda criptomoeda mais relevante no mercado.

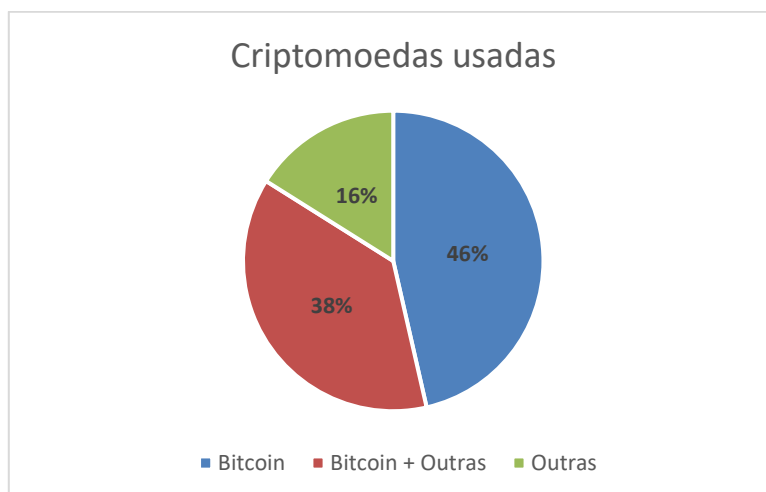


Figura 6 – Distribuição das criptomoedas pelos artigos estudados

Outro aspeto observado tem a ver com o tipo de previsão que é efetuado, previsão do valor do preço, através de modelos de regressão, ou classificação de sinal positivo ou negativo indicando se o valor vai subir ou descer. A classificação também pode ser sob a forma de instruções, ou indicações, *Hold/Buy/Sell* (aguardar, comprar, vender), como em [37], atuando como um sistema de apoio à decisão. Outros tipos de previsão encontrados são de taxas de rentabilidade e previsão de volatilidade.

O horizonte temporal de previsão varia bastante, podendo variar de minutos, horas, dias, semanas ou até meses. No mercado das criptomoedas, milhares de transações são feitas ao segundo, vinte e quatro horas por dia, sete dias da semana, e a sua cotação varia ao segundo.

A grande maioria dos artigos, 47, executa previsões sobre o preço, 4 de classificação de sinal e os restantes 7 executam outros tipos de previsão como demonstra o gráfico da figura 7. Neste ponto, assim como noutros que vão ser apresentados, o total não corresponde a 56, pois existem artigos como por exemplo [38], que utilizam mais do que um tipo de previsão.




Figura 7 – Tipos de previsão presentes nos artigos estudados

Outro aspeto relevante sobre os trabalhos analisados são os atributos previsores que são usados para os modelos desenvolvidos. 13 artigos apresentam modelos que apenas usam o preço da criptomoeda ou cotação, sendo esse preço o preço final do intervalo de tempo (*timestep*) do conjunto de dados usado. Esse intervalo de tempo dos conjuntos de dados pode ser ao segundo, minuto, hora ou dia. 18 artigos apenas usam os atributos mais comuns que geralmente são disponibilizados dos conjuntos de dados de cotações de mercado, que são os atributos *Open*, *High*, *Low*, *Close* e *Volume*, que correspondem ao preço de abertura do intervalo, preço mais alto transacionado no intervalo, preço mais baixo transacionado no intervalo, preço final do intervalo e volume transacionado no intervalo, respetivamente. 14 trabalhos usam outros atributos ou indicadores para os seus modelos de previsão para além dos anteriormente referidos, 4 usam outras cotações, de outras criptomoedas, ou de outros objetos e 9 artigos usam atributos de texto. Esses atributos de texto traduzem-se em análises de sentimentos, positivos ou negativos, relativamente à criptomoeda ou objeto de análise. Essa análise de sentimentos é efetuada sobre títulos e notícias de jornais, ou publicações e comentários em redes sociais, como por exemplo o Twitter. O gráfico da figura 8 representa a distribuição dos tipos de atributos pelos trabalhos analisados.

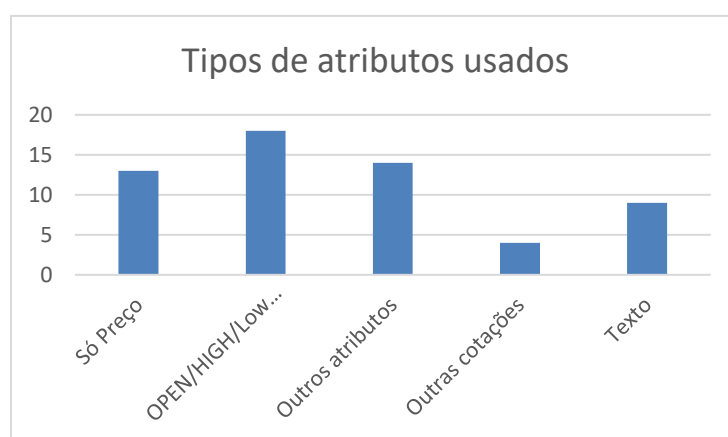


Figura 8 – Tipos de atributos usados nos artigos estudados

Outro aspeto relevante e que também pode ter influência no desempenho dos modelos são os períodos, apresentado no gráfico da figura 9 em anos, dos conjuntos de dados usados para treino e teste dos modelos. Não é garantido que um modelo que tenha um determinado desempenho num determinado período tenha o mesmo desempenho noutra período distinto. Este é um aspeto que varia bastante e é quase único de cada artigo. Variam os períodos compreendidos, o horizonte temporal e o intervalo dos registos (segundo, minuto, hora, dia). Artigos como [2] usa um conjunto de dados que compreende 8 anos, ou como [23], que usa 7 meses, havendo artigos que até usam períodos mais abrangentes ou mais restritos.

De uma forma geral a distribuição dos períodos usados é demonstrada pelo gráfico da figura 10, onde se pode verificar que o ano com maior presença nos conjuntos de registos é 2018 e apenas 5 artigos usam conjuntos de dados que incluem o ano de 2022, apesar de 30 dos 56 artigos já terem sido publicados em 2022/2023, o que pode ser justificado pelo tempo que

decorre desde a recolha dos dados, tratamento dos mesmos, desenvolvimento dos modelos e execução de testes, para além da elaboração dos respetivos artigos.



Figura 9 – Distribuição dos períodos dos conjuntos de dados dos artigos estudados

Da análise aos trabalhos relacionados que serão descritos também se podem destacar os modelos de aprendizagem máquina usados, sendo que o modelo LSTM é o mais usado, em 26 artigos, SVM (ou SVR) aparece como o segundo mais usado, em 20 artigos e o Random Forest com 15 artigos completando o top 3. O modelo ARIMA, o modelo mais comum para previsões em séries temporais surge em 10 artigos. Outros modelos que também aparecem destacados e com bons desempenhos são os modelos de Redes Neurais Recorrentes GRU, com 11 artigos e os modelos como *Gradient Boosting/ Extreme Gradient Boosting* presentes em 12 artigos. Entre os outros modelos que são usados nos trabalhos, constam modelos como o Facebook Propnet, o ELM (*Extreme Machine Learning*) ou o LASSO (*Least Absolute Shrinkage and Selection Operator*) que por não serem tão comuns nesta abordagem nem se destacarem em termos de resultados, não são diferenciados. O gráfico da figura 10 apresenta a distribuição dos modelos.




Figura 10 – Distribuição dos modelos de aprendizagem máquina nos artigos estudados

Por último, é necessário destacar as métricas de avaliação do desempenho dos modelos usadas nos artigos. Nessas métricas destacam-se o RMSE, MAPE, MAE, MSE, como métricas de regressão, e o *F1 Score*, R^2 e *Accuracy*, como métricas de classificação.

Pela análise ao gráfico da figura 11 percebe-se que as métricas de erro são mais comuns do que as de classificação.




Figura 11 – Distribuição das métricas de desempenho nos artigos estudados

Apesar da maioria dos artigos apresentar os valores das métricas usadas, apenas 3 artigos não apresentam valores de métricas, muitas vezes também são apresentados gráficos de comparação entre os valores reais e os valores previstos pelos modelos.

A comparação entre os modelos é, no entanto algo difícil de conseguir, pois apesar de não usarem todos a mesmas métricas, também os objetos de estudo (criptomoedas) não são os mesmos, nem os períodos usados nos registos de dados para treino e teste são os mesmos. É impossível aferir que os resultados se mantêm usando uma criptomoeda diferente e um conjunto de dados diferente.

Os valores das métricas variam bastante entre os artigos. Considerando os melhores desempenhos os valores encontrados apresentam as variações apresentadas na tabela 1:

Tabela 1: Variação dos valores das métricas de desempenho dos artigos estudados

	RMSE	MAPE	MAE	MSE	F1 Score	R^2	Accuracy %
Máximo	7 527,300	26,653	6 631,800	2 159 166,250	0,920	0,998	99,690
Mínimo	0,007	0,000	0,002	0,000	0,611	0,639	55,940
Médio	1 048,167	2,270	583,154	226 993,221	0,747	0,892	78,755
Desvio P.	2 058,615	6,238	1 642,889	614 030,654	0,129	0,129	16,451

Como a análise mais detalhada de cada artigo é um pouco extensa, para não avolumar demasiado o corpo do presente documento, esta encontra-se disponível no anexo A.

3 Implementação e avaliação dos modelos

A aplicação foi desenvolvida em Python, uma linguagem de programação simples e amplamente utilizada para o desenvolvimento de aplicações que utilizam bibliotecas de aprendizagem máquina. Além disso, existe uma vasta quantidade de informações e exemplos de código disponíveis para consulta.

3.1 Conjuntos de dados

Para o treino e teste dos modelos foram recolhidos diferentes conjuntos de registos que contemplam os valores de cotação ao minuto da Bitcoin, Ethereum, Binance Coin, Cardano, Solana, XRP, Polkadot, USD Coin, Dogecoin e Avalanche.

Os dados foram obtidos através da biblioteca Python YFinance, que permite a extração de cotações de criptomoedas, e outros ativos financeiros, disponíveis no portal finance.yahoo.com.

Na aplicação final, os dados poderão ser atualizados a qualquer momento. No entanto, para o desenvolvimento dos modelos e testes, foram utilizados valores de cotação ao minuto de um período de 30 dias, entre 12/05/2024 e 11/06/2024.

Os registos contemplam os atributos Datetime, Open, High, Low, Close, Adj. Close e Volume, correspondendo à data e hora da cotação, valor de abertura do período, valor mais alto transacionado no período, valor mais baixo transacionado no período, valor de fecho do período, valor líquido de fecho do período e volume transacionado no período. Estes campos, ou atributos, são transversais a todas as cotações de ativos financeiros, desde criptomoedas, às cotações de bolsa ou *Forex*.

A informação e distribuição dos registos dos atributos Close e Volume de cada criptomoeda é apresentada na tabela 2 e pelos gráficos da figura 13:

Tabela 2: Informação e distribuição dos valores de Fecho e Volume de cada criptomoeda

Bitcoin		
	Close	Volume
Contagem	33 781,00	33 781,00
Média	67 948,15	8 879 468,76
Desvio padrão	2 425,81	39 919 958,68
Mínimo	60 787,36	0,00
25%	67 063,55	0,00
50%	68 426,62	404 480,00
75%	69 441,24	7 464 960,00
Máximo	71 907,85	5 678 329 856,00

Ethereum		
	Close	Volume
Contagem	38 216,00	38 216,00
Média	3 570,00	5 314 865,10
Desvio padrão	340,87	35 036 398,49
Mínimo	2 864,56	0,00
25%	3 129,22	0,00
50%	3 744,46	134 656,00
75%	3 801,47	3 580 160,00
Máximo	3 969,70	5 627 247 616,00

Binance		
	Close	Volume
Contagem	37 923,00	37 923,00
Média	617,54	562 017,98
Desvio padrão	41,25	2 164 262,32
Mínimo	561,14	0,00
25%	592,61	0,00
50%	601,29	0,00
75%	630,35	425 792,00
Máximo	720,60	160 288 384,00

Cardano		
	Close	Volume
Contagem	37 182,00	37 182,00
Média	0,46	124 569,45
Desvio padrão	0,02	544 606,32
Mínimo	0,42	0,00
25%	0,45	0,00
50%	0,46	0,00
75%	0,46	79 388,00
Máximo	0,51	36 492 032,00

Solana		
	Close	Volume
Contagem	37 032,00	37 032,00
Média	165,35	915 416,00
Desvio padrão	9,15	3 743 308,07
Mínimo	138,05	0,00
25%	161,55	0,00
50%	166,76	26 048,00
75%	171,16	785 440,00
Máximo	188,47	495 197 696,00

XRP		
	Close	Volume
Contagem	38 102,00	38 102,00
Média	0,52	367 591,09
Desvio padrão	0,01	2 000 541,95
Mínimo	0,47	0,00
25%	0,51	0,00
50%	0,52	14 336,00
75%	0,53	283 104,00
Máximo	0,56	210 166 016,00

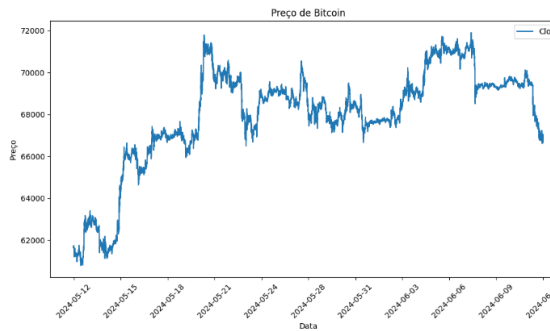
Polkadot		
	Close	Volume
Contagem	31 670,00	31 670,00
Média	7,05	76 259,87
Desvio padrão	0,34	305 245,21
Mínimo	6,17	0,00
25%	6,90	0,00
50%	7,09	4 488,00
75%	7,25	59 950,00
Máximo	7,76	18 362 512,00

USD Coin		
	Close	Volume
Contagem	37 104,00	37 104,00
Média	1,00	1 986 002,90
Desvio padrão	0,00	12 395 098,23
Mínimo	1,00	0,00
25%	1,00	0,00
50%	1,00	31 232,00
75%	1,00	1 378 944,00
Máximo	1,00	994 848 256,00

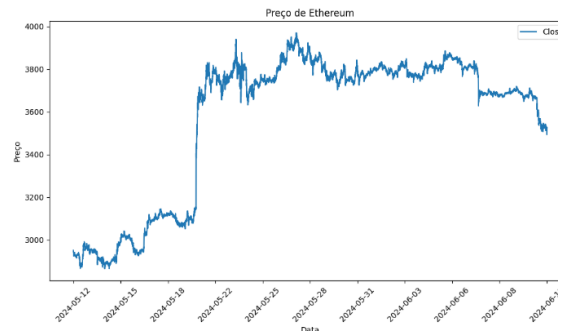
Dogecoin		
	Close	Volume
Contagem	38 052,00	38 052,00
Média	0,16	442 564,52
Desvio padrão	0,01	2 284 956,51
Mínimo	0,14	0,00
25%	0,15	0,00
50%	0,16	12 464,00
75%	0,16	318 720,00
Máximo	0,17	272 368 768,00

Avalanche		
	Close	Volume
Contagem	37 076,00	37 076,00
Média	35,76	135 487,50
Desvio padrão	2,28	627 208,87
Mínimo	31,37	0,00
25%	33,87	0,00
50%	36,03	0,00
75%	37,05	96 232,00
Máximo	41,68	67 825 056,00

Bitcoin



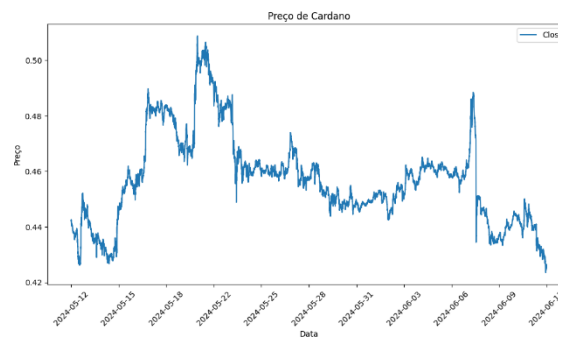
Ethereum



Binance Coin



Cardano



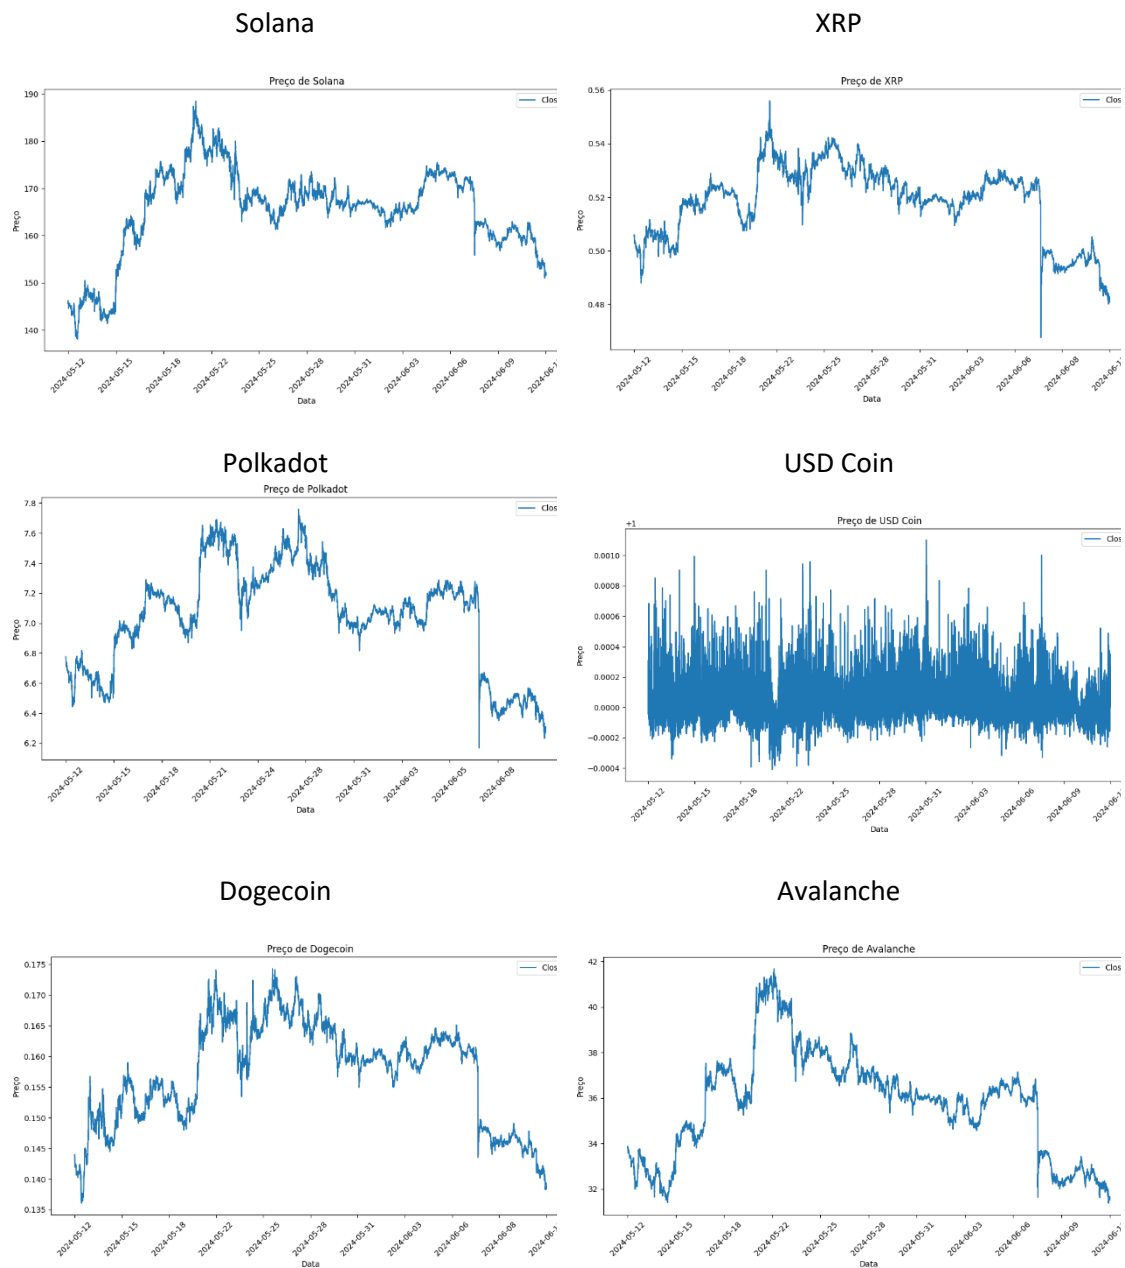


Figura 12 – Valores de fecho das criptomoedas

Como se pode verificar pela tabela 2, apesar de ser executada a mesma função com os mesmos parâmetros para transferência dos dados o número de registos não é igual para todas as criptomoedas, que variam entre 31 670 da Polkadot e 38 216 da Ethereum.

Todos os valores estão em Dólares Americanos (USD) e as cotações variam bastante consoante a criptomoeda, sendo o valor médio da Dogecoin de 0,16 USD, a criptomoeda com preço mais baixo, enquanto o valor médio da Bitcoin é de 67 948,15 USD, a que tem um preço mais elevado. No que corresponde ao volume transacionado por minuto, o valor médio da Polkadot é que

tem um valor mais baixo, de 76 259,87 USD e a Bitcoin a que tem o valor mais alto, 8 879 468,76 USD.

3.2 Limpeza e preparação dos dados

Para os conjuntos de dados obtidos pela API YFinance não há muito trabalho a ser realizado nesta fase, pois os dados são obtidos com os mesmos formatos para todas as criptomoedas e não são passados valores nulos ou vazios, contudo essa verificação é realizada para garantir que não são passados valores nulos para o treino e teste dos modelos.

Os registos depois de transferidos são guardados num ficheiro CSV para que possam ser reutilizados e trabalhados ao longo de todo o processo de modelação e teste, garantido que os dados sejam os mesmos para todos os modelos, e assim que os resultados não sejam influenciados por existirem dados diferentes para modelos diferentes.

O atributo Datetime é usado como índice dos registos e é garantida a sua ordenação para que os registos fiquem sempre sequenciais em função do tempo.

A coluna Adj. Close é removida de todos os conjuntos de dados das criptomoedas, uma vez que contém valores iguais aos valores do atributo Close e por isso é redundante.

Com a exceção do modelo SARIMA, por só utilizar o atributo Close, os dados são normalizados usando a função MinMaxScaler da biblioteca sklearn, para que os valores de todos os atributos estejam na mesma escala para treino do modelo. Essa normalização é depois revertida para teste do modelo.

Os testes comparativos dos modelos são feitos com base na previsão a 60 minutos, e a divisão dos dados é feita da seguinte forma:

- Últimos 60 registos usados para validação
- 80% dos registos restantes usados para treino
- 20% dos registos restantes usados para teste

3.3 Modelação

Ao todo foram utilizados oito modelos diferentes de regressão para comparação do desempenho utilizando os registos da Bitcoin, que como já foi referido no ponto anterior, para previsões a 60 minutos. Essa escolha deve-se ao fato da Bitcoin ser a criptomoeda de maior relevância e a que é mais utilizada nos trabalhos analisados. A 60 minutos, pois é o horizonte temporal mais curto em análise e como tal é o que deverá ter melhor desempenho.

Os testes comparativos foram efetuados tendo por base a utilização de todos os atributos, Open, High, Low, Close e Volume, e também tendo por base apenas o atributo Close. O modelo SARIMA apenas foi testado usando o atributo Close pois tem algumas particularidades que irão ser explicadas mais à frente, que o distingue dos outros modelos.

De uma forma geral os modelos podem ser usados com dados de diferentes intervalos temporais. Os registos estão disponíveis através da API YFinance, que permite transferir os registos ao minuto, à hora, ou ao dia. Para o caso de ser ao minuto podem ser transferidos os dados dos últimos 30 dias. No caso de serem intervalos de uma hora podem ser transferidos os dados dos últimos 365 dias e no caso dos registos diários não tem restrições.

A opção tomada de serem utilizados registos ao minuto permite ter uma quantidade bastante superior de registos para treino dos modelos. Há casos de modelos, como as redes neuronais que requerem muitos dados para terem um melhor desempenho. Em 30 dias podem existir até 43 200 registos, enquanto num ano em registos horários podem existir até 8 760 e em 5 anos de registos diários apenas poderiam existir até 1 825 registos.

Outro aspeto relevante nos registos ao minuto é o da variação de valores ser menos significativa entre registos o que também ajuda a que as previsões sejam mais precisas.

À exceção do modelo SARIMA em que os valores são treinados minuto a minuto, nos restantes modelos, existe uma função para criar as previsões em sequências de 60 minutos, também denominada de janelas deslizantes. Esta função é ajustada em função do horizonte temporal de previsão. Assim os últimos 60 minutos são utilizados para a previsão dos próximos 60 minutos.

O desempenho do modelo é obtido pelas métricas já referidas anteriormente, MSE, RMSE, MAE e MAPE. É ainda introduzida a métrica nRMSE, que corresponde à métrica RMSE, mas obtida a partir dos valores normalizados para permitir uma melhor comparação de desempenhos de modelos com criptomoedas diferentes, uma vez que cada uma tem valores de grandeza diferente.

3.3.1 Redes Neuronais LSTM

O primeiro teste foi feito com o modelo LSTM, uma vez que é o mais popular entre os artigos analisados, e que à partida apresenta melhores resultados.

O modelo LSTM está disponível na biblioteca Keras da API Tensorflow. Foi utilizado um modelo com 50 neurónios e duas camadas, uma LSTM e outra densa, com o otimizador *adam* e os valores de perda são obtidos em função do MSE.

O modelo é executado em 50 ciclos, ou *epochs*, sendo que pode ser terminado antecipadamente usando o método *EarlyStopping*, caso os valores da função de perda comecem a aumentar consecutivamente durante 5 ciclos.

Como se pode verificar na tabela 3 o modelo LSTM teve um melhor desempenho usando apenas o atributo Close como atributo previsor.

Tabela 3: Desempenho do modelo LSTM

Todos os atributos			Apenas Close		
	Teste	Validação		Teste	Validação
MSE	62342,97	8163,73	MSE	61702,81	7237,85
RMSE	249,69	90,35	RMSE	248,40	85,08
MAE	150,37	71,87	MAE	138,60	67,87
MAPE	0,22%	0,11%	MAPE	0,20%	0,10%
nRMSE	0,05	0,22	nRMSE	0,05	0,21

A representação gráfica dos testes e validações do modelo é apresentada na figura 13:

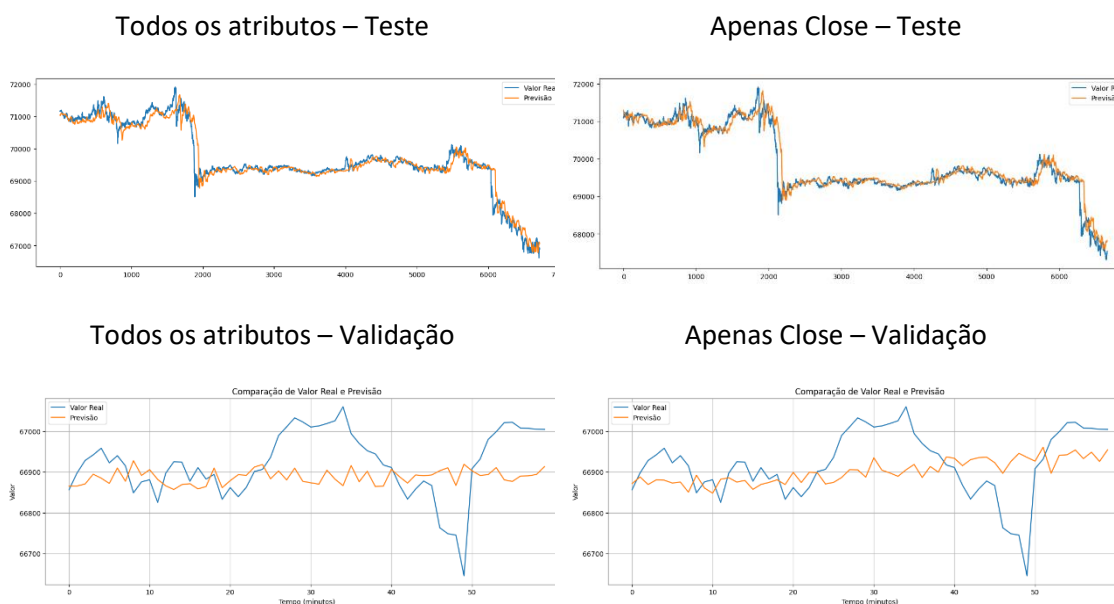


Figura 13 – Testes e validações do modelo LSTM

3.3.2 Redes Neurais GRU

O modelo GRU em termos de programação em Python é bastante semelhante ao LSTM, também disponível na biblioteca Keras da API Tensorflow, contudo trata-se de um modelo mais simples e rápido, que também pode ser mais eficiente uma vez que gere melhor o sobreajuste dos dados.

De referir que em termos de velocidade de treino dos modelos de redes neurais utilizando a API Tensorflow, esta pode ser bastante melhorada quando o computador está equipado e devidamente configurado para permitir que os modelos utilizem a memória das placas gráficas em vez da memória RAM do computador, caso contrário o processo de treino das redes pode ser bastante lento.

Assim como o modelo LSTM, são usadas redes com 50 neurónios com duas camadas, executadas em 50 ciclos, também utilizando o método EarlyStopping para que os ciclos sejam interrompidos caso os valores da função de perda comecem a aumentar durante 5 ciclos. Neste modelo também é utilizado o otimizador adam e a função de perda é dada pelo MSE.

Como se pode verificar pela tabela 4, o modelo GRU teve um melhor desempenho utilizando todos os atributos, mas teve um pior desempenho quando usando apenas o atributo Close relativamente ao LSTM.

Tabela 4: Desempenho do modelo GRU

Todos os atributos			Apenas Close		
	Teste	Validação		Teste	Validação
MSE	63202,28	5954,89	MSE	34751,03	9307,22
RMSE	251,40	77,17	RMSE	186,42	96,47
MAE	156,52	60,20	MAE	114,79	75,98
MAPE	0,22%	0,09%	MAPE	0,16%	0,11%
nRMSE	0,05	0,19	nRMSE	0,04	0,23

A representação gráfica dos testes e validações do modelo GRU é apresentada na figura 14.

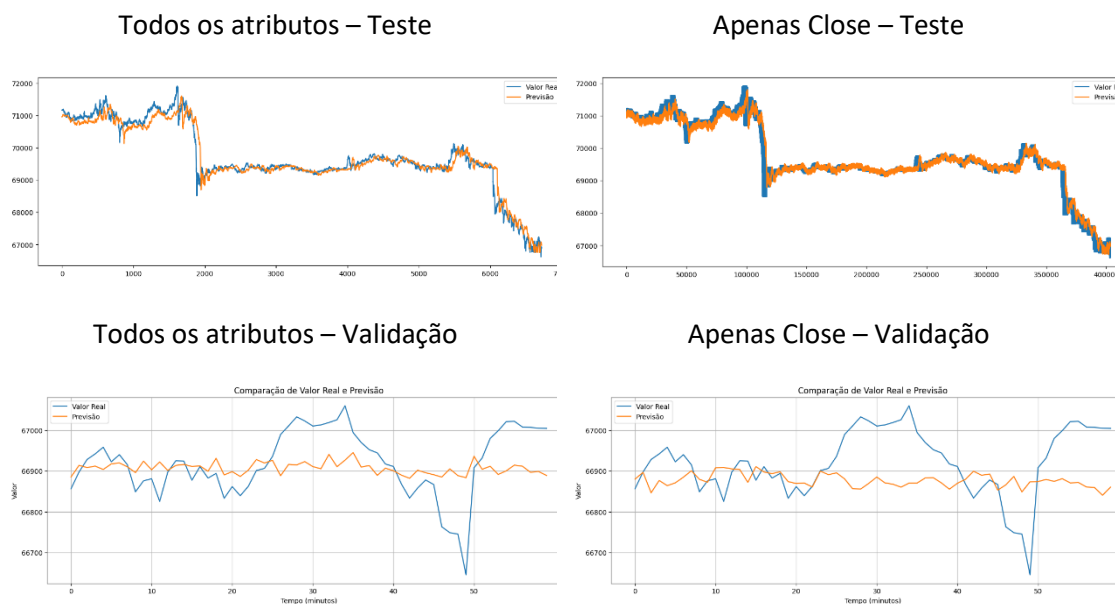


Figura 14 – Testes e validações do modelo GRU

3.3.3 SARIMA

O modelo SARIMA é obtido através da biblioteca Statsmodels. O modelo usado é na verdade o SARIMAX, que está preparado para usar variáveis exógenas no modelo SARIMA, mas que neste caso não existem nos dados obtidos e por essa razão o modelo designa-se por SARIMA e não SARIMAX.

Este modelo é muito pesado e na máquina onde foi testado nem foi possível carregar todo o conjunto de dados para treinar o modelo. Então foram carregados subconjuntos dos registos e o ponto onde foram atingidos melhores resultados foi com apenas 360 registos, ou seja, o preço dos últimos 360 minutos. Ainda Assim o modelo demora bastante a treinar, o que não se torna prático para ser colocado numa aplicação, pois para fazer previsões este modelo tem de ser sempre treinado com os novos dados para efetuar previsões, ao contrário dos restantes modelos que podem ser guardados para executar as previsões com novos dados, sem requerem novo treino.

Como já foi referido este modelo apenas utiliza o atributo Close e o treino dos dados não é feito em sequências de 60 minutos, mas sim minuto a minuto. O modelo SARIMA também não requer a normalização dos dados para treino e teste, uma vez que apenas usa um atributo predictor, que é também o atributo objetivo.

Dada a pouca quantidade de registos utilizada, neste caso não foi feita a validação igual à dos outros modelos, apenas o teste feito com 20% dos registos, o que equivale a 72 minutos em vez de 60, sendo os restante registos utilizados para treino do modelo.

Os resultados obtidos foram os apresentados na tabela 5 e figura 15.

Tabela 5: Desempenho do modelo SARIMA

Apenas Close	
	Teste
MSE	19476,59
RMSE	139,56
MAE	114,16
MAPE	0,16%
nRMSE	0,23

Apenas Close – Teste




Figura 15 – Teste do modelo SARIMA

3.3.4 Regressão Linear

Para o modelo de Regressão Linear é utilizada a biblioteca Sklearn e apesar de ser o modelo de regressão mais simples o desempenho foi bastante interessante. Não existe muita parametrização, apenas é executada a função de criação das sequências de 60 minutos para treino do modelo e a normalização e divisão dos dados em treino e teste como nos modelos LSTM e GRU.

O que se verificou nos modelos anteriores é que são capazes de acompanhar de uma forma mais ou menos acentuada a evolução dos preços, mas não preveem os grandes picos de variação dos valores. A Regressão Linear tende ainda mais a ser uma linha reta, quando


representada graficamente, como se pode verificar nos gráficos de validação da figura 16. A grande vantagem é que se trata de um modelo muito simples e muito rápido de treinar.

Em termos de avaliação o modelo obteve os valores presentes na tabela 6, que se aproximam bastante do modelo GRU, tendo um melhor desempenho quando usado apenas o atributo Close:


Tabela 6: Desempenho do modelo Regressão Linear

Todos os atributos			Apenas Close		
	Teste	Validação		Teste	Validação
MSE	61883,91	6979,26	MSE	965,77	6722,40
RMSE	248,76	83,54	RMSE	31,08	81,99
MAE	142,94	64,36	MAE	16,64	62,49
MAPE	0,21%	0,10%	MAPE	0,02%	0,09%
nRMSE	0,05	0,20	nRMSE	0,01	0,20


Todos os atributos – Teste



Apenas Close – Teste



Todos os atributos – Validação



Apenas Close – Validação




Figura 16 – Testes e validações do modelo Regressão Linear

3.3.5 Random Forest


O modelo Random Forest não é muito comum para previsões de séries temporais, e o processo de treino também é bastante pesado quando usado com uma grande quantidade de dados. Para não sobrecarregar muito o processo de treino foi aplicado um modelo com 100 árvores de decisão. Para a execução do modelo é utilizada a biblioteca Sklearn.

Em termos de desempenho o modelo foi um pouco pior do que os modelos anteriores, sobretudo na validação. O modelo apresenta uma melhoria significativa quando treinado apenas com o atributo Close.


Tabela 7: Desempenho do modelo Random Forest

Todos os atributos			Apenas Close		
	Teste	Validação		Teste	Validação
MSE	1128,20	387460,75	MSE	126651,25	38281,06
RMSE	33,59	622,46	RMSE	355,88	195,66
MAE	19,31	572,41	MAE	246,14	167,82
MAPE	2,77%	85,55%	MAPE	35,41%	25,09%
nRMSE	0,01	1,50	nRMSE	0,07	0,47


Todos os atributos – Teste



Apenas Close – Teste



Todos os atributos – Validação



Apenas Close – Validação




Figura 17 – Testes e validações do modelo Random Forest

3.3.6 Support Vector Machine

O modelo executado, *Support Vector Regressor*, utilizado para problemas de regressão, consta na biblioteca Sklearn.

Neste modelo, assim como nos anteriores, com exceção do ARIMA, após normalização dos dados, o modelo é treinado em sequência de 60 minutos, ou janela deslizante de 60 minutos, com o parâmetro kernel com o valor rbf, função de base radial.

Este modelo também é um pouco pesado para treinar com muitos dados, mas também tem um desempenho em termos de métricas interessante, sobretudo quando treinado com todos os atributos.

Tabela 8: Desempenho do modelo SVM

Todos os atributos			Apenas Close		
	Teste	Validação		Teste	Validação
MSE	503319,18	10301,07	MSE	444222,48	121987,11
RMSE	709,45	101,49	RMSE	666,50	349,27
MAE	407,04	83,40	MAE	385,04	338,49
MAPE	0,58%	0,12%	MAPE	0,54%	0,51%
nRMSE	0,13	0,24	nRMSE	0,13	0,84




Figura 18 – Testes e validações do modelo SVM

3.3.7 XGBoost

O modelo XGBoost utilizado também consta da biblioteca Sklearn e em termos de treino é bastante rápido, contudo o desempenho ficou bastante aquém dos anteriores na validação, sobretudo quando treinado com todos os atributos.

Em termos de configurações foram usadas 100 árvores de decisão, ou número de previsores, e com uma taxa de aprendizagem de 0,1.

Tabela 9: Desempenho do modelo XGBoost

Todos os atributos			Apenas Close		
	Teste	Validação		Teste	Validação
MSE	1377,54	4206051,13	MSE	1473,86	37715,50
RMSE	37,12	2050,87	RMSE	38,39	194,20
MAE	21,07	1053,07	MAE	21,31	148,61
MAPE	0,03%	1,57%	MAPE	0,03%	0,22%
nRMSE	0,01	4,95	nRMSE	0,01	0,47




Figura 19 – Testes e validações do modelo XGBoost

3.3.8 LightGBM

Também presente da biblioteca Sklearn, um modelo derivado do XGBoost, o LightGBM [39] consegue melhores resultados com treino mais rápido.

Com valores de configuração por defeito, o desempenho, ainda que não tão bom quanto as redes neurais, é melhor do que o XGBoost, quando usado com todos os atributos previsores, mas piora quando usado apenas o preço.

Tabela 10: Desempenho do modelo LightGBM

Todos os atributos			Apenas Close		
	Teste	Validação		Teste	Validação
MSE	128096,50	29859,99	MSE	162110,90	38132,43
RMSE	357,91	172,80	RMSE	402,63	195,28
MAE	257,60	137,39	MAE	270,88	165,60
MAPE	37,87%	20,54%	MAPE	39,12%	24,76%
nRMSE	0,13	0,42	nRMSE	0,08	0,47




Figura 20 – Testes e validações do modelo LightGBM

3.4 Comparação do desempenho dos modelos

O modelo que apresenta um melhor desempenho são as redes neurais GRU, pelo que esse modelo foi aplicado a todas as criptomoedas selecionadas e a diferentes horizontes temporais de previsão, que vão de 60 minutos a 240 minutos, ou seja de 1 a 4 horas.

O que se constata é que o desempenho baixa bastante quando o horizonte de previsão aumenta quando usado registos de alta frequência, o que também era esperado uma vez que a previsão com tantos passos à frente é muito mais difícil. Sobretudo quando os modelos não conseguem prever as grandes quebras ou subidas de valores, e não conseguem prever as mudanças de sentido. Ou seja, se uma criptomoeda estiver numa tendência crescente, o modelo vai realizar a previsão no mesmo sentido, e se houver uma mudança no sentido da evolução o modelo não irá prever, pois também não existem atributos previsores que indiquem que essa mudança pode acontecer.

Também os tempos de treino do modelo aumentam consideravelmente quando se aumenta o horizonte de previsão, indo de 9 segundos por ciclo de treino para previsões a 60 minutos até 60 segundos, para previsões de 240 minutos. Esses tempos podem variar consoante a máquina onde forem executados os treinos, contudo para o efeito, foram executados num computador com processador Intel i7 12650H 2.30 GH, 16 GB de RAM e uma placa gráfica NVIDIA GeForce RTX 3080.

O modelo está configurado para executar até 50 ciclos de aprendizagem, *epochs*, contudo como tem parametrizado o método *EarlyStopping*, com tolerância de 5 ciclos caso os valores da

função de perda comecem a aumentar, por norma não são excedidos os 20 ciclos em cada processo de treino.

Inicialmente tinham sido projetados outros horizontes temporais mais curtos de 15, 30 e 45 minutos, mas o desempenho não melhorava a ponto de se justificar essa disponibilização na aplicação. Também tinham sido projetados outros horizontes mais longos, de 6, 12 e 24 horas, mas aqui o desempenho baixava demasiado. Muito provavelmente para esses horizontes de previsão o treino dos modelos poderá ser melhor com registos de intervalos de uma hora, em vez de um minuto.

Foram comparados os desempenhos do modelo com todos os horizontes temporais para Bitcoin e como se pode verificar os valores das métricas de desempenho mantêm-se estáveis até à previsão a 240 minutos, sendo que quando se aumenta até aos 1440 esses valores aumentam consideravelmente.

Tabela 11: Desempenho do modelo GRU para os diferentes horizontes de previsão

Min.	15	30	45	60	120	180	240	360	720	1440
MSE	16391	23634	7786	5955	25713	33575	89106	375233	1854184	1589417
RMSE	128,03	153,73	88,24	77,17	160,35	183,23	298,51	612,56	1361,68	1260,72
MAE	118,67	113,55	69,99	60,20	135,11	141,82	270,26	561,15	1264,40	1024,31
MAPE	0,18%	0,17%	0,10%	0,09%	0,20%	0,21%	0,40%	0,84%	1,88%	1,51%
Nrmse	0,34	0,37	0,21	0,19	0,26	0,30	0,48	0,62	0,73	0,36




Figura 21 – Desempenho do modelo GRU para os diferentes horizontes de previsão

Em termos de desempenho do modelo com outras criptomoedas para os intervalos de previsão de 60 a 240 minutos, são como ilustrados nas tabelas 12 a 16 e gráficos da figura 22.

Tabela 12: Valores de MSE do modelo GRU para as diferentes criptomoedas

Min.	BTC	ETH	BNB	ADA	SOL	XRP	DOT	USDC	DOGE	AVAX
60	5954,89	421,41	0,55	0,00	0,35	0,00	0,00	0,00	0,00	0,01
120	25713,45	918,79	1,45	0,00	3,08	0,00	0,01	0,00	0,00	0,16
180	33574,83	1289,26	2,41	0,00	3,15	0,00	0,01	0,00	0,00	0,17
240	89106,07	1201,93	11,52	0,00	4,13	0,00	0,02	0,00	0,00	0,17

Tabela 13: Valores de RMSE do modelo GRU para as diferentes criptomoedas

Min.	BTC	ETH	BNB	ADA	SOL	XRP	DOT	USDC	DOGE	AVAX
60	77,17	20,53	0,74	0,00	0,59	0,00	0,01	0,00	0,00	0,12
120	160,35	30,31	1,20	0,00	1,76	0,00	0,07	0,00	0,00	0,40
180	183,23	35,91	1,55	0,00	1,77	0,00	0,11	0,00	0,00	0,41
240	298,51	34,67	3,39	0,01	2,03	0,00	0,13	0,00	0,00	0,41

Tabela 14: Valores de MAE do modelo GRU para as diferentes criptomoedas

Min.	BTC	ETH	BNB	ADA	SOL	XRP	DOT	USDC	DOGE	AVAX
60	60,20	18,96	0,67	0,00	0,54	0,00	0,01	0,00	0,00	0,11
120	135,11	27,94	0,95	0,00	1,64	0,00	0,07	0,00	0,00	0,36
180	141,82	33,86	1,15	0,00	1,42	0,00	0,10	0,00	0,00	0,36
240	270,26	33,07	3,05	0,00	1,61	0,00	0,11	0,00	0,00	0,33

Tabela 15: Valores de MAPE do modelo GRU para as diferentes criptomoedas

Min.	BTC	ETH	BNB	ADA	SOL	XRP	DOT	USDC	DOGE	AVAX
60	0,09%	0,54%	0,11%	0,09%	0,35%	0,20%	0,15%	0,01%	0,48%	0,34%
120	0,20%	0,79%	0,16%	0,90%	1,08%	0,54%	1,04%	0,01%	1,37%	1,16%
180	0,21%	0,96%	0,19%	0,91%	0,94%	0,42%	1,58%	0,01%	1,79%	1,14%
240	0,40%	0,94%	0,50%	1,10%	1,06%	0,81%	1,74%	0,01%	1,91%	1,06%

Tabela 16: Valores de nRMSE do modelo GRU para as diferentes criptomoedas

Min.	BTC	ETH	BNB	ADA	SOL	XRP	DOT	USDC	DOGE	AVAX
60	0,19	0,59	0,34	0,30	0,61	0,61	0,22	0,26	0,70	0,74
120	0,26	0,64	0,27	0,72	0,55	0,69	0,71	0,22	0,84	0,68
180	0,30	0,74	0,35	0,75	0,56	0,57	0,71	0,30	0,92	0,70
240	0,48	0,72	0,52	0,74	0,58	0,87	0,70	0,26	0,87	0,56

Em termos de comparação do desempenho entre criptomoedas diferentes, com grandezas diferentes, as métricas comparáveis são apenas a MAPE, pois trata-se de uma métrica percentual e o nRMSE, pois trata-se de uma métrica normalizada do valor de RMSE. Verifica-se então um aumento dos valores de erro geral da previsão a 60 minutos dos restantes horizontes temporais, com a exceção da criptomoeda USD Coin que tem variações de preço tão ténues que não destacam grande diferença nas previsões com diferentes horizontes temporais.

Com a exceção da criptomoeda USD Coin, pelos motivos já referidos, dos testes efetuados destacam-se as seguintes observações:

- Em termos de nRMSE o modelo apresentou o melhor desempenho com a Bitcoin nos quatro horizontes temporais;
- Também na métrica nRMSE os piores desempenhos foram com a Avalanche a 60 minutos, e a Dogecoin a 120, a 180 e 240 minutos, juntamente com a XRP neste último caso;
- No que toca a valores de MAPE a Bitcoin e a Cardano tiveram o melhor desempenho a 60 minutos, a Binance Coin a 120 e a 180 minutos, e a Bitcoin a 240 minutos;
- Os piores valores de MAPE registaram-se na previsão de Ethereum a 60 minutos, e de Dogecoin a 120, 180 e 240 minutos.




Figura 22 – Desempenhos do modelo GRU para todas as criptomoedas e diferentes horizontes de previsão

3.5 Comparação com trabalhos relacionados

Para comparação com outros trabalhos é preciso ter atenção que esta análise serve apenas para apresentar um enquadramento dos desempenhos e não para referir que um trabalho é melhor que outro, pois é preciso ter em conta que os períodos dos dados não são os mesmos e os trabalhos não usam todos os mesmos horizontes de previsão. Na maior parte dos casos os registos utilizados e horizontes de previsão não são ao minuto, mas sim diários. Para comparação serão apenas usados trabalhos que apresentam as mesmas moedas, o mesmo tipo de previsão, ou seja, do valor de fecho, e pelo menos uma métrica comparável às utilizadas neste trabalho.

Tabela 17: Valores das métricas de desempenho dos trabalhos relacionados

Título	Moeda	Previsão	RMSE	MAPE	MAE	MSE
Price Prediction of Cryptocurrency Using a Multi-Layer Gated Recurrent Unit Network with Multi Features [6]	Bitcoin	Preço a 21 dias	251,61	0,31%	164,49	63 307,31
Cryptocurrency Value Prediction with Boosting Models [24]	Bitcoin	Preço diário	458,02		345.512	209 778,00
The random neural network in price predictions [36]	Bitcoin	Preço diário	217,53	3,26%	79,25	
Hybrid data decomposition-based deep learning for Bitcoin prediction and algorithm trading [38]	Bitcoin	Preço diário	0,01	0,01%	0,01	
Data Selection to Train Machine Learning Models and Forecast Bitcoin Prices: Depth vs. Width [40]	Bitcoin	Preço diário	7 527,30	0,16%	6 631,80	
Twitter Mining based Forecasting of Cryptocurrency using Sentimental Analysis of Tweets [41]	Bitcoin	Preço diário		2,42%	0,00	1,41
Forecasting Bitcoin Price Using Interval Graph and ANN Model: A Novel Approach [42]	Bitcoin	Preço diário	0,07	0,03%		
Predicting Bitcoin Price using Machine Learning [20]	Bitcoin	Preço diário	1 987,11	0,18%		
Statistical Scrutiny of the Prediction Capability of Different Time Series Machine Learning Models in Forecasting Bitcoin Prices [14]	Bitcoin	Preço diário	1 447,65	0,03%		
Cryptocurrency Price forecasting: A Comparative Study of Machine Learning Model in Short-Term Trading [29]	Bitcoin	Preço diário	3 599,17		2 139,91	
Cryptocurrency Price Prediction With Multi-task Multi-step Sequence-to-Sequence Modeling [43]	Bitcoin	Preço diário		0,07%		0,04
Bitcoin Price Forecasting using Time-series Architectures [12]	Bitcoin	Preço diário	1 469,41			2 159 166,25
Forecasting financial time series with Boltzmann entropy through neural networks [15]	Bitcoin	Preço diário	372,84			
Deep Learning Forecasting in Cryptocurrency High-Frequency Trading [44]	Bitcoin	Preço a 5 minutos	1,44			
A new method of ensemble learning: case of cryptocurrency price prediction [45]	Bitcoin	Preço a 3 meses	673,00			
Cryptocurrency Price Prediction Based on Long-Term and Short-Term Integrated Learning [46]	Bitcoin	Preço diário	5 251,20			

Título	Moeda	Previsão	RMSE	MAPE	MAE	MSE
Prediction of Cryptocurrency Price using Machine Learning Techniques and Public Sentiment Analysis [47]	Bitcoin	Preço diário	6 720,14			
Prediction of Cryptocurrency prices using Transformers and Long Short term Neural Networks [48]	Bitcoin	Preço diário	367,00			
Time-series forecasting of Bitcoin prices using high-dimensional features: a machine learning approach [35]	Bitcoin	Preço diário		0,14%		
Bitcoin closing price movement prediction with optimal functional link neural networks [8]	Bitcoin	Preço diário		1,56%		
Bitcoin daily price prediction through understanding blockchain transaction pattern with machine learning methods [49]	Bitcoin	Preço diário		1,69%		
Forecasting Financial Time Series Using Robust Deep Adaptive Input Normalization [50]	Bitcoin	Preço a 10 dias			83,27	
Bitcoin Price Prediction Using Machine Learning and Deep Learning Algorithms [13]	Bitcoin	Preço diário			0,02	
Using Transformers and Deep Learning with Stance Detection to Forecast Cryptocurrency Price Movement [51]	Bitcoin	Preço diário			0,02	
Price Prediction of Bitcoin using Social Media Activities and Past Trends [52]	Bitcoin	Preço a 1 mês				271,00
Investigation of Ethereum Price Trends using Machine learning and Deep Learning Algorithms [31]	Ethereum	Preço diário	253,68		115,91	64 355,56
Parent Coin based Cryptocurrency Price Prediction using Regression Techniques [53]	Litecoin	Preço diário	0,01		0,00	0,00
Ethereum Price Prediction using Topological Data Analysis [54]	Ethereum	Preço diário		0,75%		
RMSE calculation of LSTM models for predicting prices of different cryptocurrencies [55]	Cardano	Preço diário	0,60			

4 Sistema

Neste capítulo é apresentada a estrutura do sistema desenvolvido e as suas funcionalidades.

A solução consiste numa aplicação web que recolhe os dados dos preços ao minuto dos últimos 30 dias das criptomoedas já referidas e apresenta as previsões para 4 horizontes temporais que variam de 1 a 4 horas. A estrutura da solução é representada na figura 23.

O sistema permite ainda que os modelos sejam treinados novamente para aprimorar a previsão, uma vez que os dados podem assumir distribuições bastante diferentes de uns períodos para outros, e assim ajusta-se o modelo a esses novos padrões dos dados.

Para utilizar a aplicação só é necessário um software de navegação web, tipo Google Chrome ou Internet Explorer, e pode ser acedida de qualquer dispositivo que possua esse tipo de software.

Os dados são carregados no servidor onde também é realizado todo o processamento.

Face à natureza académica do sistema desenvolvido, a aplicação não contém restrições de uso nem é necessária qualquer autenticação ou registo de dados dos utilizadores.

A aplicação está disponível online em <https://crypto-mm.streamlit.app/>.

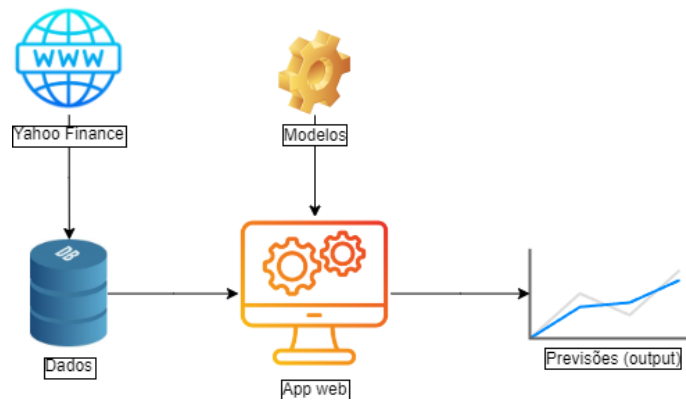


Figura 23 – Componentes do sistema

4.1 Estrutura do sistema

Em termos de funcionamento, o sistema pode ser dividido em três módulos, conforme ilustrado na figura 25.




Figura 24 – Estrutura do sistema

4.1.1 Dados

Neste primeiro módulo a aplicação através da API YFinance transfere os dados ao minuto dos últimos 30 dias para a aplicação e depois são gravados em ficheiro csv. A aplicação permite o carregamento e a visualização gráfica desses dados.

4.1.2 Modelos

Os modelos podem ser treinados novamente, o que pode ser benéfico para o desempenho, uma vez que os dados podem sofrer alterações nos seus padrões de comportamento ao longo do tempo, como já foi referido, mas não é necessário executar novamente o treino dos modelos para efetuar novas previsões. Isso só aconteceria caso o modelo usado fosse o SARIMA, contudo o modelo usado é o GRU.

Existe um modelo independente para cada criptomoeda e para cada horizonte de previsão. Após a execução do treino dos modelos, estes ficam guardados para serem executados posteriormente quando forem efetuadas novas previsões.

4.1.3 Previsões

Este módulo executa as previsões para a criptomoeda e para o horizonte temporal selecionados e apresenta em forma de gráfico a evolução futura prevista para o preço. Antes de executar uma previsão convém atualizar os dados históricos pois o modelo precisa do último intervalo igual ao horizonte temporal para fazer a previsão da próxima janela temporal.

4.2 Aplicação web

A aplicação web desenvolvida tem uma estrutura simples com apenas um ficheiro `app.py` que pode ser executada utilizando a biblioteca Streamlit. Essa biblioteca em Python permite adicionar componentes web ao código Python para serem apresentados num navegador web. Quando executada, a aplicação pode ser acedida numa máquina local ou em rede, se for executada num servidor onde os dados ficam guardados e onde é feito o processamento.

A aplicação permite ao utilizador atualizar e visualizar os dados históricos dos últimos 30 dias para cada uma das 10 criptomoedas disponíveis, além de disponibilizar previsões para diferentes horizontes temporais e até treinar novamente os modelos.

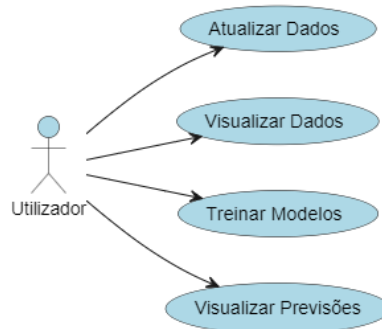


Figura 25 – Diagrama de uso do sistema

A interface do utilizador foi desenhada para ser intuitiva, permitindo que utilizadores de todos os níveis de experiência naveguem facilmente pelas funcionalidades. Do lado esquerdo da interface são apresentados os botões de opções e os resultados são apresentados na área principal da página.



Figura 26 – Ecrã da App web

Em primeiro lugar é necessário escolher a criptomoeda sobre a qual irão ser efetuadas as operações. Por defeito é selecionada a Bitcoin, mas na caixa de seleção poderá ser escolhida outra criptomoeda.

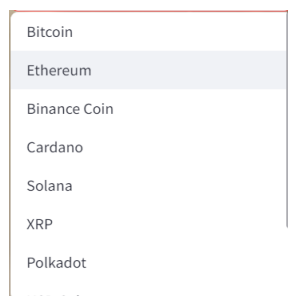


Figura 27 – Seleção das criptomoedas da App web

De seguida o utilizador pode atualizar os dados históricos da criptomoeda selecionada. Os dados são transferidos automaticamente e são gravados num ficheiro csv. Caso não haja erros na transferência o processo será confirmado como bem sucedido.




Figura 28 – Atualização de dados na App web

Os dados gravados podem ser consultados, sendo apresentado um gráfico histórico dos preços dos últimos 30 dias. Os dados podem ser consultados a qualquer momento, não necessitando do passo anterior, a aplicação apresenta os dados que estão gravados no ficheiro csv que contém os valores da última atualização, contudo é conveniente atualizar os dados antes de efetuar previsões, pois as previsões são feitas em função da última janela do intervalo igual ao horizonte temporal selecionado.




Figura 29 – Visualização dos dados na App web

A aplicação permite ao utilizador treinar novamente o modelo, o que pode ser útil quando os padrões históricos mudam significativamente, e ajustar melhor o modelo aos dados permitindo uma previsão mais eficaz.

Para tal é necessário selecionar o horizonte temporal do modelo que irá ser treinado clicar no botão "Treinar modelo e gravar". O modelo é então treinado e quando terminada a operação os resultados de teste são apresentados juntamente com as métricas e o modelo é gravado para ser executado posteriormente.

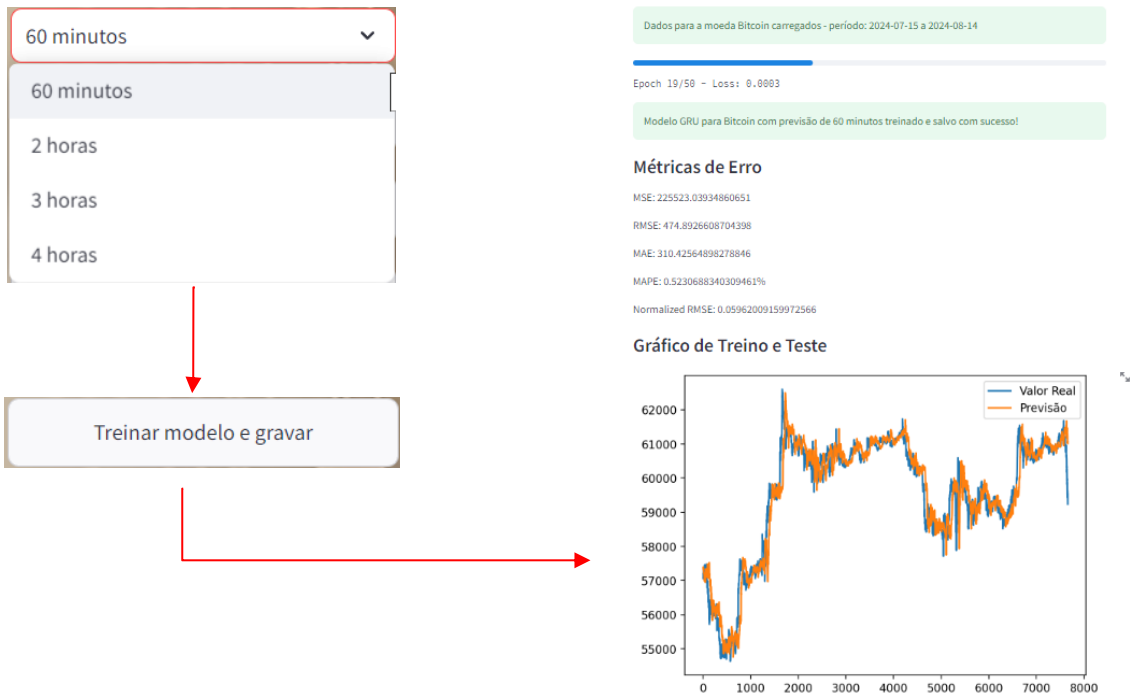


Figura 30 – Treino dos modelos na App web

Por fim para visualizar as previsões, o utilizador seleciona o horizonte temporal e clica no botão “Carregar modelo e fazer previsões”. Os dados são então carregados e o gráfico com os valores previstos é apresentado.



Figura 31 – Previsões na App web

5 Conclusão e trabalho futuro

Após a revisão bibliográfica, este trabalho descreve alguns conceitos envolvidos no tema, tais como a Bitcoin, as séries temporais, e alguns dos algoritmos que se destacaram nos artigos analisados. Esses algoritmos foram testados para obter os melhores resultados possíveis, e posteriormente, foi feita uma seleção do melhor modelo, que foi implementado numa aplicação de software.

Dos testes realizados, verifica-se que existem modelos mais bem preparados para realizar previsões sobre problemas de séries temporais do que outros. Os modelos com melhores desempenhos são as redes neurais LSTM e GRU, e os modelos SARIMA e Regressão Linear, sendo que as redes GRU apresentam um melhor desempenho relativamente aos restantes. Os testes tiveram como atributos previsores os campos mais comuns utilizados nos trabalhos analisados e que estão presentes nas cotações de mercado, que são os valores de abertura, valor mais alto transacionado, valor mais baixo transacionado, e volume transacionado, sendo o preço de fecho o atributo objetivo para o problema.

Em termos de desempenho, das métricas analisadas pode-se concluir que os valores obtidos podem ser considerados bons. Contudo, os resultados mostram que as previsões acompanham as tendências gerais, mas não capturam os grandes picos de mudança nos valores. O que torna este tipo de previsões mais eficaz para horizontes mais curtos, em que esses picos não são tão drásticos e as diferenças de preço não são tão acentuadas, sobretudo no caso da Bitcoin.

No futuro, poderão ser incluídos outros atributos que possam melhorar o desempenho dos modelos para horizontes temporais superiores, como notícias sobre o mercado financeiro, índices de confiança do consumidor, ou até publicações nas redes sociais e dados de pesquisas realizadas por utilizadores na internet, como apresentado em alguns trabalhos analisados. Esses atributos requerem mais tratamentos, mais capacidade de processamento e acesso a dados em tempo real para que um sistema seja totalmente funcional, como o atualmente implementado, contudo poderão ser relevantes para ajudar a prever mudanças de sentido e grandes picos de valorização ou desvalorização.

Este trabalho também poderá ser expandido com a inclusão de mais criptomoedas no sistema, e o aumento dos horizontes de previsão. Dado os atributos utilizados também poderão ser incluídos outros tipos de ativos financeiros cotados em bolsa, uma vez que partilham a mesma estrutura de dados e também podem ser obtidos através da API YFinance.

Referências

- [1] S. Ranjan, P. Kayal, and M. Saraf, "Bitcoin Price Prediction: A Machine Learning Sample Dimension Approach," *Comput Econ*, vol. 61, no. 4, pp. 1617–1636, Apr. 2023, doi: 10.1007/s10614-022-10262-6.
- [2] G. Attanasio, P. Garza, L. Cagliero, and E. Baralis, "Quantitative cryptocurrency trading: Exploring the use of machine learning techniques," in *Proceedings of the 5th International Workshop on Data Science for Macro-Modeling, DSMM 2019, in conjunction with the ACM SIGMOD/PODS Conference*, Association for Computing Machinery, Inc, Jun. 2019. doi: 10.1145/3336499.3338003.
- [3] H. Wang and X. Zhou, "Less is More: Bitcoin Volatility Forecast Using Feature Selection and Deep Learning Models," in *IEEE International Conference on Industrial Informatics (INDIN)*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 681–688. doi: 10.1109/INDIN51773.2022.9976100.
- [4] R. Wirth and J. Hipp, "CRISP-DM: Towards a Standard Process Model for Data Mining," London, UK: Springer-Verlag., 2000.
- [5] M. H. B. M. Sabri, A. Muneer, and S. M. Taib, "Cryptocurrency Price Prediction using Long Short-Term Memory and Twitter Sentiment Analysis," in *2022 6th International Conference on Computing, Communication, Control and Automation, ICCUBEA 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ICCUBEA54992.2022.10011090.
- [6] G. R. Patra and M. N. Mohanty, "Price Prediction of Cryptocurrency Using a Multi-Layer Gated Recurrent Unit Network with Multi Features," *Comput Econ*, 2022, doi: 10.1007/s10614-022-10310-1.
- [7] H. Sebastião and P. Godinho, "Forecasting and trading cryptocurrencies with machine learning under changing market conditions," *Financial Innovation*, vol. 7, no. 1, Dec. 2021, doi: 10.1186/s40854-020-00217-x.
- [8] S. C. Nayak, "Bitcoin closing price movement prediction with optimal functional link neural networks," *Evol Intell*, vol. 15, no. 3, pp. 1825–1839, Sep. 2022, doi: 10.1007/s12065-021-00592-z.
- [9] I. E. Livieris, S. Stavroyiannis, L. Iliadis, and P. Pintelas, "Smoothing and stationarity enforcement framework for deep learning time-series forecasting," *Neural Comput Appl*, vol. 33, no. 20, pp. 14021–14035, Oct. 2021, doi: 10.1007/s00521-021-06043-1.
- [10] L. J. Parab and P. P. NITnaware, "Evaluation of Cryptocurrency coins with Machine Learning algorithms and Blockchain Technology," in *2022 IEEE Region 10 Symposium*,

TENSYMP 2022, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/TENSYMP54529.2022.9864430.

- [11] G. E. P. Box and G. M. Jenkins, "Time Series Analysis: Forecasting and Control," 1970.
- [12] L. G. N. De Leon, R. C. Gomez, M. L. G. Tacal, J. V. Tylar, V. V. Nojor, and A. R. Villanueva, "Bitcoin Price Forecasting using Time-series Architectures," in *9th International Conference on ICT for Smart Society: Recover Together, Recover Stronger and Smarter Smartization, Governance and Collaboration, ICISS 2022 - Proceeding*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ICISS55894.2022.9915199.
- [13] B. Malhotra, C. Chandwani, P. Agarwala, and S. Mann, "Bitcoin Price Prediction Using Machine Learning and Deep Learning Algorithms," in *2022 10th International Conference on Reliability, Infocom Technologies and Optimization (Trends and Future Directions), ICRITO 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ICRITO56286.2022.9964677.
- [14] C. Dinshaw, R. Jain, and S. A. I. Hussain, "Statistical Scrutiny of the Prediction Capability of Different Time Series Machine Learning Models in Forecasting Bitcoin Prices," in *Proceedings of 4th International Conference on Cybernetics, Cognition and Machine Learning Applications, ICCMLA 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 329–336. doi: 10.1109/ICCMLA56841.2022.9989057.
- [15] L. Grilli and D. Santoro, "Forecasting financial time series with Boltzmann entropy through neural networks," *Computational Management Science*, vol. 19, no. 4, pp. 665–681, Oct. 2022, doi: 10.1007/s10287-022-00430-2.
- [16] J. J. Hopfield, "Neural networks and physical systems with emergent collective computational abilities (associative memory/parallel processing/categorization/content-addressable memory/fail-soft devices)," 1982. [Online]. Available: <https://www.pnas.org>
- [17] S. Hochreiter and J. Schmidhuber, "Long Short-Term Memory," *Neural Comput*, vol. 9, no. 8, pp. 1735–1780, Nov. 1997, doi: 10.1162/neco.1997.9.8.1735.
- [18] J. Hu, "Intelligent Decisionmaking System through LSTM Prediction Model and DQN algorithm," in *2022 IEEE 2nd International Conference on Data Science and Computer Application, ICDSICA 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 958–965. doi: 10.1109/ICDSICA56264.2022.9988461.
- [19] K. Cho, B. van Merriënboer, D. Bahdanau, and Y. Bengio, "On the Properties of Neural Machine Translation: Encoder-Decoder Approaches," Sep. 2014, [Online]. Available: <http://arxiv.org/abs/1409.1259>
- [20] M. Mittal and G. Geetha, "Predicting Bitcoin Price using Machine Learning," in *2022 International Conference on Computer Communication and Informatics, ICCCI 2022*,

- Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ICCCI54379.2022.9740772.
- [21] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Association for Computing Machinery, Aug. 2016, pp. 785–794. doi: 10.1145/2939672.2939785.
- [22] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," in *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, Association for Computing Machinery, Aug. 2016, pp. 785–794. doi: 10.1145/2939672.2939785.
- [23] E. Akyildirim, O. Cepni, S. Corbet, and G. S. Uddin, "Forecasting mid-price movement of Bitcoin futures using machine learning," *Ann Oper Res*, 2021, doi: 10.1007/s10479-021-04205-x.
- [24] S. Swati and A. Mohan, "Cryptocurrency Value Prediction with Boosting Models," in *Proceedings of 2022 International Conference on Intelligent Innovations in Engineering and Technology, ICIET 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 183–188. doi: 10.1109/ICIET55458.2022.9967540.
- [25] Q. Zhong and M. Huo, "Crypto Profit Forecasting using hybrid Machine Learning method," in *2022 3rd International Conference on Big Data, Artificial Intelligence and Internet of Things Engineering, ICBAIE 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 585–588. doi: 10.1109/ICBAIE56435.2022.9985937.
- [26] C. Cortes, V. Vapnik, and L. Saitta, "Support-Vector Networks Editor," Kluwer Academic Publishers, 1995.
- [27] E. Akyildirim, A. Goncu, and A. Sensoy, "Prediction of cryptocurrency returns using machine learning," *Ann Oper Res*, vol. 297, no. 1–2, pp. 3–36, Feb. 2021, doi: 10.1007/s10479-020-03575-y.
- [28] K. C. Kumar and M. Rajesh, "Ethereum and Binance Price Forecasting Using Machine Learning," in *2022 IEEE 3rd Global Conference for Advancement in Technology, GCAT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/GCAT55367.2022.9971954.
- [29] H. Lyu, "Cryptocurrency Price forecasting: A Comparative Study of Machine Learning Model in Short-Term Trading," in *Proceedings - 2022 Asia Conference on Algorithms, Computing and Machine Learning, CACML 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 280–288. doi: 10.1109/CACML55074.2022.00054.
- [30] L. Breiman, "Random Forests," 2001.

- [31] D. K. Tejaswi, H. Chauhan, T. Jaya Lakshmi, R. Swetha, and N. N. Sri, "Investigation of Ethereum Price Trends using Machine learning and Deep Learning Algorithms," in *2022 2nd International Conference on Intelligent Technologies, CONIT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/CONIT55038.2022.9848000.
- [32] Q. Wang, "Cryptocurrencies asset pricing via machine learning," *Int J Data Sci Anal*, vol. 12, no. 2, pp. 175–183, Aug. 2021, doi: 10.1007/s41060-021-00252-6.
- [33] F. Galton, "Regression Towards Mediocrity in Hereditary Stature."
- [34] A. Botchkarev, "A new typology design of performance metrics to measure errors in machine learning regression algorithms," *Interdisciplinary Journal of Information, Knowledge, and Management*, vol. 14, pp. 45–76, 2019, doi: 10.28945/4184.
- [35] M. Mudassir, S. Bennbaia, D. Unal, and M. Hammoudeh, "Time-series forecasting of Bitcoin prices using high-dimensional features: a machine learning approach," *Neural Comput Appl*, 2020, doi: 10.1007/s00521-020-05129-6.
- [36] W. Serrano, "The random neural network in price predictions," *Neural Comput Appl*, vol. 34, no. 2, pp. 855–873, Jan. 2022, doi: 10.1007/s00521-021-05903-0.
- [37] D. Mahayana, S. A. Madyaratri, and M. Fadhil 'Abbas, "Predicting Price Movement of the BTCUSDT Pair Using LightGBM Classification Modeling for Cryptocurrency Trading," in *12th International Conference on System Engineering and Technology, ICSET 2022 - Proceeding*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 48–53. doi: 10.1109/ICSET57543.2022.10010808.
- [38] Y. Li, S. Jiang, X. Li, and S. Wang, "Hybrid data decomposition-based deep learning for Bitcoin prediction and algorithm trading," *Financial Innovation*, vol. 8, no. 1, Dec. 2022, doi: 10.1186/s40854-022-00336-7.
- [39] G. Ke *et al.*, "LightGBM: A Highly Efficient Gradient Boosting Decision Tree." [Online]. Available: <https://github.com/Microsoft/LightGBM>.
- [40] J. M. Dempere, Z. A. El-Agure, and D. Memic, "Data Selection to Train Machine Learning Models and Forecast Bitcoin Prices: Depth vs. Width," in *8th International Conference on Information Technology Trends: Industry 4.0: Technology Trends and Solutions, ITT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 39–44. doi: 10.1109/ITT56123.2022.9863966.
- [41] U. Maqsood, F. Y. Khuhawar, S. Talpur, F. H. Jaskani, and A. A. Memon, "Twitter Mining based Forecasting of Cryptocurrency using Sentimental Analysis of Tweets," in *2022 Global Conference on Wireless and Optical Technologies, GCWOT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/GCWOT53057.2022.9772923.

- [42] R. Murugesan, V. Shanmugaraja, and A. Vadivel, "Forecasting Bitcoin Price Using Interval Graph and ANN Model: A Novel Approach," *SN Comput Sci*, vol. 3, no. 5, Sep. 2022, doi: 10.1007/s42979-022-01291-x.
- [43] J. Kristensen, J. P. Madrigal-Cianci, G. Felekis, and M. Liatsikou, "Cryptocurrency Price Prediction With Multi-task Multi-step Sequence-to-Sequence Modeling," in *Proceedings - 2022 IEEE International Conference on Blockchain, Blockchain 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 53–60. doi: 10.1109/Blockchain55522.2022.00018.
- [44] S. Lahmiri and S. Bekiros, "Deep Learning Forecasting in Cryptocurrency High-Frequency Trading," Mar. 01, 2021, *Springer*. doi: 10.1007/s12559-021-09841-w.
- [45] A. M. Rather, "A new method of ensemble learning: case of cryptocurrency price prediction," *Knowl Inf Syst*, vol. 65, no. 3, pp. 1179–1197, Mar. 2023, doi: 10.1007/s10115-022-01796-0.
- [46] D. Yu, "Cryptocurrency Price Prediction Based on Long-Term and Short-Term Integrated Learning," Institute of Electrical and Electronics Engineers (IEEE), Mar. 2022, pp. 543–548. doi: 10.1109/icpeca53709.2022.9718963.
- [47] M. H. Mishal *et al.*, "Prediction of Cryptocurrency Price using Machine Learning Techniques and Public Sentiment Analysis," in *Proceedings of 2022 25th International Conference on Computer and Information Technology, ICCIT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 657–662. doi: 10.1109/ICCIT57492.2022.10055524.
- [48] A. Tanwar and V. Kumar, "Prediction of Cryptocurrency prices using Transformers and Long Short term Neural Networks," in *2022 International Conference on Intelligent Controller and Computing for Smart Power, ICCCSP 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ICICCSP53532.2022.9862436.
- [49] X. Li and L. Du, "Bitcoin daily price prediction through understanding blockchain transaction pattern with machine learning methods," *J Comb Optim*, vol. 45, no. 1, Jan. 2023, doi: 10.1007/s10878-022-00949-9.
- [50] N. Passalis, J. Kannianen, M. Gabbouj, A. Iosifidis, and A. Tefas, "Forecasting Financial Time Series Using Robust Deep Adaptive Input Normalization," *J Signal Process Syst*, vol. 93, no. 10, pp. 1235–1251, Oct. 2021, doi: 10.1007/s11265-020-01624-0.
- [51] Y. Son *et al.*, "Using Transformers and Deep Learning with Stance Detection to Forecast Cryptocurrency Price Movement," in *International Conference on ICT Convergence*, IEEE Computer Society, 2022, pp. 1301–1306. doi: 10.1109/ICTC55196.2022.9953018.
- [52] K. P. Sharma, S. K. Singh, A. Choudhary, and H. Goel, "Price Prediction of Bitcoin using Social Media Activities and Past Trends," in *Proceedings of the 13th International*

Conference on Cloud Computing, Data Science and Engineering, Confluence 2023, Institute of Electrical and Electronics Engineers Inc., 2023, pp. 516–521. doi: 10.1109/Confluence56041.2023.10048799.

- [53] J. Aravindan and R. K. V. Sankara, “Parent Coin based Cryptocurrency Price Prediction using Regression Techniques,” in *2022 IEEE Region 10 Symposium, TENSYPMP 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/TENSYPMP54529.2022.9864452.
- [54] S. M. Hafez, M. El Nainay, M. Abougabal, and A. Kosba, “Ethereum Price Prediction using Topological Data Analysis,” in *2022 IEEE Global Conference on Artificial Intelligence and Internet of Things, GCAIoT 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 146–153. doi: 10.1109/GCAIoT57150.2022.10019049.
- [55] N. Malsa, V. Vyas, and J. Gautam, “RMSE calculation of LSTM models for predicting prices of different cryptocurrencies,” *International Journal of Systems Assurance Engineering and Management*, 2021, doi: 10.1007/s13198-021-01431-1.
- [56] I. E. Livieris, S. Stavroyiannis, E. Pintelas, T. Kotsilieris, and P. Pintelas, “A dropout weight-constrained recurrent neural network model for forecasting the price of major cryptocurrencies and CCI30 index,” *Evolving Systems*, vol. 13, no. 1, pp. 85–100, Feb. 2022, doi: 10.1007/s12530-020-09361-2.
- [57] R. K. Jana, I. Ghosh, and D. Das, “A differential evolution-based regression framework for forecasting Bitcoin price,” *Ann Oper Res*, vol. 306, no. 1–2, pp. 295–320, Nov. 2021, doi: 10.1007/s10479-021-04000-8.
- [58] E. Bouri, K. Gkillas, R. Gupta, and C. Pierdzioch, “Forecasting Realized Volatility of Bitcoin: The Role of the Trade War,” *Comput Econ*, vol. 57, no. 1, pp. 29–53, Jan. 2021, doi: 10.1007/s10614-020-10022-4.
- [59] X. Ye, Y. Li, X. Feng, and C. Heng, “A Crypto Market Forecasting Method Based on Catboost Model and Bigdata,” in *2022 7th International Conference on Intelligent Computing and Signal Processing, ICSP 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 686–689. doi: 10.1109/ICSP54964.2022.9778789.
- [60] X. Du, Z. Tang, J. Wu, K. Chen, and Y. Cai, “A New Hybrid Cryptocurrency Returns Forecasting Method Based on Multiscale Decomposition and an Optimized Extreme Learning Machine Using the Sparrow Search Algorithm,” *IEEE Access*, vol. 10, pp. 60397–60411, 2022, doi: 10.1109/ACCESS.2022.3179364.
- [61] M. H. Khan, D. Sharma, N. N. Prasanth, and S. P. Raja, “Bitcoin Price Prediction in a Distributed Environment Using a Tensor Processing Unit: A Comparison With a CPU-Based Model,” *IEEE Syst Man Cybern Mag*, vol. 8, no. 2, pp. 39–43, Apr. 2022, doi: 10.1109/msmc.2021.3118893.

- [62] N. Ramya, R. Sanjay Roshan, R. Vishal Srinivas, and D. Krishna Prasad, "Crypto-Currency Price Prediction using Machine Learning," in *2022 6th International Conference on Trends in Electronics and Informatics, ICOEI 2022 - Proceedings*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 1455–1458. doi: 10.1109/ICOEI53556.2022.9776665.
- [63] P. C. Sekhar, M. Padmaja, B. Sarangi, and Aditya, "Prediction of Cryptocurrency using LSTM and XGBoost," in *2022 IEEE International Conference on Blockchain and Distributed Systems Security, ICBDS 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/ICBDS53701.2022.9935871.
- [64] J. Wu, X. Guo, M. Fang, and J. H. Zhang, "Short term return prediction of cryptocurrency based on XGBoost algorithm," in *Proceedings - 2022 International Conference on Big Data, Information and Computer Network, BDICN 2022*, Institute of Electrical and Electronics Engineers Inc., 2022, pp. 39–42. doi: 10.1109/BDICN55575.2022.00015.
- [65] N. Passalis *et al.*, "Multisource financial sentiment analysis for detecting Bitcoin price change indications using deep learning," *Neural Comput Appl*, vol. 34, no. 22, pp. 19441–19452, Nov. 2022, doi: 10.1007/s00521-022-07509-6.
- [66] E. Loginova, W. K. Tsang, G. van Heijningen, L. P. Kerkhove, and D. F. Benoit, "Forecasting directional bitcoin price returns using aspect-based sentiment analysis on online text data," *Mach Learn*, 2021, doi: 10.1007/s10994-021-06095-3.
- [67] S. Oikonomopoulos, K. Tzafilkou, D. Karapiperis, and V. Verykios, "Cryptocurrency Price Prediction using Social Media Sentiment Analysis," in *13th International Conference on Information, Intelligence, Systems and Applications, IISA 2022*, Institute of Electrical and Electronics Engineers Inc., 2022. doi: 10.1109/IISA56318.2022.9904351.
- [68] R. Parekh *et al.*, "DL-GuesS: Deep Learning and Sentiment Analysis-Based Cryptocurrency Price Prediction," *IEEE Access*, vol. 10, pp. 35398–35409, 2022, doi: 10.1109/ACCESS.2022.3163305.

Anexo A

Os artigos analisados são apresentados de acordo com o título, autores, ano de publicação, criptomoedas usadas como objeto da previsão, tipo de previsões que efetuam, modelos de aprendizagem máquina usados, conjuntos de dados e períodos usados para aprendizagem e testes, métricas de desempenho, melhores resultados obtidos, contribuições e conclusões.

Título: Quantitative cryptocurrency trading: exploring the use of machine learning techniques [2]

Autores: Giuseppe Attanasio, Paolo Garza, Luca Cagliero, Elena Baralis

Ano: 2019

Criptomoedas: Várias

Tipo de Previsão: Preço diário

Modelos de previsão: ARIMA, EXPSMOOTH, LINREG, MLP, SVC, Naive Bayes, Random Forest

Conjunto de dados: Open, Close, High, Low de todas as moedas - Jan 2011 - Dez 2018

Métricas: Taxa de lucro

Melhores resultados: Taxas de lucro e superiores às referências de mercado. Análise anual com taxas de lucro que vão até aos 1364%.

Contribuições/conclusões: O artigo apresenta uma comparação de vários modelos de aprendizagem máquina e conclui que os modelos de previsão de séries temporais (regressão) têm melhores resultados que os modelos de classificação. O artigo conclui ainda que o treino de várias criptomoedas em simultâneo melhora o desempenho relativamente ao treino individual.

Título: A dropout weight-constrained recurrent neural network model for forecasting the price of major cryptocurrencies and CCI30 index [56]

Autores: Ioannis E. Livieris · Stavros Stavroyiannis · Emmanuel Pintelas · Theodore Kotsilieris · Panagiotis Pintelas

Ano: 2021

Criptomoedas: ICCi30

Tipo de Previsão: Preço a 7, 14 e 21 dias

Modelos de previsão: RNN, LSTM, CNN

Conjunto de dados: Preços diários BTC, ETH, XRP e ICCi30 - Jan 2017 - Jun 2019

Métricas: MAE e RMSE

Melhores resultados: MAE=45,805, 46,087, 54,097 e RSME=59,636, 59,632, 70,071 para 7, 14 e 21 dias respetivamente

Contribuições/conclusões: O artigo propõe a introdução de restrição de pesos e desistência nas redes neuronais para reduzir o problema de *overfitting*. A técnica é aplicada aos modelos de redes neuronais RNN, LSTM e CNN, sendo que em todos os modelos houve um melhoramento no desempenho, sendo que as RNN tiveram os melhores resultados.

Título: Bitcoin Price Prediction: A Machine Learning Sample Dimension Approach [1]

Autores: Sumit Ranjan · Parthajit Kayal · Malvika Saraf

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário e a 5 minutos

Modelos de previsão: LOGREG, Linear Discriminant Analysis, Random Forest, XGBoost, Quadratic Discriminant, SVM, Decision Tree e KNN

Conjunto de dados: Bitcoin daily price, block size, hash rate, mining difficulty, number of transactions, confirmed transactions per day, mempool transaction count, mempool size, total transaction fees, market capitalization, estimated transaction value, the time between blocks, trades per minute, search volume index from Google.com, and gold spot price.; 5-min interval Bitcoin trading prices. Jan 2017 - Dez 2019

Métricas: Accuracy, Precision, Recall e F1-score

Melhores resultados: Accuracy 64,84% para o valor diário e 59,4% para o intervalo de 5 minutos.

Contribuições/conclusões: Este artigo compara vários modelos com base num vasto número de atributos oriundos da Blockchain. Os melhores modelos foram LOGREG para o preço diário e XGBoost para o intervalo de 5-minutos

Título: Time-series forecasting of Bitcoin prices using high-dimensional features: a machine learning approach [35]

Autores: Mohammed Mudassir, Shada Bennbaia, Devrim Unal, Mohammad Hammoudeh

Ano: 2020

Criptomoedas: Bitcoin

Tipo de Previsão: Cassificação de sinal e preço do dia seguinte, 7, 30 e 90 dias

Modelos de previsão: ANN, Stacked ANN, SVM, LSTM

Conjunto de dados: Simple Moving Average (SMA), Exponential Moving Average (EMA), Relative Strength Index (RSI), Weighted Moving Average (WMA), Standard Deviation (STD), Variance (VAR), Triple Moving Exponential (TRIX) and Rate of Change (ROC). Abr 2013 - Dez 2019

Métricas: MAE, RMSE, MAPE, Accuracy , F1-score e AUC

Melhores resultados: 65% de Accuracy para o para o dia seguinte e 62% - 64% de Accuracy para a previsão de 7 a 90 dias. Para os valores do dia seguinte e a taxa de erro MAPE é 0,0144 para o dia seguinte e entre 0,0288 e 0,0410 para as previsões de 7 a 90 dias.

Contribuições/conclusões: O artigo apresenta a elasticidade do horizonte de previsão sem perda significativa no desempenho dos modelos. Os modelos com melhor desempenho foram o SANN na previsão para o dia seguinte e o LSTM para a previsão de 7 a 90 dias.

Título: The random neural network in price predictions [36]

Autor: Will Serrano

Ano: 2021

Criptomoedas: Bitcoin, Ethereum, Ripple e outras cotações

Tipo de Previsão: Preço diário

Modelos de previsão: RNN, LSTM e LINREG

Conjunto de dados: Preços diários + uma variável não correlacionada. Jul 2010 - Set 2020 (para Bitcoin)

Métricas: RMSE, MAE e MAPE

Melhores resultados: Para Bitcoin apresenta RMSE=217,53, MAE=79,25 e MAPE=3,26

Contribuições/conclusões: O artigo demonstra que o desempenho varia conforme a cotação, o número de variáveis e o número de neurónios usado nas redes, mas de uma forma geral os modelos RNN e LSTM têm os melhores resultados e muito similares, sendo que para a Bitcoin o LSTM com 5 neurónios teve melhor desempenho. O desempenho com duas variáveis é ligeiramente superior do que com uma variável apenas.

Título: Smoothing and stationarity enforcement framework for deep learning time-series forecasting [9]

Autores: Ioannis E. Livieris, Stavros Stavroyiannis, Lazaros Iliadis, Panagiotis Pintelas

Ano: 2021

Criptomoedas: CCI30 e outros cotações

Tipo de Previsão: Preço diário

Modelos de previsão: CNN-LSTM

Conjunto de dados: Preços diários. Jan 2017 - Mar 2020

Métricas: MAE, RMSE, R2. Accuracy, AUC, Geometric Mean, Sensitivity e Specificity

Melhores resultados: Para CCI30 o modelo teve Accuracy=55,94% e RMSE=190,48, MAE=112,75 e R2=0,934

Contribuições/conclusões: O artigo introduz um coeficiente alisamento de séries temporais para reduzir a volatilidade, fazendo o alisamento com pesos em função dos valores mais recentes para os mais antigos.

Título: Forecasting financial time series with Boltzmann entropy through neural networks [15]

Autores: Luca Grilli, Domenico Santoro

Ano: 2022

Criptomoedas: Bitcoin e outras cotações de bolsa

Tipo de Previsão: Preço diário

Modelos de previsão: LSTM

Conjunto de dados: Open, High, Low, Adj Close/Last, Volume, MACD, Stochastic, RSI, Entropy . Jan 2015 - Dez 2019

Métricas: RMSE

Melhores resultados: O melhor RMSE para Bitcoin é de 372,84

Contribuições/conclusões: O artigo inclui a entropia de Boltzmann nos atributos previsores e compara quais os atributos que produzem melhores resultados quando aplicados no modelo proposto. A melhor combinação é Open, High, Low, Close com Entropia

Título: Prediction of cryptocurrency returns using machine learning [27]

Autores: Erdinc Akyildirim, Ahmet Goncu, Ahmet Sensoy

Ano: 2020

Criptomoedas: Top 20

Tipo de Previsão: Preço diário e a 15-, 30-, 60 minutos

Modelos de previsão: SVM, LOGREG, ANN, e Random Forests

Conjunto de dados: "Open, high, low, close, High–low, # of trades, US dollar volume and cryptocurrency volume (for all trades), # of trades, US dollar volume and cryptocurrency volume (for buyer-initiated trades), Returns Moving average (MA), Correlation MA and close, Relative strength index (RSI, Moving average convergence, divergence (MACD), Rate of change, rate of change return, Exponential weighted moving average (EWMA), Momentum indicator, Average true range, Williams' %R, Aroon stochastic oscillatorm, Commodity channel index, Double exponential moving average, (DEMA). Abr 2013 - Jun 2018

Métricas: Accuracy

Melhores resultados: Os melhores resultados foram para a previsão dos valores diários das moedas ETH e XMR com Accuracy de 69%, para Bitcoin a 60 minutos 63%, 61% para Bitcoin a 30 minutos e 63% para a previsão a 15 minutos da OMG.

Contribuições/conclusões: O artigo apresenta uma comparação de vários modelos, sendo que o melhor desempenho foi conseguido com o classificador SVM.

Título: A differential evolution-based regression framework for forecasting Bitcoin price [57]

Autores: R. K. Jana, Indranil Ghosh, Debojyoti Das

Ano: 2021

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário de 1 até 5 dias

Modelos de previsão: Support Vector Regression (SVR)

Conjunto de dados: Preços diários. Jan 2013 - Fev 2019

Métricas: Directional predictive accuracy, Nash–sutcliffe efficiency, Index of agreement e Theil Index

Melhores resultados: Directional predictive accuracy (DA) = 98,9%, Nash–sutcliffe efficiency (NSE),=99,8% Index of agreement (IA)=99,9%, Theil Index (TI)=2,8%

Contribuições/conclusões: O artigo demonstra que a combinação da pesquisa meta heurística com os modelos de regressão numa configuração granular otimiza a previsão.

Título: Forecasting mid-price movement of Bitcoin futures using machine learning [23]

Autores: Erdinc Akyildirim, Oguzhan Cepni, Shaen Corbet, Gazi Salah Uddin

Ano: 2021

Criptomoedas: Bitcoin

Tipo de Previsão: Classificação do sinal do preço médio dos intervalos de 5, 10, 15, 30 e 60 minutos

Modelos de previsão: KNN, Naive Bayes, LOGREG, Random Forest, SVM, XGBoost

Conjunto de dados: Preços médios de diferentes intervalos 5-, 10-, 15-, 30-, 60 minutos, por períodos de 1 a 5 meses. Jan 2020 - Set 2020

Métricas: Accuracy

Melhores resultados: Os resultados variam consoante os intervalos, mas os melhores resultados foram atingidos KNN com 87% Accuracy e o SVM com 71%. Os valores médios para LOGREG, Naive Bayes e XGBoost foram de 54%, 45%, e 55%, respetivamente.

Contribuições/conclusões: O artigo compara os vários modelos de aprendizagem máquina e cinco dos seis modelos usados têm um Accuracy acima dos 50% e têm resultados melhores do que o modelo ARIMA, mais tradicional para séries temporais.

Título: Forecasting Realized Volatility of Bitcoin: The Role of the Trade War [58]

Autores: Elie Bouri, Konstantinos Gkillas, Rangan Gupta, Christian Pierdzioch

Ano: 2020

Criptomoedas: Bitcoin

Tipo de Previsão: Previsão da volatilidade diária, semanal e mensal

Modelos de previsão: Random forest

Conjunto de dados: 1 hora - US-China trade indicators (Google Trends.) e preços da Bitcoin, EOS, Ethereum, Litecoin e Ripple. Jul 2017 - Jun 2019

Métricas: Absolute Loss (L1) e Quadratic Loss (L2)

Melhores resultados: Para a previsão diária conseguiu L1=0.0000 e L2=0.0001, para a semanal L1=0.0046 e L2=0.0685 e para a mensal L1=0.0242 e L2=0.1276

Contribuições/conclusões: O artigo é relevante para demonstrar que a guerra comercial entre EUA e China também pode influenciar a volatilidade e conseqüentemente os preços da Bitcoin

Título: Price Prediction of Cryptocurrency Using a Multi-Layer Gated Recurrent Unit Network with Multi Features [6]

Autores: Gyana Ranjan Patra, Mihir Narayan Mohanty

Ano: 2022

Criptomoedas: Bitcoin, Ethereum e Dogecoin

Tipo de Previsão: Preço a 21 dias

Modelos de previsão: Multilayer GRU, GRU RNN e LSTM

Conjunto de dados: Open, Close, High, Low, Volume, Ammount Traded in USD. Jan 2014 - Jun 2021 (Bitcoin), Fev 2016 - Abr 2020 (Ethereum) e Set 2014 - Jul 2021 (Dogecoin)

Métricas: MSE, RMSE, MAE, MAPE, Accuracy e Precision

Melhores resultados: Para a Bitcoin o modelo LSTM teve 97,63% Accuracy, 98,16% para GRU e Multilayer GRU 99,69%. Em termos de MAPE o modelo LSTM teve 0,0237, 0,0184 para GRU e 0,0031 para o Multilayer GRU.

Contribuições/conclusões: O artigo demonstra que apesar dos modelos LSTM e GRU terem um bom desempenho, quando usado o Multilayer o GRU consegue uma melhoria considerável.

Título: Forecasting Financial Time Series Using Robust Deep Adaptive Input Normalization [50]

Autores: Nikolaos Passalis, Juho Kannianen, Moncef Gabbouj, Alexandros Iosifidis, Anastasios Tefas

Ano: 2021

Criptomoedas: Bitcoin, Ethereum e outras cotações de bolsa

Tipo de Previsão: A cada 50 dias prevê o preço médio dos 10 dias seguintes

Modelos de previsão: MLP (Multilayer Perception), CNN e RNN

Conjunto de dados: Para Bitcoin, valores médios diários de intervalos de 1 minuto - open, high, low, close, volume volume-weighted. Jan 2014 - Abr 2020

Métricas: F1-score, κ score, MAE, R^2 e Max Error

Melhores resultados: Para Bitcoin os melhores resultados foram obtidos com o modelo CNN com MAE = 83,27, R^2 = 0,9948 e Max Error = 408.49

Contribuições/conclusões: O artigo propõe a implementação de uma camada adaptativa de normalização dos valores dos atributos previsores que melhora o desempenho dos 3 modelos testados.

Título: Bitcoin closing price movement prediction with optimal functional link neural networks [8]

Autor: Sarat Chandra Nayak

Ano: 2021

Criptomoedas: Bitcoin

Tipo de Previsão: Preço do dia, semana e mês seguintes

Modelos de previsão: Functional link neural network (FLN), MLP, SVM, ARIMA, Least Square Estimation (LSE)

Conjunto de dados: Daily, weekly, monthly closing values. Set 2014 - Dez 2020

Métricas: MAPE, NMSE, UT e ARV

Melhores resultados: Os melhores valores em termos de MAPE são 0,03185 para a previsão diária, 0,01557 para a previsão semanal e 0,03349 para a previsão mensal

Contribuições/conclusões: O artigo compara várias configurações do modelo FLN com os restantes modelos. Todas as configurações usadas (Trigonometric, Chebyshev, Laguerre e Legendre) tiveram melhores resultados que os restantes modelos, sendo a melhor configuração a Trigonometric para valores diários e Legendre para valores semanais e mensais.

Título: Deep Learning Forecasting in Cryptocurrency High-Frequency Trading [44]

Autores: Salim Lahmiri, Stelios Bekiros

Ano: 2021

Criptomoedas: Bitcoin

Tipo de Previsão: Preço a 5 minutos seguintes

Modelos de previsão: Deep Forward Neural Network (DFNN)

Conjunto de dados: Preço a cada 5 minutos. Jan. 2016 - Mar 2018

Métricas: RMSE

Melhores resultados: RMSE = 1,4406

Contribuições/conclusões: O artigo analisa as potencialidades do modelo DFNN, que aplicado com gradiente Levenberg-Marquardt tem melhor desempenho, é fácil de utilizar e é rápido a processar, sendo ideal para online trading.

Título: RMSE calculation of LSTM models for predicting prices of different cryptocurrencies [55]

Autores: Nitima Malsa, Vaibhav Vyas, Jyoti Gautam

Ano: 2021

Criptomoedas: Ethereum, Cardano ADA, EOS, NEO e Tron

Tipo de Previsão: Preço diário

Modelos de previsão: LSTM

Conjunto de dados: Preços diários. Não apresenta o período de análise, apenas o número de dias dos *datasets*, que vão de 1000 a 1750.

Métricas: RMSE

Melhores resultados: RMSE = 0,01 para a Tron, 0,06 para Cardano ADA, 0,60 para NEO, 0,79 para EOS e 1,06 para a Ethereum

Contribuições/conclusões: O artigo compara o desempenho do modelo LSTM com diferentes criptomoedas e tem melhor desempenho com a Tron e o pior desempenho com a Ethereum

Título: Forecasting and trading cryptocurrencies with machine learning under changing market conditions [7]

Autores: Helder Sebastião, Pedro Godinho

Ano: 2021

Criptomoedas: Bitcoin, Ethereum e Litecoin

Tipo de Previsão: Previsão da rentabilidade das estratégias de negócio (sinal e valor)

Modelos de previsão: LINREG, Random Forests e SVM

Conjunto de dados: 50 variáveis usadas, entre as quais open, close, high, low, volume, market capitalization, Returns. Ago 2015 - Mar 2019

Métricas: Success Rate, MAE, RMSE e Theil's U2

Melhores resultados: Os resultados para a Bitcoin foram MAE=2,24 e RMSE=3,36

Contribuições/conclusões: O artigo demonstra que o modelo LINREG teve melhor desempenho que o RF e o SVM, que teve o pior desempenho para as três moedas.

Título: Hybrid data decomposition-based deep learning for Bitcoin prediction and algorithm trading [38]

Autores: Yuze Li, Shangrong Jiang, Xuerong Li, Shouyang Wang

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Classificação do Sinal e preço a 1, 2, 3 dias seguintes

Modelos de previsão: LSTM, LINREG, ARIMA

Conjunto de dados: Preços diários. Abr 2013 - Jan 2021

Métricas: RMSE, MAE, MAPE, Directional Accuracy

Melhores resultados: RMSE=0,0071, 0,0073 e 0,0080 para a previsão a 1, 2 e 3 dias respectivamente. MAPE=0,0113, 0,0121 e 0,0126

Contribuições/conclusões: O artigo propõe a introdução da técnica de decomposição dos valores das séries temporais em sinal bidirecional, o que melhora o desempenho do modelo. O modelo com melhor desempenho é o LSTM.

Título: Cryptocurrencies asset pricing via machine learning [32]

Autor: Qiyu Wang

Ano: 2021

Criptomoedas: Top 100

Tipo de Previsão: Preço diário

Modelos de previsão: LINREG, Random Forests, Neural Networks

Conjunto de dados: 30 variáveis de mercado, equidade, volatilidade, liquidez. factores entre categorias e factores únicos das criptomoedas. Dez 2013 - Ago 2018

Métricas: R²

Melhores resultados: R²=0,639 para a Bitcoin

Contribuições/conclusões: O artigo contribui com um sistema de avaliação dos atributos previsores em termos de contribuição para um melhor desempenho dos modelos.

Título: Forecasting Bitcoin Price Using Interval Graph and ANN Model: A Novel Approach [42]

Autores: R. Murugesan, V. Shanmugaraja, A. Vadivel

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço do dia, semana e mês seguintes

Modelos de previsão: Back Propagation Neural Network (BPNN), Radial Basis Function Neural Network (RBFNN) e ELM

Conjunto de dados: open, close, high, low. Não indica o período

Métricas: MAPE, RMSE e Dstat

Melhores resultados: Os melhores valores foram MAPE=0,02900 e RMSE=0,06546 para a previsão ao dia, MAPE=0,05200 e RMSE=0,05200 para a previsão semanal e MAPE=0,01208 e RMSE=0,02801 para a previsão mensal

Contribuições/conclusões: O artigo inclui Interval Graph nos modelos de Redes Neurais, que melhora o seu desempenho. Os melhores modelos foram BPNN para previsão diária e mensal, sendo o ELM melhor para a previsão semanal.

Título: A new method of ensemble learning: case of cryptocurrency price prediction [45]

Autor: Akhter Mohiuddin Rather

Ano: 2022

Criptomoedas: Top 10

Tipo de Previsão: Previsão do preço a 3 meses

Modelos de previsão: RNN, SVM e Decision Trees

Conjunto de dados: Preços diários. Jan 2020 - Mai 2022

Métricas: R^2 e RMSE

Melhores resultados: Para Bitcoin o modelo combinado tem $R^2=0,94$ e $RMSE=6,73.0$

Contribuições/conclusões: O artigo demonstra que um modelo combinado dos três algoritmos tem um desempenho superior aos modelos isolados.

Título: Bitcoin daily price prediction through understanding blockchain transaction pattern with machine learning methods [49]

Autores: Xiao Li, Linda Du

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário

Modelos de previsão: SVM e Full Connected Neural Network (FCNN)

Conjunto de dados: Bitcoin blockchain graph data, usando três intervalos de tempo em separado. Ago 2013 - Jul 2016, Abr 2013 - Abr 2017 e Jan 2017 - Dez 2017

Métricas: MAPE

Melhores resultados: O modelo com melhor desempenho apresenta $MAPE=1,69$

Contribuições/conclusões: O artigo inclui a informação Graph da Blockchain, e daí retira padrões das transações, para depois aplicar a aprendizagem em diferentes horizontes temporais. O modelo SVM tem melhor desempenho.

Título: A Crypto Market Forecasting Method Based on Catboost Model and Bigdata [59]

Autores: Xiaoxiao Ye, Yirui Li, Xu Feng, Chen Heng

Ano: 2022

Criptomoedas: Bitcoin e Ethereum

Tipo de Previsão: Preço a 15 minutos

Modelos de previsão: CatBoost, Gradient Boosting, SVM e LINREG

Conjunto de dados: intervalo de 1 minuto - Count, Open, High, Low, Close, Volume, VWAP. Período não indicado

Métricas: Pearson Correlation (Pxy)

Melhores resultados: $Pxy=0,0358$

Contribuições/conclusões: O artigo compara o desempenho dos diferentes modelos para previsão de alta frequência. O modelo CatBoost tem o melhor desempenho.

Título: A New Hybrid Cryptocurrency Returns Forecasting Method Based on Multiscale Decomposition and an Optimized Extreme Learning Machine Using the Sparrow Search Algorithm [60]

Autores: Xiaxou Du, Zhenpeng Tang, Junchuan Wu, Kaijie Chen, Yi Cai

Ano: 2022

Criptomoedas: Bitcoin e Ethereum

Tipo de Previsão: Taxas de lucro do 1 a 5 dias seguintes

Modelos de previsão: ELM (sem e com otimização Sparrow Search), ARIMA, Naive Baues, SVR

Conjunto de dados: Taxas de lucro diárias, com base no preço final do dia. Jan 2017 - Jun. 2021

Métricas: MAE, NRMSE, SMAPE e R2

Melhores resultados: Para Bitcoin o modelo teve MAE=0,6163 e NRMSE=0,0238 para previsão a 1 dia e MAE=1,1142 e NRMSE=0,0432 para a previsão a 5 dias

Contribuições/conclusões: O artigo propõe um modelo que recorre à decomposição dos componentes previsores em duas fases, Variational Modal Decomposition (VMD) e Completed Ensemble Empirical Mode Decomposition with Adaptive Noise (CEEMDAN), aplicando depois o modelo de previsão. Modelo ELM otimizado tem o melhor desempenho.

Título: Bitcoin Price Forecasting using Time-series Architectures [12]

Autores: Louise Gabriel N. De Leon, Rafael C. Gomez, Martin Lance G. Tacal, Jonathan V. Taylarm Verlyn V. Nojor, Alonica R. Villanueva

Ano: 2023

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário

Modelos de previsão: ARIMA, SARIMA, GRU, RNN, LSTM, e Facebook Prophet

Conjunto de dados: open, low, high, close e volume. Jan 2018 - Jan 2022

Métricas: MSE e RMSE

Melhores resultados: Os melhores resultados têm MSE=2159166,25 e RMSE=1469,41

Contribuições/conclusões: O artigo compara o desempenho de vários modelos sendo que o com melhores resultados é o GRU e o pior o Facebook Prophet.

Título: Bitcoin Price Prediction in a Distributed Environment Using a Tensor Processing Unit [61]

Autores: Mohd Hammad Khan, Devdutt Sharma, N. Narayanan Prasanth, and S.P. Raja

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço ponderado do dia seguinte

Modelos de previsão: LSTM

Conjunto de dados: Price, weighted price. Jan 2014 - Nov 2020

Métricas: Accuracy e MSE

Melhores resultados: Apenas apresenta visualização gráfica das previsões e não os valores de MSE e Accuracy. Tempo de processamento TPU inferior em 70,65%

Contribuições/conclusões: O artigo compara o desempenho do modelo LSTM quando aplicado o processamento através de CPU ou de TPU (Tensor Processing Unit), e embora este tenha resultados ligeiramente inferiores de desempenho em termos de previsão tem melhor desempenho em termos de velocidade.

Título: Bitcoin Price Prediction Using Machine Learning and Deep Learning Algorithms [13]

Autores: Bhavay Malhotra, Chittaranjan Chandwani, Pratham Agarwala, Suman Mann

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário

Modelos de previsão: ARIMA, LINREG, Ridge Regression, LASSO, LSTM e GRU

Conjunto de dados: Close, high, low, open e volume. Dez 2020 - Mai 2022

Métricas: MAE

Melhores resultados: MSE=0,02294

Contribuições/conclusões: O artigo analisa vários modelos e conclui que o ARIMA tem o melhor desempenho, contudo um fator determinante para o melhor resultado tem a ver com o fato do horizonte temporal ser ajustado. Para este caso com 4 meses de registos foi atingido o melhor desempenho.

Título: Crypto Profit Forecasting using hybrid Machine Learning method [25]

Autores: Qi Zhong, Mingda Huo

Ano: 2022

Criptomoedas: Várias - não indica quais

Tipo de Previsão: Preço a 1 e 5 minutos

Modelos de previsão: Catboost, XGboost, Gradient Boosting

Conjunto de dados: intervalos de 1 Minuto - Upper_Shadow=high-max(close,open), ower_shadow=min(close,open)-low, Close/Open, Close-Open, High-Low, High/Low, mean(Open, High, Low, Close), median(Open, High, Low, Close). Não indica o período, o dataset é composto por 50 registos

Métricas: Root Mean Square Percentage Error Loss (RMSPE), Pearson Correlation Coeffic (Pxy)

Melhores resultados: RMSPE=0,0359

Contribuições/conclusões: O artigo compara os modelos de *Boosting* (impulsão) e propõe um modelo combinado Catboost + XGboost que produz melhores resultados do que os modelos usados separadamente.

Título: Cryptocurrency Price forecasting: A Comparative Study of Machine Learning Model in Short-Term Trading [29]

Autor: Haoran Lyu

Ano: 2022

Criptomoedas: Top 10

Tipo de Previsão: Preço diário

Modelos de previsão: Decision Tree, LINREG, Ridge Regression, LASSO, Bayesian Ridge Regression Random Forest, KNNs, NN, Gradient Boosting e SVM

Conjunto de dados: Open, close, high, low, volume. Mai 2021 - Set 2021

Métricas: R^2 , RMSE, Explained Variance, RMSLE, MAE

Melhores resultados: Para a Bitcoin o melhor resultado $R^2=0,663052$, RMSE=0,663052 MAE=2139,914446

Contribuições/conclusões: O artigo analisa o desempenho de vários modelos para várias criptomoedas e conclui que os resultados variam consoante as moedas utilizadas, contudo o Gradient Boosting teve melhor desempenho para a Bitcoin, bem como na maior parte das restantes criptomoedas.

Título: Cryptocurrency Price Prediction Based on Long-Term and Short-Term Integrated Learning [46]

Autor: Dongze Yu

Ano: 2022

Criptomoedas: Bitcoin, Binance Coin, Cardano, Dogecoin, Ethereum, Tether, XRP

Tipo de Previsão: Preço diário

Modelos de previsão: SVR

Conjunto de dados: Open, close, High, low, volume, quote change, Closing price for next day. Dados até Jun 2021

Métricas: RMSE, R^2

Melhores resultados: Para a Bitcoin o modelo proposto tem RMSE=5251,1959 e $R^2=0,7200$

Contribuições/conclusões: O artigo propõe a introdução do modelo integrado de Long-Term Short-Term, que melhora consideravelmente o desempenho do modelo SVR.

Título: Crypto-Currency Price Prediction using Machine Learning [62]

Autores: Ramya N, Sanjay Roshan R, Vishal Srinivas R, Krishna Prasad D

Ano: 2022

Criptomoedas: Bitcoin e outras das principais

Tipo de Previsão: Previsão do preço a 1 semana, 1 mês e 1 ano

Modelos de previsão: Facebook Prophet

Conjunto de dados: "Open, close, High, low, volume, Closing adj. Price (adjusted to return the value after accounting). 2017 - 2022"

Métricas: Não apresenta

Melhores resultados: Visualização gráfica apenas

Contribuições/conclusões: O artigo apenas conclui que os resultados são aproximados e que o modelo Facebook Prophet é uma boa solução para a previsão de várias criptomoedas. Os gráficos apresentados demonstram proximidade dos valores previstos aos reais.

Título: Cryptocurrency Price Prediction With Multi-task Multi-step Sequence-to-Sequence Modeling [43]

Autores: Jesper Kristensen, Juan P. Madrigal-Cianci, Giorgos Felekis, Maria Liatsikou

Ano: 2022

Criptomoedas: 22 das principais

Tipo de Previsão: Preço diário

Modelos de previsão: LSTM, Last Values Predictor (LVP), Random Forest, FFNN

Conjunto de dados: Intervalo de 1 minuto - preço de todas as moedas em simultâneo. Jan 2020 - Dez 2021

Métricas: MAPE, MSE, Coefficient of Determination

Melhores resultados: Para Bitcoin os modelos propostos apresentam MAPE=0,066 e MSE=0,043

Contribuições/conclusões: O artigo propõe dois modelos LSTM treinados com intervalos de preço médio da hora a hora, a cada 8 horas e considerando uma única criptomoeda ou todas em simultâneo. O desempenho dos modelos varia de criptomoeda para criptomoeda. No caso da Bitcoin o modelo treinado só com uma criptomoeda apresenta melhor MSE, o modelo com todas as moedas apresenta melhor MAPE.

Título: Cryptocurrency Value Prediction with Boosting Models [24]

Autores: Swati S, Anuraj Mohan

Ano: 2022

Criptomoedas: Bitcoin e Ripple

Tipo de Previsão: Preço diário

Modelos de previsão: XGBoost, AdaBoost e CatBoost

Conjunto de dados: Intervalo de 1 minuto - Open, close, High, low, volume, 2012 - 2020.

Métricas: MAE, MSE, RMSE e R^2

Melhores resultados: Melhores valores atingidos MAE=345.512, MSE=209778, RMSE=458,016 e $R^2 = 0,91365$

Contribuições/conclusões: O artigo compara modelos de Boosting (impulsão) e conclui que o modelo Adaboost tem o melhor desempenho.

Título: Data Selection to Train Machine Learning Models and Forecast Bitcoin Prices: Depth vs. Width [40]

Autores: Dr. Juan M. Dempere, Dr. Zakea Ali El-Agure, Dr. Deni Memic

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário

Modelos de previsão: LINREG e Elastic Net Regression (ENR)

Conjunto de dados: 2 Datasets - um com preços diário, volume e max-min spread de 19 criptomoedas durante 5 anos (2016-2020) e outro com preços diário, volume e max-min spread de 45 criptomoedas durante 3 anos (2018-2020)

Métricas: RMSE, MAE, MAPE, Symmetric MAPE, Theil U1 Coefficient e Theil U2 Coefficient

Melhores resultados: RMSE=7527,3 e 17,161.1 e MAE=6631,8 e 14,604.2 para os modelos com 19 e 45 criptomoedas respetivamente.

Contribuições/conclusões: Dos modelos apresentados no artigo, o ENR tem melhor desempenho que o LINREG, e os modelos que têm mais registos históricos e menos atributos têm melhores resultados do que modelos com menos registos e mais atributos.

Título: Ethereum and Binance Price Forecasting Using Machine Learning [28]

Autores: K.chaitanya kumar, Rajesh.M

Ano: 2022

Criptomoedas: Ethereum e Binance coin

Tipo de Previsão: Preço, mas não refere quais os intervalos

Modelos de previsão: LINREG, SVM, Random Forest, Gradient Boost, Adaboost

Conjunto de dados: Open, high, low, volume, close. 600.000 registos entre 2016 - 2021

Métricas: RMSE e MSE

Melhores resultados: RMSE=0,12 e MSE=0,00

Contribuições/conclusões: O artigo compara vários modelos e conclui que o que tem melhor desempenho é o Random Forest.

Título: Ethereum Price Prediction using Topological Data Analysis [54]

Autores: Samia M. Hafez Mustafa ElNainay, Mohamed Abougabal, Ahmed Kosba

Ano: 2022

Criptomoedas: Ethereum

Tipo de Previsão: Preço da hora, dia e semana seguintes

Modelos de previsão: CNN, TCN, LSTM, GRU e Stacking Ensembles

Conjunto de dados: Number of transactions, Number of unique senders, Number of unique receivers, Number of newly contacted addresses, Transaction value, Smart contracts creations, Number of smart contracts interactions, Number of smart contracts, Number of smart contracts "from" e Smart contract moving funds. Ago 2015 - Ago 2021

Métricas: MAPE

Melhores resultados: MAPE=0,0075, 0,049 e 0,1375 para a previsão da hora, dia e semana seguintes respetivamente.

Contribuições/conclusões: O artigo compara o desempenho dos modelos isolados e combinados e conclui que o melhor modelo é o Ensemble LSTM + GRU

Título: Evaluation of Cryptocurrency coins with Machine Learning algorithms and Blockchain Technology [10]

Autores: Leenata Jaymin Parab, Dr Prashant P Nitnaware

Ano: 2022

Criptomoedas: Bitcoin, XRP, Ethereum, Dogecoin e SHIBA INU

Tipo de Previsão: Preço diário

Modelos de previsão: ARIMA, LSTM

Conjunto de dados: Open, high, low, volume, close. Não indica o período

Métricas: Não apresenta

Melhores resultados: Não apresenta

Contribuições/conclusões: O artigo não apresenta resultados. O objetivo é a disponibilização de uma ferramenta em que o utilizador seleciona a criptomoeda e o sistema carrega o dataset correspondente aos valores históricos da moeda em questão e treina os dois modelos e apresenta as previsões.

Título: Intelligent Decisionmaking System through LSTM Prediction Model and DQN algorithm [18]

Autor: Jiafeng Hu

Ano: 2022

Criptomoedas: Bitcoin, cotação do ouro

Tipo de Previsão: Preço diário

Modelos de previsão: LSTM

Conjunto de dados: Preços diários. 2016 - 2021

Métricas: Não apresenta

Melhores resultados: Não apresenta

Contribuições/conclusões: O artigo apresenta um sistema de apoio à decisão (comprar, segurar e vender) com recurso ao modelo LSTM com DQN Learning Reinforcement.

Título: Investigation of Ethereum Price Trends using Machine learning and Deep Learning Algorithms [31]

Autores: Dronavalli Krishna Tejaswi, Himanshi Chauhan, T. Jaya Lakshmi, Rachakonda Swetha, Nallamothu Navya Sri

Ano: 2022

Criptomoedas: Ethereum

Tipo de Previsão: Preço diário

Modelos de previsão: LSTM, GRU; XGBoost, Random Forest, SVR, KNN

Conjunto de dados: Open, close, High, low, volume, closing adj. price (adjusted to return the value after accounting). Ago 2015 - Dez 2021"

Métricas: RMSE, MAE, MSE e R^2

Melhores resultados: RMSE=253,683, MSE=64355,564, MAE=115,908 e $R^2=0,965$

Contribuições/conclusões: O artigo compara o desempenho de vários modelos e conclui que o modelo LSTM apresentou o melhor desempenho.

Título: Less is More: Bitcoin Volatility Forecast Using Feature Selection and Deep Learning Models [3]

Autores: Haiping Wang, Xin Zhou

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Volatilidade diária

Modelos de previsão: GARCH, Random Forest, SVR, LSTM, DNN, CNN, GRU

Conjunto de dados: 75 variáveis - 2 de de transações, 1 de Google Trend, 9 de Blockshain, 49 variáveis macroeconómicas e 14 indicadores técnicos. Para a volatilidade é usado um dataset com preços a cada 5 minutos. Fev 2015 - Mai 2021

Métricas: MAPE, MAE, MSE e RMSE

Melhores resultados: O modelo com melhor desempenho teve MAPE=0,238013

Contribuições/conclusões: O artigo compara vários modelos, com e sem combinações entre eles e diferentes quantidades de atributos e conclui que o modelo LSTM sem combinações teve o melhor desempenho com o conjunto de atributos mais pequeno.

Título: Parent Coin based Cryptocurrency Price Prediction using Regression Techniques [53]

Autores: Aravindan Jg, Sankara Rama Krishnan

Ano: 2022

Criptomoedas: Litecoin e Dogecoin

Tipo de Previsão: Preço diário

Modelos de previsão: Decision Tree, Random Forest, Extra-Tree-Regressor e Ridge regressor

Conjunto de dados: Bitcoin price, Moving Average. Não refere o período

Métricas: MSE, RMSE, MAE e R^2

Melhores resultados: RMSE=0,008381896 e MAE= 0,003652063 para Litecoin e RMSE=0,008857141 e MAE=0,002486977 para Dogecoin

Contribuições/conclusões: O artigo analisa diferentes modelos explorando a relação das criptomoedas com a “moeda mãe”, a Bitcoin, e conclui que o modelo Random Forest teve melhor desempenho para a Litecoin e o modelo Extra-Tree-Regressor melhor para Dogecoin. Os modelos têm melhor desempenho quando previstos com os atributos da “moeda mãe”.

Título: Predicting Bitcoin Price using Machine Learning [20]

Autores: Ms. Monisha Mittal, Mrs. G. Geetha

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário

Modelos de previsão: GRU

Conjunto de dados: Open, close, high, low e volume. 2014 - 2020

Métricas: RMSE e MAPE

Melhores resultados: RMSE=1987,1057 e MAPE=0,184905

Contribuições/conclusões: Neste artigo só um modelo é testado e não produz comparações.

Título: Predicting Price Movement of the BTCUSDT Pair Using LightGBM Classification Modeling for Cryptocurrency Trading [37]

Autores: Dimitri Mahayana, Shafa Amarsya Madyaratri, Muhanunad Fadhl 'Abbas

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Classificação de sinal e taxa de lucro

Modelos de previsão: Light Gradien Bosting (LGB) e LOGREG

Conjunto de dados: Intervalo de 1 minuto - open, close, high, low, volume, quote asset volume, number of trades. Jan 2021 - Mar 2022

Métricas: Accuracy, precision, Recall e F1-score, Specificity, False Positive Rate e AUC

Melhores resultados: Precision=0,6030, Recall=0,619, F1=0,6111 e Accuracy=0,6011

Contribuições/conclusões: O artigo compara o modelo LGB com o LOGREG e tem melhor desempenho, mas apesar da Accuracy ser superior a 60% a Taxa de Lucro resultante da estratégia (classificação *Buy/Hold*) foi negativa=-1.542%.

Título: Prediction of Cryptocurrency prices using Transformers and Long Short term Neural Networks [48]

Autores: Ayush Tanwar, Vinod Kumar

Ano: 2022

Criptomoedas: Bitcoin, Ethereum e Binance coin

Tipo de Previsão: Preço diário

Modelos de previsão: LSTM, LHB, ChoudharyKnn e LSTM com Transformers

Conjunto de dados: Open, Low, High, Close e Volume. Não revela o período, mas contem 195 registos

Métricas: RMSE

Melhores resultados: Para a Bitcoin apresenta RMSE=367

Contribuições/conclusões: O artigo demonstra que apesar de ser mais pesado em termos de processamento o modelo LSTM + Transformers consegue melhorar ainda mais o LSTM, que por si só já era o melhor modelo.

Título: Prediction of Cryptocurrency using LSTM and XGBoost [63]

Autores: PNRL Chandra Sekhar, M Padmaja, Biswajit Sarangi, Aditya

Ano: 2022

Criptomoedas: Várias

Tipo de Previsão: Preço diário

Modelos de previsão: XGBoost, LSTM

Conjunto de dados: Open, close, high, low, volume, Market Capital. 2018 - 2021

Métricas: MAE e R^2

Melhores resultados: Para XGBoost MAE=0,02396 e $R^2=0,8680$ e para o LSTM MAE=0,1073 e $R^2=0,99$

Contribuições/conclusões: O artigo demonstra que aplicando a configuração EarlyStopping ao modelo LSTM para reduzir o tempo de execução, o MAE é pior comparativamente ao XGBoost, contudo ainda mantém um R^2 superior.

Título: Short term return prediction of cryptocurrency based on XGBoost algorithm [64]

Autores: Jie Wu, Xingchen Guo

Ano: 2022

Criptomoedas: Várias

Tipo de Previsão: Preço ao minuto

Modelos de previsão: XGBoost, Gradient Boosting, SVM e LINREG

Conjunto de dados: Intervalo de 1 Minuto - Count, Open, High, Low, Close, Volume, VWAP e Target

Métricas: Pearson correlation coefficient (Pxy)

Melhores resultados: Pxy=0,0351

Contribuições/conclusões: O artigo demonstra que o modelo XGBoost tem o melhor desempenho quando acrescentando atributos trabalhados, como Close/Open, Close-Open, High-Low, High/Low, valores médios e medianas.

Título: Statistical Scrutiny of the Prediction Capability of Different Time Series Machine Learning Models in Forecasting Bitcoin Prices [14]

Autores: Carl Dinshaw, Reetu Jain, Syed Abou Iltaf Hussain

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário

Modelos de previsão: LSTM ARIMA e SARIMA

Conjunto de dados: Intervalo de 1 hora - Count, Open, High, Low, Close, Volume. Mar 2021 - Jul 2022

Métricas: RMSE, MAPE e R²

Melhores resultados: RMSE=1447,648, MAPE=0,03059 e R²=0,9702

Contribuições/conclusões: O artigo demonstra da comparação feita que o modelo LSTM foi o que teve melhor desempenho.

Título: Multisource financial sentiment analysis for detecting Bitcoin price change indications using deep learning [65]

Autores: Nikolaos Passalis, Loukia Avramelou, Solon Seficha, Avraam Tsantekidis, Stavros Doropoulos, Giorgos Makris, Anastasios Tefas

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Taxas de lucro diária

Modelos de previsão: MLP, CNN e RNN

Conjunto de dados: 200,000 títulos de artigos financeiros de diferentes fontes e o preço diário, 2015 - 2020

Métricas: Accuracy e F1 score

Melhores resultados: Para a classificação não supervisionada dos sentimentos teve Accuracy=0,68 e F1=0,60 e para o desempenho total teve Accuracy=0,92 e F1=0,92

Contribuições/conclusões: Este artigo demonstra que só o uso de atributos de análise de sentimento tem melhor desempenho do que baseado só no preço ou até na combinação dos dois. O modelo com melhor desempenho é o CNN.

Título: Forecasting directional bitcoin price returns using aspect-based sentiment analysis on online text data [66]

Autores: Ekaterina Loginova, Wai Kit Tsang, Guus van Heijningen, Louis-Philippe Kerkhove, Dries F. Benoit

Ano: 2021

Criptomoedas: Bitcoin

Tipo de Previsão: Classificação de sinal ao dia

Modelos de previsão: Naive Bayes, LOGREG, SVM, Random Forestm LSTM, MLP

Conjunto de dados: Open, High, Low, Close, textos extraídos de Reddit, Bitcointalk e CryptoCompare Fev 2017 - Abr 2019

Métricas: ROC AUC

Melhores resultados: AUC=0.58

Contribuições/conclusões: O artigo analisa quais os melhores modelos para análise de sentimento e quais os atributos que permitem o melhor desempenho e conclui que o melhor desempenho foi obtido com a base de dados do Bitcointalk e com o modelo de análise de sentimento Topic JST (Joint/Sentiment Topic). O modelo com melhor desempenho na previsão foi o MLP.

Título: Cryptocurrency Price Prediction using Long Short-Term Memory and Twitter Sentiment Analysis [5]

Autores: Muhammad Husaini Bin Mohd Sabri, AmgadMuneer, Shakirah Mohd Taib

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário

Modelos de previsão: LSTM

Conjunto de dados: Dados do Twitter e preços diários. Jan 2021 - Nov 2021

Métricas: Accuracy

Melhores resultados: Accuracy=94,35%,

Contribuições/conclusões: Neste artigo , os dados do twiter são processados em termos de percentagem de afetação do preço, para prever o valor do preço.

Título: Cryptocurrency Price Prediction using Social Media Sentiment Analysis [67]

Autores: Sotirios Oikonomopoulos, Katerina Tzafilkou, Dimitrios Karapiperis, Vassilios Verykios

Ano: 2022

Criptomoedas: Top 7

Tipo de Previsão: Taxas de lucro a 12 horas

Modelos de previsão: Vector Autoregression

Conjunto de dados: Dados do Twitter (14.659.664 de registos) e preços diários. Set 2021 - Nov 2021

Métricas: Accuracy, MAPE, Mean Error, MAE, Mean Percentage Error, RMSE, Correlation e Min-Max Error

Melhores resultados: Accuracy=99,62%, MAPE=0,0038, MAE=16,4771 e RMSE=26,6533

Contribuições/conclusões: No artigo só são revelados os resultados atingidos para Ethereum e Polkadot sendo que a que teve melhores resultados foi a primeira.

Título: DL-GuesS: Deep Learning and Sentiment Analysis-Based Cryptocurrency Price Prediction [68]

Autores: Raj Parekh, Nisarg P. Patel, Nihar Thakkar

Ano: 2022

Criptomoedas: Dash e Bitcoin-Cash

Tipo de Previsão: Preço diário até 30 dias

Modelos de previsão: LSTM+GRU e VADER para análise sentimental

Conjunto de dados: Tweets sobre Dash Bitcoin-Cash, Litecoin, e Bitcoin, e o preço diário de cada moeda. Dez 2020 - Abr 2021

Métricas: MSE, MAE e MAPE

Melhores resultados: MSE=0,0185, MAE=0,0805 e MAPE=4,7928

Contribuições/conclusões: O artigo apresenta um modelo híbrido, que usa não só a análise de sentimentos sobre as moedas em questão, como também a interdependência entre as moedas principais e a moeda em previsão. O modelo híbrido tem melhor desempenho que os dois modelos usados separadamente.

Título: Prediction of Cryptocurrency Price using Machine Learning Techniques and Public Sentiment Analysis [47]

Autores: Mehedi Hasan Mishal, Nura Jannat Rakhi, Fahmida Rashid

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário

Modelos de previsão: SVR) Facebook Prophet, ARIMA, LSTM e XGBoost

Conjunto de dados: Intervalo de 1 hora - dados do Twitter e preços. 2016 - 2022

Métricas: RMSE

Melhores resultados: RMSE=6720,140

Contribuições/conclusões: O artigo apresenta uma comparação dos modelos e o LSTM foi o que teve melhor desempenho.

Título: Price Prediction of Bitcoin using Social Media Activities and Past Trends [52]

Autores: Krishna Pal Sharina,

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário até um mês

Modelos de previsão: ANN, LSTM, GRU, ARIMA, RF, SVM

Conjunto de dados: Intervalo de 1 hora - preços, notícias e dados do Twitter. 2015 - 2019

Métricas: RMSE

Melhores resultados: RMSE=271

Contribuições/conclusões: Neste artigo o modelo LSTM combinado com GRU teve o melhor desempenho, e é melhor só usando dados do Twitter do que combinado com os dados de notícias. O modelo ARIMA tem um bom desempenho para o valor do dia seguinte, mas o desempenho cai drasticamente quando se expande o horizonte de previsão.

Título: Twitter Mining based Forecasting of Cryptocurrency using Sentimental Analysis of Tweets [41]

Autores: Uroosa Maqsood, Faheem Yar Khuhawar, Shahnawaz Talpur

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Open, Close, High, Low diários

Modelos de previsão: RNN, GRU, Convolution 1D, e LSTM

Conjunto de dados: Intervalo de 1 Segundo - Compound Score, Count Negative, Count Neutral, Count Positive, Sentimental Negative, Sentimental Positive do Twitter e Open, Close, High, Low, Volume. Não especifica o período

Métricas: MAE, Mean Absolute, Scaled Error, MAPE e MSE

Melhores resultados: MAE=0,003, MAPE=2,42 e MSE=1,1423 para previsões a um dia, e MAE=0,0022, MAPE=1,433 e MSE=1,4122 para previsão a 10 dias

Contribuições/conclusões: No artigo, o modelo LSTM apresenta o melhor desempenho e mantém o desempenho mesmo aumentando o horizonte temporal de previsão.

Título: Using Transformers and Deep Learning with Stance Detection to Forecast Cryptocurrency Price Movement [51]

Autores: Yeonwoo Son, Soham Vohra, Rohit Vakkalagadda

Ano: 2022

Criptomoedas: Bitcoin

Tipo de Previsão: Preço diário

Modelos de previsão: LSTM

Conjunto de dados: Dados do Twitter com posição -1, 0 e 1 relativamente à Bitcoin. e Preço. Jan 2018 - Jul 2022

Métricas: MAE

Melhores resultados: MAE=1144\$ a 5 dias sendo que o valor chegou aos 60.000\$, equivale a um MAE aproximadamente de 0,019

Contribuições/conclusões: o artigo demonstra que aplicando os modelos de transformação do texto FinBERT e RoBERTa, refinado com Ensembled Logistic Regression para aplicação do modelo previsional LSTM o modelo conseguiu um bom desempenho, mesmo até 6 meses de previsão.