

## Análise do câmbio de criptomoedas através do uso de inteligência artificial

Gustavo M. Penna<sup>†</sup>, Ricardo M. Salgado

*Departamento de Ciência da Computação (DCC), Instituto de Ciências Exatas (ICEx), Universidade Federal de Alfenas (UNIFAL-MG).*

**Resumo:** O mercado de câmbio de criptomoedas é onde é possível comprar e vender criptomoedas como Bitcoin e Ethereum, e onde as pessoas tentam ganhar dinheiro com a diferença de preço entre compra e venda, mas tentar prever o valor futuro de uma moeda é difícil, e precisa de uma forte análise matemática de mercado para se aproximar do valor real. Assim, o objetivo deste artigo é usar o modelo de Deep Learning, LSTM (Long short term memory), juntamente com técnicas de manipulação de dados como análise exploratória de dados para prever o preço e a tendência do Bitcoin, fornecendo um modelo confiável que pode ser usado para ajudar os traders a tomarem decisões sobre se eles devem comprar uma criptomoeda, visando lucro. Também foram feitas validações de compatibilidade com outros estudos prévios usando técnicas e modelos como Convolutional Neural Networks (CNN) e Recurrent Neural Networks (RNN).

**Palavras-chave:** Inteligência artificial; LSTM; Bitcoin; mercado financeiro; criptomoeda.

## Cryptocurrency exchange analysis through the use of artificial intelligence

**Abstract:** The cryptocurrency exchange market is where it's possible to buy and sell cryptocurrency like Bitcoin and Ethereum, and where people try to earn money through the price difference between buying and selling, but trying to predict the future value of a currency is hard, and needs a strong mathematical analysis on the market to get close to the real value. Thus, this paper's objective is to use the LSTM (Long short term memory) Deep Learning model, together with techniques of data manipulation like exploratory data analysis, to predict the Bitcoin price and tendency, providing a reliable model that can be used to help traders make decisions on whether or not they should buy a cryptocurrency, aiming at profit. Compatibility validations were made with previous studies using techniques and models such as Convolutional Neural Networks (CNN) and Recurrent Neural Networks (RNN).

**Keywords:** Artificial intelligence; LSTM; Bitcoin; stock market; cryptocurrency.

### Introdução

Segundo o Estadão, o mercado financeiro movimenta trilhões de dólares todos os anos (ANDRADE, 2021), e muitas tecnologias que o afetam também possuem grande demanda e envolvem grandes quantidades de dinheiro, é um campo que possui constantes inovações e automatizações, e a explosão do uso da inteligência artificial se inclui nisso (ECONOMIA.IG, 2022). O setor financeiro sempre busca usar tecnologias de ponta (DIAS PAIVA; MAGDA DA SILVA ROMA, 2014), e com a concretização do uso de algoritmos de inteligência artificial fora do ambiente de pesquisa, rapidamente foi descoberta sua utilização no mercado financeiro, possibilitando o desenvolvimento de estratégias de negociação mais eficientes e seguras (PIOTROSKI, 2000).

Não apenas foi concebido o uso de algoritmos de inteligência artificial nessa área, como também foram inovados, passando a utilizar novos algoritmos e modelos como o *Deep Learning* através das CNNs (*Convolutional Neural Networks*) (HOSEINZADE; HARATIZADEH, 2019; SELVIN et al., 2017), técnicas de extração de variáveis como as RBMs (*Restricted Boltzmann Machines*) (LIANG et al., 2017), modelos capazes de trabalhar com conjuntos de dados temporais (em que os dados são correlacionados através do tempo) como as RNNs (*Recurrent Neural Networks*) (SELVIN et al., 2017; MCNALLY; ROCHE; CATON, 2018), consequentes melhorias como a LSTM (*Long short-term memory*) (SELVIN et al., 2017; PAIVA; ROMA, 2014; MCNALLY; ROCHE; CATON, 2018), e também modelos que fazem tanto o uso dos dados estatísticos quanto de dados textuais de notícias, providas de jornais (AKITA, 2016).

---

<sup>†</sup> Autor correspondente: [gustavo.penna@sou.unifal-mg.edu.br](mailto:gustavo.penna@sou.unifal-mg.edu.br).

Logo, a área está em constante evolução, e aperfeiçoamentos são sempre buscados pelas empresas que atuam no ramo, investindo milhões por ano em pesquisa e desenvolvimento para buscar avanços tecnológicos e obter o maior lucro em relação aos concorrentes (SOARES, 2021). Devido à importância dessas inovações, as mesmas quase sempre são mantidas em sigilo empresarial, dificultando para que sejam estudadas no ambiente acadêmico e por pesquisadores independentes, e conseqüentemente dificultando sua aplicação por pessoas ou fundos que desejam investir no mercado financeiro ou analisá-lo através das tecnologias disponíveis.

Muitos trabalhos relacionados já foram realizados, usando diferentes técnicas e formatos de análise, como modelos avançados baseados nos dados estatísticos como o ARMA (*Autoregressive-moving average*) (MARWALA, 2014) e ARIMA (*Autoregressive integrated moving average*) (SELVIN et al., 2017), além dos próprios modelos de aprendizado de máquina. Tais algoritmos apresentam resultados diversos, porém é constatado que a maioria possui resultados muito bons (define-se mais de 50% de acerto como lucro), como a previsão estatística usando CNN que possui apenas 4,89% de erro médio (SELVIN et al., 2017). A previsão por texto usando *Paragraph Vector* também conseguiu ótimos resultados, com lucro de aproximadamente 12.119.000 *yens*, cerca de \$92.380 na conversão atual, quase o triplo em comparação com modelos de análise numérica, que lucraram 4.308.000 *yens*, cerca de \$32.839 (AKITA, 2016).

Assim, hipóteses anteriores como a do mercado eficiente (FAMA, 1970), suposta em 1970, que afirma que é impossível prever preços, já foram refutadas (MALKIEL, 2005), pois na época não foi levado em conta a capacidade de previsão de algoritmos de inteligência artificial, visto que o poder computacional era muito menor, e o conceito de *Algorithmic Trading* (negociações feitas com o auxílio de algoritmos) acabara de dar seus primeiros passos (MCGOWAN, 2009).

Além dos modelos para previsão de valores, também é possível o desenvolvimento de simulações do mercado financeiro, onde é possível testar os modelos para validar métricas de desempenho (SHUANG; ZHANG, 2011; WANG; FANG; ZHUANG, 2009). Previsões focadas especificamente no preço do *Bitcoin* também foram realizadas, usando LSTM, RNN e ARIMA, Com RMSE (*Root mean squared error*, desvio médio quadrático do erro) de 6,87%, 5,45% e 53,74%, respectivamente (MCNALLY; ROCHE; CATON, 2018); BNNs (*Bayesian neural networks*) (JANG; LEE, 2017) com RMSE de 0,0256 e SVR (*Support vector regression*) (MARWALA, 2014) com RMSE de 0,0179. Diferente do mercado financeiro, para a previsão de valores de criptomoedas não há dados de empresas para uso, então deve-se usar dados numéricos como preços de abertura e fechamento, volume e quantidade de operações, e dados da própria *blockchain* (sistema de rede em que funciona o *Bitcoin*) como dificuldade de mineração e taxa de *hash* (MCNALLY; ROCHE; CATON, 2018).

Os resultados da previsão de *Bitcoin* também são muito variáveis, não dependendo apenas dos algoritmos usados, mas também do conjunto de dados usados e da época, visto que a capitalização do *Bitcoin* alterou drasticamente numa medida de poucos anos, principalmente entre 2013 e 2017 (BAUR, 2017). De acordo com McNally et al. (2018), a média de acurácia da previsão do preço do *Bitcoin* usando LSTM é próxima de 52%, de RNN 50% e de ARIMA também 50%, utilizando dados entre 2013 e 2016. De acordo com Jang et al. (2017), o RMSE da regressão linear chegou a aproximadamente 9%, a BNN teve aproximadamente 0,5% e o SVR 14%, usando dados de 2011 até 2017.

Outras abordagens já foram realizadas para tentativa de previsão do valor, como a geração de imagens de *candlesticks* (representações de dados em intervalos de tempo) para previsão visual, utilizando ações da Petrobras de 2001 até 2016, com acurácia de 73% (PAIVA; ROMA, 2014); e o uso de indicadores macroeconômicos externos, junto dos dados de vários mercados financeiros do mundo e conseguindo acurácias de mais de 70% usando modelos como o GARCH (*Generalized autoregressive conditional heteroskedasticity*) (MACIEL; BALLINI, 2010). Dessa forma, este estudo tem o intuito de realizar uma previsão relativamente precisa do preço do *Bitcoin* após determinado período de tempo, aplicando operações de manipulação dos dados históricos, e modelos de inteligência artificial capazes de interpretar séries temporais.

O conteúdo deste trabalho encontra-se organizado da seguinte forma: na Seção II são apresentados alguns conceitos sobre previsão de vazões, na Seção III é abordada a metodologia utilizada para realizar os experimentos, já na Seção IV é feita uma discussão sobre os dados utilizados para alimentar o modelo, na Seção V são mostrados os resultados obtidos e finalmente na Seção VI são feitas as considerações finais do trabalho.

## Fundamentação teórica

Para prever o valor de uma moeda ou ação, é necessário avaliar seu comportamento passado, comparando as tendências de alta e de baixa, estabilidade, e como a variação do seu valor no último intervalo de tempo predefinido afeta o valor final. É possível realizar medidas estatísticas para comparar médias, medianas e modas num intervalo de tempo, porém tais operações são muito superficiais comparadas com as aplicabilidades da inteligência artificial (MARWALA, 2014), que pode ser aproveitada através de algoritmos de *Deep Learning* como o LSTM, que é especializado em conjuntos de dados que envolvem sequências temporais.

Além de modelos para realizar a predição de um valor, é possível usar *Autoencoders* (DIAS PAIVA; MAGDA DA SILVA ROMA, 2014) para extrair variáveis e PCAs (*Principal Component Analysis*) para reduzir a dimensionalidade, otimizando ainda mais o conjunto de dados (WAQAR et al., 2017). Assim, visto que o problema da predição de valor do *Bitcoin* é temporal, foi escolhida a arquitetura LSTM. Essa arquitetura possui um “estado escondido” adicional, que é repassado junto de cada elemento do conjunto de dados, assim, o modelo possui uma entrada que serve como “memória” do que foi visto anteriormente, sendo ideal para problemas temporais.

## Metodologia proposta

Nesta seção, serão explicados o conjunto de dados do problema e os métodos utilizados para tratar dados, processá-los, treinar modelos e realizar previsões. Todas as operações foram realizadas em um computador usando um processador *AMD Ryzen 5 3400* e *16GB* de *RAM*, e os scripts foram programados na linguagem *Python*, usando modelos da biblioteca *Keras*.

### A. Conjunto de dados

O conjunto de dados usados neste trabalho é o histórico de informações dos *candlesticks* do *Bitcoin* em relação ao dólar (BTC/USDT). Também chamados de “velas” ou “*candles*”, são representações de variáveis do mercado financeiro em intervalos de tempo. Cada *candlestick* pode ter um tempo variado entre 1 minuto até 1 mês, e armazena os dados como preço de início, preço final, volume de transações, entre outros, nesse período de tempo. Para o melhor equilíbrio entre precisão dos dados e tamanho da base de dados, foi usado o intervalo de 5 minutos para cada *candlestick*. Tal intervalo foi decidido pensando num período que não é afetado por grandes alterações nas tendências de alta e baixa, focando no curto prazo e sem precisar se preocupar nas tendências a longo prazo. As informações de cada *candlestick* desse conjunto de dados estão representadas na Tabela 1.

Tabela 1. Descrição das variáveis do conjunto de dados

<i>Variável</i>	<i>Definição</i>
<i>Open time</i>	Horário de abertura.
<i>Open</i>	Valor de abertura.
<i>High</i>	Valor máximo no intervalo.
<i>Low</i>	Valor mínimo no intervalo.
<i>Close</i>	Valor de fechamento.
<i>Close time</i>	Horário de fechamento.
<i>Quote asset volume</i>	Volume da moeda vendida (USDT).
<i>Number of trades</i>	Quantidade de trocas realizadas.
<i>Taker buy base asset volume</i>	Volume de ordens da moeda comprada (BTC).
<i>Taker buy quote asset volume</i>	Volume de ordens da moeda vendida (USDT).

Fonte: Documentação da API da Binance (BINANCE, 2021)

Como objetivo da previsão, foi definido o valor de fechamento da *candle* (coluna Close), visto que, ao conseguir os dados básicos na abertura, pode-se prever seu valor final e decidir se a compra deve ser feita ou não. Quando não é possível obter valores como o máximo ou mínimo, usa-se o valor da *candle* anterior, visto que é a mais próxima da atual.

As variáveis da Tabela 1 são as *features* (propriedades ou características mensuráveis) bases do conjunto de dados, essas serão manipuladas na análise exploratória de dados para ficarem mais adequadas para o modelo de inteligência artificial.

Os dados usados foram coletados de 31 de dezembro de 2020, até 31 de dezembro de 2021, em intervalos de 5 minutos, usando a *API* (*Application Programming Interface*) da corretora *Binance* (BINANCE, 2021), seu uso é gratuito e pode ser feito por qualquer pessoa com uma conta registrada. No conjunto de dados coletado existem 104.924 (cento e quatro mil novecentos e vinte quatro) *candles* disponíveis, ou seja, medições para serem estudadas e processadas. A Figura 1 representa um gráfico dessas *candles*, limitadas do dia 1 de janeiro de 2021 até 31 de janeiro de 2021, como exemplo. Neste gráfico, as *candles* verdes indicam valorização durante aquele período de tempo, e as vermelhas indicam desvalorização.


Figura 1. Candlesticks do Bitcoin no mês de janeiro de 2021



Fonte: Dos autores.

## B. Etapas de processamento

O modelo proposto possui 3 etapas. A primeira etapa é a análise exploratória de dados (EDA), onde será feito um estudo dos dados disponíveis e manipulações para gerar mais informações relevantes. A segunda etapa é o treinamento dos modelos de inteligência artificial, em que os dados disponíveis serão separados em um conjunto de treino e outro de testes, e o conjunto de treino será alimentado ao modelo. Na terceira etapa é realizada a previsão dos dados de testes e validação dos resultados obtidos, usando métricas como RMSE, MAPE e MAE, além de verificar se a operação prevista pelo modelo resultaria em lucro ou prejuízo. A Figura 2 representa as etapas do modelo, juntamente com a aquisição de dados, que já foi citada.



Fonte: Dos autores.

### C. Análise exploratória de dados

Para aplicar a *EDA* nos dados no modelo, é necessário estudá-los, formatá-los corretamente, remover variáveis que não serão utilizadas bem como criar novas variáveis que podem ser úteis. Devido à natureza estatística dessa base, é evidente a possibilidade de gerar novos dados com operações matemáticas simples, como a média de valores entre determinados intervalos de tempo, ou a diferença entre valores para cada entrada. Essas são úteis pois provêm mais informações para serem processadas pela IA, que se forem geradas de forma correta, aumentam sua performance.

Para o problema, novas *features* adicionais foram geradas, como a *RSI* (*Relative Strength Index*) e *ADX* (*Average Directional Index*), que são indicadores usados no mercado financeiro para análise técnica e auxílio da tomada de decisão, assim, são variáveis que podem melhorar consideravelmente a acurácia do modelo:

#### 1) *RSI* (fórmula 1)

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

$$RS = \frac{Mxa}{Mxb}$$

Onde *Mxa* é a média entre as últimas 14 altas e *Mxb* a média entre as últimas 14 baixas.

#### 2) *ADX* (fórmula 2)

$$ADX = MMA(DX, 14) \quad (2)$$

$$DX = \left( \frac{|DP - DN|}{|DP + DN|} \right) \times 100$$

onde *MMA* é a média móvel aritmética, *DP* é o índice direcional positivo e *DN* é o índice direcional negativo. O *ADX* também foi calculado usando os últimos 14 valores.

Além disso, foi formatado o *timestamp* (carimbo de tempo) de abertura para uma data no formato YYYY-MM-DD H:M:S, que é usada como índice para o modelo, para melhor visualização. Por fim, foi calculado o preço médio da *candle* (fórmula 3), e criada uma variável booleana “Deve comprar” que considera se a compra na abertura deveria ter sido efetuada, levando em consideração se o preço de fechamento é maior que o preço de abertura.

$$Média = \frac{Preço\ mais\ alto + Preço\ mais\ baixo}{2} \quad (3)$$

Ao final, obteve-se o conjunto de dados demonstrado na Tabela 2. As propriedades desses dados estão mais bem representadas na análise descritiva da Tabela 3, exibindo a média, mínima, máxima e variação dos principais valores.

Após a geração dessas novas *features* artificiais, é necessário formatar os dados para inserção no modelo. Para isso, primeiro é realizada a separação entre dados de treino e teste, nesse problema foi feita a separação de 67% dos dados para treino (Contemplando do dia 31 de dezembro de 2020 até 2 de setembro de

2021) e 33% restantes para testes (de 2 de setembro de 2021 até 31 de dezembro de 2021), dessa forma garante-se que o modelo irá ser avaliado com base em dados não vistos anteriormente.

Tabela 2. Conjunto de dados após análise exploratória

<i>Data (A-M-D H:M)</i>	31/12/2020 21:00	31/12/2020 21:05	...	31/12/2021 20:55	31/12/2021 21:00
<i>Horário de abertura (Timestamp)</i>	1609459200000	1609459500000	...	1640994900000	1640995200000
<i>Valor de abertura</i>	28923,63	28975,65	...	46285,79	46216,93
<i>Valor mais alto</i>	29017,5	28979,53	...	46285,8	46391,49
<i>Valor mais baixo</i>	28913,12	28846,28	...	46132,04	46208,37
<i>Valor de fechamento</i>	28975,65	28858,94	...	46216,93	46321,34
<i>Volume</i>	182,89	214,57	...	145,02	185,68
<i>Horário de fechamento</i>	1609459499999	1609459799999	...	1640995199999	1640995499999
<i>Volume da moeda vendida</i>	5300787	6201532	...	6703859	8598314
<i>Quantidade trocas realizadas</i>	5614	4928	...	3870	4551
<i>Volume de ordens da moeda comprada</i>	80,03	113,76	...	77,52	106,55
<i>Volume de ordens da moeda vendida</i>	2319247	3287213	...	3584387	4933083
<i>RSI</i>	1	1	...	42,59	48,94
<i>ADX</i>	1	1	...	30,93	29,25
<i>Deve comprar</i>	1	0	...	0	1
<i>Valor médio</i>	28965,31	28912,9	...	46208,92	46299,93

Fonte: Dos autores.


Vale ressaltar que por ser um problema temporal, não é possível usar técnicas de validação cruzada, visto que os dados devem ser treinados e testados em ordem, dada a natureza dos modelos *LSTM*. Os dados também são separados em dois conjuntos, sendo um as variáveis usadas para treino, e o outro a variável que deve ser prevista, no caso, a coluna *Close*, que representa o valor de fechamento da *candle*, essa está representada na Figura 3.

Tabela 3. Análise descritiva de alguns dados do conjunto

	<i>Valor mais alto</i>	<i>Valor mais baixo</i>	<i>Valor de fechamento</i>	<i>Valor de abertura</i>
Média	47442,07	47271,4	47357,35	47357,19
Mínima	28846,46	28130	28752,8	28752,8
Máxima	69000	68681	68734,26	68734,26
Variação	9822,4	9820,39	9821,77	9821,9

Fonte: Dos autores.

Figura 3. Valores que tentarão ser previstos (valor de fechamento x data).



Fonte: Dos autores.

Em sequência, é feita a normalização dos dados, usando as fórmulas de *MinMax* (fórmula 4) e *Standard Score* (fórmula 5), formatando os valores para o intervalo entre 0 e 1 para diminuir as discrepâncias entre valores, de forma que valores muito altos ou muito baixos ainda serão contabilizados corretamente.

$$x' = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (4)$$

$$x' = \frac{x - \text{media}(x)}{\text{std}(x)} \quad (5)$$

onde X é um valor, dentro do conjunto de valores, à ser normalizado.


#### D. Treinamento dos modelos

O modelo desse problema foi instanciado com uma camada de entrada de *LSTM* com 13 neurônios, uma camada oculta linear de 128 neurônios, e uma camada de saída linear com 1 classe de retorno (pois é um problema de regressão). Como função de ativação entre camadas, foi usada a *ReLU (Rectified Linear Unit)*, para capturar melhor a interação entre as variáveis. Após o instanciamento, foi feita a parametrização e inserção de demais filtros desejados, definindo o número de épocas para treino como 1000, a taxa de aprendizado para 0,001, e os critérios para cálculo de perda e otimização como o *Adam* e *L1 (Least absolute deviations)*.

Com o modelo e os dados prontos, foi realizada a iteração pela quantidade de épocas, em cada época são passados os tensores de treino pela rede neural, feita a otimização dos pesos, e então calculado o erro com base nos tensores de teste. Antes de cada iteração é guardado o dicionário de estados do modelo, que contém os pesos e equações dos neurônios, dessa forma, na próxima iteração, pode-se recarregar o estado anterior caso o treino atual cause uma queda na porcentagem de acerto, garantindo que os treinos irão apenas causar um aumento na acurácia, e não diminuição. Ao final do treino, também é guardado esse dicionário de estados do modelo, possibilitando carregar o modelo já treinado para prever dados futuros ou para treiná-lo novamente.

A Figura 4 demonstra o gráfico dos valores previstos no treino comparados com os valores reais, pode-se notar que nas mudanças pequenas o modelo foi capaz de prever com precisão, mas não teve uma performance tão boa nas mudanças bruscas de valor.

Figura 4. Predições do treino (valor de fechamento x data).



Fonte: Dos autores.

### E. Previsão

Com o modelo treinado, basta executá-lo novamente, mas dessa vez em dados novos ao invés dos dados de treino, operação chamada de previsão. Dessa forma, é possível verificar a acurácia do modelo como se estivesse prevendo dados do mundo real, visto que os dados de teste são desconhecidos pelo modelo no treino. Ao final da previsão, são aplicadas diversas métricas de acurácia para calcular os resultados do modelo, são usadas as métricas *RMSE*, *MAPE* (*Mean absolute percentage error*, porcentagem de erro médio absoluto) e *MAE* (*Mean absolute error*, erro médio absoluto), essas métricas foram escolhidas pois são as mais indicadas para calcular o erro em problemas de regressão.

Os dados usados para a previsão foram do dia 31 de dezembro de 2021, onde acaba o conjunto de teste do treino, até o dia 19 de janeiro de 2022, com um total de 5473 *candles* para previsão. Todos dados também passaram pelo processo de *EDA*, pois necessitam estar na mesma estrutura dos dados de treino para serem corretamente processados pelo modelo.

### Resultados


Com os dados obtidos na etapa de previsão, foi possível verificar os resultados do modelo num ambiente simulando o mundo real, com dados nunca vistos antes tanto no treino quanto no teste. A figura 5 demonstra o gráfico dos valores previstos comparados com os valores reais, as séries praticamente se sobrepõem, indicando um alto ajuste da previsão com os dados reais, não sempre prevendo o preço exato, mas conseguindo prever as tendências de alta e baixa.

Como é possível observar, o modelo foi capaz de acompanhar as diversas tendências desse período. Ao final do ano de 2021, houve uma grande queda no preço do *Bitcoin*, devido às preocupações com as novas variantes do *Covid-19* e com os bloqueios de viagens. Assim, vários fundos que usam criptomoedas para combater a inflação decidiram vendê-las para continuarem com lucro mesmo com baixa na economia, e com o aumento na oferta da moeda veio a baixa do preço (HOLLAND, 2022).

Aliado ao surgimento de novas *altcoins* (moedas alternativas) e com o aumento da inflação, principalmente na economia norte-americana, criou-se um período de alta volatilidade (alta frequência de oscilação) do valor das criptomoedas, causando as quedas e altas que podem ser visualizadas no gráfico (HAJRIC, 2022).



Figura 5. Predições da classificação (valor de fechamento x data).




Fonte: Dos autores.

Como exemplo, pode-se citar a queda de 05/01/2022 de 1,05%, causada principalmente pela reação às decisões econômicas do governo norte-americano, e a queda de 10/01/2022 de 1,04%, acompanhando a baixa do mercado de ações *Nasdaq* e a inflação (PONCIANO, 2022).

Na Figura 6, é possível ver com mais detalhes o comportamento do modelo na queda do dia 05/01/2022, que apesar de não conseguir prever os valores com exatidão, identifica corretamente as tendências. Essa identificação pode ser explicada através da queda acentuada às 16:40h, que primeiramente não havia sido identificada, mas após o uso dessa informação na próxima iteração, o modelo notou que deveria continuar em queda, e só parou após a estabilização às 17:15h. O mesmo ocorreu na queda das 19:30h, onde o modelo previu que haveria uma estabilização, mas depois de notar a queda da *candle* anterior, seguiu a tendência de queda.

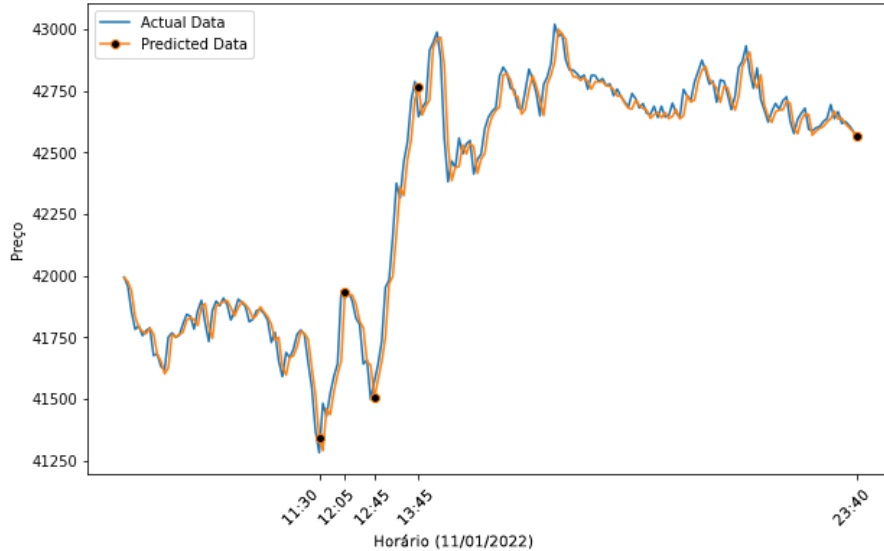
Figura 6. Predições da classificação, focado na queda do dia 05/01/2022 (valor de fechamento x data).



Fonte: Dos autores.

O mesmo pode ser observado na Figura 7, em que as tendências de alta das 12:05h e 13:45h foram identificadas após a primeira *candle* de alta, e só estabilizaram após a próxima *candle* fechar com valor sem crescimento acentuado.

Figura 7. Predições da classificação, focado na queda do dia 05/01/2022 (valor de fechamento x data).



Fonte: Dos autores.

Como citado anteriormente, a validação cruzada não é possível, dada a natureza dos modelos LSTM, em que os dados devem ser treinados e previstos em ordem temporal. Logo, para uso real do modelo, é necessário principalmente validar se o valor previsto é maior ou menor que o valor inicial, pois isso é o que define se uma compra resultaria em perda ou ganho. Assim, é realizada essa validação, verificando se a operação realizada pelo modelo resultou em lucro, e calculada uma taxa de acerto, que foi definida como “Acerto para valor maior ou menor”, explícito na tabela 4. Na Tabela 4, também são exibidos os erros calculados usando as diversas métricas citadas anteriormente.

Tabela 4. Resultado da validação do modelo

<i>Métrica</i>	<i>Valor</i>
Acerto para valor maior ou menor	78,82%
RMSE	0,013
MAPE	0,0109
MAE	6,8863

Fonte: Dos autores.

Assim, pode-se notar que o modelo possui uma boa performance, capaz de prever com certa acurácia os futuros valores de fechamento das velas, além de, em aproximadamente 78% das vezes, conseguir prever se o valor de fechamento será maior ou menor do que o de abertura.

## Conclusão

Este trabalho apresentou uma proposta de modelo de inteligência artificial capaz de prever com certa precisão o valor de criptomoedas, focando na propriedade temporal dos elementos do mercado financeiro. Observou-se que o modelo proposto usando *LSTM* é compatível com outros modelos como *ARIMA* e *CNN*, com seu melhor resultado na predição da alta ou baixa dos preços. A grande quantidade de dados, assim como um bom ajuste na parametrização, mostrou que o modelo também foi compatível com a performance dos

modelos de outros trabalhos como Selvin et al. (2017) e McNally et al. (2018), uma comparação direta não é possível visto que os conjuntos de dados são diferentes e relativos à outros períodos. Com os resultados obtidos neste estudo, percebe-se que é possível criar um *software* para auxílio na tomada de decisões, que também pode ser utilizado no escopo de diversas criptomoedas, além do *Bitcoin*, mas para melhor confiança deve ser acompanhada de outros modelos tomadores de decisão como definição de riscos e definição dos preços de compra e venda (ALEXANDRE MACEDO et al., 2013).

Através desse projeto, foi possível concluir que, com o uso de algoritmos de inteligência artificial é possível prever valores com elevada precisão, sem depender de sistemas caros e potentes ou análises estatísticas complexas, de forma que qualquer pessoa pode conseguir prever as tendências de preço.

Para continuidade deste trabalho, pode-se considerar a criação de *ensembles* de vários modelos diferentes, uma análise mais profunda das *features* e da análise exploratória de dados, além de hiperparametrização do modelo.

## Referências

AKITA, Ryo. Deep learning for stock prediction using numerical and textual information. **2016 IEEE/ACIS 15th ICIS**, , p. 1–6, 2016.

ALEXANDRE MACEDO, Jose; THEODORO OLIVEIRA CAMARGO, Luis; CESAR BRANDAO DE OLIVEIRA, Humberto; EDUARDO DA SILVA, Luiz; MENEZES SALGADO, Ricardo. An intelligent decision support system to investment in the stock market. *IEEE Latin America Transactions*, vol. 11, no. 2, p. 812–819, 2013. <https://doi.org/10.1109/TLA.2013.6533971>.

ANDRADE, Jenne. B3 bate recorde e movimentada R\$26 bilhões por dia em 2020. *eInvestidor.estadao*, 2021. Disponível em: <https://investidor.estadao.com.br/investimentos/b3-recorde-26-bilhoes-dia>. Acesso em: 23-mar-2022.

*BINANCE*, Official documentation for the Binance APIs and streams. Disponível em: <https://github.com/binance/binance-spot-api-docs/blob/master/rest-api.md>>. Acesso em: 01-Abr-2021.

BAUR, Dirk G., and Thomas Dimpfl. "Realized bitcoin volatility.", 2017. *SSRN* 2949754 (2017): 1-26.

ECONOMIA.IG, Conheça 5 tendências tecnológicas que impulsionam o mercado financeiro (2021). Disponível em: <https://economia.ig.com.br/1bilhao/2021-10-28/conheca-5-tendencias-tecnologicas-que-impulsionam-o-mercado-financieiro.html>. Acesso em: 24-mar-2022.

PAIVA, Felipe Dias; ROMA, Carolina Magda da Silva. Métodos de *deep learning* aplicados a *candlestick* como estratégia de investimento. 2014.

FAMA, Eugene F. Session Topic: Stock market price behavior session chairman: Burton G. Malkiel efficient capital markets: A review of theory and empirical work. **The Journal of Finance**, vol. 25, no. 2, p. 383–417, 1970.

HAJRIC, Vildana. Bitcoin Declines to Lowest Level Since December's Flash Crash. *Bloomberg*, 2022. Disponível em: <https://www.bloomberg.com/news/articles/2022-01-05/bitcoin-declines-to-lowest-level-since-december-s-flash-crash>. Acesso em: 26-mar-2022.

HOLLAND, Frank. Cryptocurrency prices fall in December, and investors blame omicron, climate change. *CNBC*, 2021. Disponível em: <https://www.cnn.com/2021/12/29/cryptocurrency-prices-fall-in-december-and-investors-blame-omicron-climate-change.html>. Acesso em: 25-mar-2022.

HOSEINZADE, E.; HARATIZADEH, S. Cnnpred: Cnn-based stock market prediction using a diverse set of variables. *Expert Systems with Applications*, Elsevier, v. 129, p. 273–285, 2019.

JANG, Huisu; LEE, Jaewook. An empirical study on modeling and prediction of Bitcoin prices with Bayesian Neural Networks based on Blockchain information. *IEEE Access*, vol. 6, p. 5427–5437, 2017. <https://doi.org/10.1109/ACCESS.2017.2779181>.

*Keras: The Python Deep Learning API*. Disponível em: <https://keras.io/>. Acesso em 07-mar-2023.

LIANG, Qiubin, et al. "Restricted Boltzmann machine based stock market trend prediction." *2017 International Joint Conference on Neural Networks (IJCNN)*. IEEE, 2017.

MACIEL, Leandro S.; BALLINI, Rosângela. Neural networks applied to stock market forecasting: An empirical analysis. *Learning and Nonlinear Models*, vol. 8, no. 1, p. 3–22, 2010. <https://doi.org/10.21528/lnlm-vol8-no1-art1>.

MARWALA, Lufuno Ronald. Forecasting the Stock Market Index Using Artificial Intelligence Techniques. 2014. 67–70 f. 2014. <https://core.ac.uk/download/pdf/39667613.pdf>.

MCNALLY, Sean; ROCHE, Jason; CATON, Simon. Predicting the price of Bitcoin using machine learning. *Proceedings - 26th, PDP 2018*, , p. 339–343, 2018. <https://doi.org/10.1109/PDP2018.2018.00060>.

MALKIEL, B.G. (2005), Reflections on the Efficient Market Hypothesis: 30 Years Later. *Financial Review*, 40: 1-9. <https://doi.org/10.1111/j.0732-8516.2005.00090.x>.

MCGOWAN, Michael J. "The rise of computerized high frequency trading: use and controversy." *Duke L. & Tech. Rev.* 9 (2009): 1.

PONCIANO, Jonathan. 'Looking Ugly': Crypto Market Crash Intensifies After \$300 Billion Sell-Off—How Low Can Bitcoin Prices Go?. *Forbes*, 2022. Disponível em: <https://www.forbes.com/sites/jonathanponciano/2022/01/10/looking-ugly-crypto-market-crash-intensifies-after-300-billion-sell-off-how-low-can-bitcoin-prices-go/?sh=9acf96aa11bd>. Acesso em: 26-mar-2022.

PIOTROSKI, Joseph D. "Value investing: The use of historical financial statement information to separate winners from losers." *Journal of Accounting Research* (2000): 1-41.

SELVIN, Sreelekshmy; VINAYAKUMAR, R.; GOPALAKRISHNAN, E. A.; MENON, Vijay Krishna; SOMAN, K. P. Stock price prediction using LSTM, RNN and CNN-sliding window model. *ICACCI 2017*, vol. 2017-Jan, p. 1643–1647, 2017. <https://doi.org/10.1109/ICACCI.2017.8126078>.

SOARES, Rebeca. CFOs brasileiros estão mais propensos a investir em tecnologia. *eInvestidor.estadao*, 2021. Disponível em: <https://einvestidor.estadao.com.br/investimentos/cfos-investem-em-tecnologia>. Acesso em: 24-mar-2022.

SHUANG, Yao; ZHANG, Weiqiang Huang Zhan. *Heterogeneous Investors*. no. 3, p. 2418–2421, 2011.

WANG, Jianliang; FANG, Linshan; ZHUANG, Xiang. Study and application of stock robot kaburobo based on artificial intelligence. *IJCAI*, p. 260–262, 2009. <https://doi.org/10.1109/IJCAI.2009.47>.

WAQAR, M., DAWOOD, H., GUO, P., SHAHNAWAZ, M. B., & GHAZANFAR, M. A. (2017). *Prediction of Stock Market by Principal Component Analysis*. *2017 13th International Conference on Computational Intelligence and Security (CIS)*. doi:10.1109/cis.2017.00139.