



SIMULAÇÃO DE DUAS TÉCNICAS DE PREDIÇÃO PARA NEGOCIAÇÃO DE CRIPTOMOEDAS

TWO PREDICTION TECHNIQUES SIMULATION FOR CRYPTOCURRENCY TRADING

ÁREA TEMÁTICA: 1. ADMINISTRAÇÃO DA INFORMAÇÃO

Mateus Felipe Larrosa Furlan, UEM, Brasil, ra102951@uem.br

Wagner Igarashi, UEM, Brasil, wigarashi@uem.br

Deisy Cristina Corrêa Igarashi, UEM, Brasil, dccigarashi@uem.br

Resumo

Marcada pela alta volatilidade no preço de criptomoedas, este mercado é responsável pela movimentação de trilhões de dólares, tendo como principal expoente a Bitcoin, moeda que no ano de 2021 ultrapassou o valor de 60 mil dólares. Assim, várias técnicas já utilizadas no mercado de ações como análise técnica e fundamentalista passaram a compor as estratégias de compra e venda dos investidores neste mercado. Além disso, técnicas computacionais da área da Inteligência Artificial, como as redes neurais artificiais do tipo Long Short Term Memory (LSTM), têm ganho destaque na previsão do mercado financeiro. Diante deste cenário, este trabalho tem como objetivo a realização de uma análise comparativa entre o uso de análise técnica e de LSTM para a predição de momentos propícios à compra, venda e manutenção de criptomoedas. O resultado obtido pelo modelo utilizando indicadores técnicos não foi satisfatório, visto que obteve um lucro de apenas 3,84% durante o período de 30 dias. Enquanto o modelo LSTM alcançou um lucro médio de 22,94% nas simulações.

Palavras chave: simulação; criptomoedas, análise técnica; redes neurais artificiais; LSTM.

Abstract

Marked by the high volatility in the price of cryptocurrencies, this market is responsible for the movement of trillions of dollars, with Bitcoin as its main exponent, a currency that in 2021 exceeded the value of 60 thousand dollars. Thus, several techniques already used in the stock markets, such as technical and fundamental analysis, became part of the buying and selling strategies of investors in this market. In addition, computational techniques in the field of Artificial Intelligence, such as Long Short Term Memory (LSTM) artificial neural networks, have gained prominence in forecasting the financial market. Given this scenario, this work aims to carry out a comparative analysis between the use of technical analysis and LSTM for the prediction of favorable moments for the purchase, sale and maintenance of cryptocurrencies. The result obtained by the model using technical indicators was not satisfactory, since it obtained a profit of only 3.84% during the period of 30 days. The LSTM model, on the other hand, achieved an average profit of 22.94% in the simulations.

Keywords: simulation; cryptocurrency, technical analysis; artificial neural network; LSTM.

1. INTRODUÇÃO

De acordo com Yuan e Wang (2018) a maioria das criptomoedas diferem-se do dinheiro eletrônico tradicional em cinco aspectos principais: descentralização, pois não demanda de entidade regulamentadora; anonimidade, neste caso a identidade do usuário é armazenada e não

é possível saber quem realizou a transação; tem quantidade limitada de moeda, portanto pode se esgotar e demandar da negociação somente entre os investidores que já dispõem do recurso; é um software de domínio público, ou seja possibilita que qualquer pessoa entenda o mecanismo de emissão dessas moedas; e ausência de valor intrínseco, são representadas por um código computacional e não tem, por si só, um valor monetário; por isso um dos fatores que influenciam no preço atribuído às criptomoedas é a quantidade de pessoas que utilizam essas moedas.

As criptomoedas utilizam uma tecnologia inovadora de alta-segurança, com muitas funcionalidades, e são oportunamente utilizadas como ativos de investimentos, o que vêm atraindo pesquisadores e investidores (Klein, Thu & Walther, 2018). Similarmente aos investimentos em ações, as criptomoedas podem possibilitar ganhos elevados, mas também se configuram como negócios de risco elevado. Para minimizar este risco, vários investidores utilizam de estratégias de mercado, como análise fundamentalista e técnica.

Além de estratégias de mercado, houve um aumento no desenvolvimento e utilização de técnicas de Inteligência Artificial, como redes neurais artificiais (RNA) voltadas para o mercado financeiro. Tais esforços foram designados ao estudo e desenvolvimento de técnicas para prever os preços de ativos, a fim de tornar esse mercado mais previsível e minimizar os riscos. Para isso, pesquisadores tem aliado indicadores técnicos à técnicas computacionais, como RNA *Long Short Term Memory* (LSTM), visando encontrar um modelo que facilite a tomada de decisões com base em dados históricos.

No cenário apresentado, é importante ressaltar que diferentes técnicas podem levar a resultados diferentes de predição para a realização de transações de investimento, no que podemos estabelecer a seguinte pergunta de pesquisa: Quais técnicas podem ser mais adequadas no processo de predição do movimento de preços de criptomoedas? De modo a responder esta pergunta de pesquisa, este estudo tem como objetivo realizar a análise comparativa entre duas técnicas de predição de preço, envolvendo o momento de compra e venda de criptomoedas. A primeira técnica utiliza indicadores técnicos simulados a partir de um robô de investimentos, utilizando a interface de programação de aplicativos da Binance. A segunda técnica foi desenvolvida utilizando uma RNA do tipo LSTM simulando investimentos em dados históricos de criptomoedas.

2. INDICADORES TÉCNICOS

Há dois tipos de análises utilizadas para prever tendências de preços de ações (análise fundamentalista e análise técnica). Cada uma apresenta particularidades tornando-as diferentes entre si. A análise fundamentalista, conforme Walter (1974) é utilizada por pessoas que agem como especuladores, pois esta abordagem faz uso apenas de notícias relacionadas, diretamente ou indiretamente, ao ativo financeiro.

A análise técnica, empregada no desenvolvimento desta pesquisa, não busca o motivo de uma movimentação do mercado, e sim seu efeito, pois acredita que apenas o efeito da movimentação importa (MURPHY, 1999). A análise técnica estuda ativos do mercado, por meio de gráficos, com o objetivo de prever a variação futura no preço de determinados ativos para, desta forma, definir qual o melhor momento de compra, venda e manutenção de ativos financeiros para maximizar o lucro. Um dos principais motivos para traduzir os preços de ativos em gráficos é

para facilitar a identificação de tendências e/ou padrões que podem auxiliar na predição do preço, uma vez que, conforme exposto por Murphy (1999), há certos padrões gráficos que foram identificados no passado que refletem alguns padrões que se repetem com o tempo.

O alcance do objetivo da análise técnica, depende de analistas utilizarem indicadores técnicos, para entender como o preço de um ativo pode se mover. Tais indicadores utilizam informações como: preço médio, máximo e mínimo de um ativo, além do preço de abertura, fechamento e o volume no mercado, a fim de identificar padrões e tendências. Os indicadores técnicos dividem-se em quatro categorias principais+: indicadores de tendência, indicadores de momentum, indicadores de volume, indicadores de volatilidade

Indicadores de tendência utilizam a média móvel, o qual é base para a criação de outros indicadores. A média móvel simples calcula a média da variação dos preços em um determinado período de tempo (geralmente dias) (Stockcharts, 2021). A partir das médias móveis diárias é estruturado um gráfico que auxilia na busca do padrão de comportamento em um determinado período. Contudo, esta técnica tem limitações por utilizar um período curto para análise (dias). Além disso, o primeiro dia de cálculo tem o mesmo peso que o último dia, contrariando o entendimento de que quanto mais recente o dado, maior o seu peso para o cálculo da média (Stockcharts, 2021).

Para minimizar o problema dos pesos foi desenvolvida a média móvel ponderada, assim o preço de fechamento é multiplicado pela posição do dia no período analisado. Mas, o problema de considerar apenas do período analisado ainda permanece, por isso foi desenvolvido o método da média móvel da suavização exponencial. Esse método ainda atribui maior importância aos dados mais recentes. Além disso, leva em conta todos os preços passados e usa um longo período de retrospectiva. Geralmente o impacto dos preços antigos no cálculo é mínimo, mas de grande importância, uma vez que auxilia na redução do ruído (Stockcharts, 2021).

O cálculo da média móvel exponencial (MME) é dividido em três passos: (i) cálculo da média móvel simples para o valor inicial da MME; (ii) cálculo do multiplicador do peso; e (iii) cálculo da média móvel exponencial para cada dia entre o dia inicial da MME e o dia atual, usando o preço, o multiplicador e o valor do MME do período anterior (Stockcharts, 2021)

A partir das médias foi desenvolvida a média móvel convergente e divergente (MACD - *Moving Average Convergence Divergence*) amplamente utilizado por analistas e traders. O MACD transforma dois indicadores de tendência (duas médias móveis), em um indicador de momentum ao subtrair a média móvel de maior período pela média móvel de menor período. Os dados processados pela MACD são dispostos em um gráfico composto por: linha MACD, linha de sinal e histograma. A linha MACD representa a diferença entre duas médias móveis exponenciais do preço de fechamento (últimos 12 e 26 dias). A linha de sinal definida por uma média móvel exponencial da linha MACD (usualmente período de 9 dias) utilizada para identificar pontos de virada. E o histograma, que é dado pela subtração entre a linha MACD e a linha de sinal. O histograma é positivo quando a linha MACD encontra-se acima da linha de sinal, e o oposto ocorre quando a linha de MACD está abaixo. A convergência ocorre quando as médias móveis se direcionam uma à outra, enquanto a divergência ocorre quando as médias móveis se afastam uma da outra. Quando a linha MACD cruza de baixo para cima a linha de

sinal, pode indicar um momento de compra. Caso a linha MACD cruze a linha de sinal de cima para baixo, pode indicar um momento de venda.

Outro indicador de momentum utilizado é o Índice de Força Relativa (RSI - *Relative Strength Index*). Segundo Murphy (1999) o RSI avalia a tendência de força de um ativo dada a sua variação de preço, indicando possíveis zonas de sobrecompra e sobrevenda. Zonas de sobrecompra indicam que o preço de um determinado ativo está mais alto que o valor intrínseco ou justo. Já as zonas de sobrevenda sinalizam que seu preço atual está mais baixo que o valor real do ativo. Esse é um indicador que mede a força interna de um ativo comparado à ele mesmo, em vez de compará-lo à outro ativo do mercado (Pring, 2002). O RSI foi desenvolvido com o intuito de solucionar dois problemas de um indicador de momentum: (1) movimentos irregulares e (2) a necessidade de dados de variações de preço de um ativo para fins comparativos (Pring, 2002).

Na categoria de indicadores de volatilidade, o oscilador estocástico é um dos mais conhecidos. É utilizado quando se busca demonstrar a relação entre o preço de fechamento e suas máximas e mínimas durante um determinado período de tempo. Ele é representado por duas linhas, %K e %D. A primeira é calculada por meio da divisão entre a diferença do preço de fechamento corrente e a menor mínima do período definido e a diferença do fechamento corrente e a maior máxima do período definido. A segunda é uma média móvel simples de, geralmente, três dias dos valores encontrados em %K. Assim como o RSI, esse indicador é utilizado para a identificação de zonas de sobrecompra e sobrevenda (Pring, 2002).

Caso a linha %K esteja entre 0 e 20 pontos, indica-se zona de sobrevenda. Caso o valor estiver acima de 80 pontos, indica zona de sobrecompra. Valores que não estejam nestas faixas não possuem interpretação precisa (Pring, 2002).

3. APRENDIZADO DE MÁQUINA

Segundo Samuel (1959) “O Aprendizado de Máquina é o campo de estudo que dá aos computadores a habilidade de aprender sem serem explicitamente programados”. Já para Mitchell (1997), o aprendizado de máquina (AM) é a capacidade de um programa de computador aprender a partir de uma experiência E a respeito de uma tarefa T e alguma medida de desempenho D, caso o programa desempenhe em T o medido por D, ele aprende com a experiência E.

Para Russel e Norvig (2020) existem dois motivos que tornam a capacidade de uma máquina de aprender vantajosa para os seres humanos. O primeiro é que a computação surge para solucionar algum entrave, para os quais os métodos tradicionais não são capazes de resolver (Géron, 2017) e por possuírem parâmetros instáveis, não sendo aplicável para antecipar situações. O segundo motivo é que o AM surge para solucionar problemas que nem programadores experientes sabem como resolver utilizando técnicas tradicionais.

De acordo com Alessandretti, El Bahrawy, Aiello e Baronchelli (2018) as técnicas de AM são efetivas para a predição do preço de ativos financeiros no mercado de ações e, consequentemente, são eficientes na predição do preço de criptomoedas. Muitos algoritmos se mostram eficientes na predição de preço de ações, e podem ser eficientes para a predição de

preço de criptomoedas, entre eles podem ser citados o Random Forest, Rede Neural Bayesina e Long Short-Term Memory (LSTM) que, de acordo com Wang e Gao (2018), é uma rede neural recorrente (RNR).

3.1 Long Short Term Memory

A predição dos preços de ativos financeiros é um dos maiores exemplos de dados que pode ser interpretada como uma série temporal. O preço dos ativos sofre influência de fatores externos, como política, economia e até mesmo da repercussão na mídia. As RNR introduziram o conceito de tempo em sua estrutura de rede, contudo, segundo Qian e Chen (2019), usar uma rede deste tipo para a predição de preço não é indicado, visto que a sequência de dados é longa e sofre interferência de fatores externos, podendo levar ao problema de desaparecimento de gradientes. A fim de solucionar esse problema, Hochreiter e Jürgen (1997) propuseram o modelo de rede chamado *Long Short Term Memory* (LSTM), que é utilizado neste trabalho para a implementação do modelo de predição de preços utilizando Aprendizado de Máquina.

Um dos pontos principais do modelo LSTM está em sua estrutura interna, que permite o armazenamento de padrões que se repetem com o tempo. Além disso, esse modelo permite o truncamento de informações quando são irrelevantes para o resultado. A cada variável que o LSTM processa, são adicionados novos dados em um compartimento de memória, com gates (portões) controlando qual novo dado deve ser armazenado e quais dados antigos devem ser descartados. Diferentemente das redes neurais recorrentes que produzem uma lista de estados durante o seu processamento, o próximo estado computado pelo LSTM depende do estado atual.

A arquitetura do LSTM é constituída de três partes, sendo a primeira onde são selecionadas as informações que serão mantidas e as que serão descartadas por serem irrelevantes. Na segunda parte é onde a decisão de quais informações devem ser mantidas na memória, podendo ser interpretada como a parte em que o modelo aprende novas coisas. Por fim, a terceira parte passa para frente as informações atualizadas. Essas três partes são chamadas, respectivamente, de *Forget Gate*, *Input Gate* ou *Remember Gate* e *Output Gate*.

4. MATERIAIS E MÉTODOS

Primeiramente foi realizado o levantamento dos indicadores técnicos mais utilizados e possíveis técnicas de Aprendizado de Máquina. Em um segundo momento foi desenvolvido um modelo de análise técnica implementado em um robô de investimento no ambiente de simulação da Binance. Foi desenvolvido também um modelo que realiza a predição de preços de criptomoedas com base em uma RNR do tipo LSTM. Por fim, foi feita uma análise comparando os resultados dos dois modelos.

A tomada de decisão do robô de investimento é baseada em regras de produção utilizando os indicadores técnicos MACD, RSI e Oscilador Estocástico. Para a linha MACD, utilizou-se uma média móvel exponencial de 12 dias e outra de 26 dias, enquanto para o cálculo da linha de sinal do MACD foi definido um período de 9 dias. Já para o Índice de Força Relativo, RSI, optou-se por 9 dias de fechamento para a realização do cálculo do indicador, com valores limites de 30 e 70. Por fim, para o cálculo do Oscilador Estocástico, foi utilizado um período de 14 dias para a geração da linha %K, com os valores limites de 20 e 80.

Para treinar o modelo LSTM foi utilizada a biblioteca Pandas, para recuperar dados da API Yahoo Finance, relacionados a históricos de preços de cinco criptomoedas: Bitcoin (BTC), Ethereum (ETH), Binance Coin (BNB), XRP e Dogecoin (DOGE) (Tabela 1). Entre as informações utilizadas para a construção do modelo foram: o preço de abertura, o preço de fechamento, o menor e o maior preço atingido no dia e o volume de transações realizadas. Foi realizada uma normalização dos valores na escala de -1 a 1, utilizando a biblioteca *sklearn*.

A criação do modelo LSTM foi feita a partir de funções fornecidas pela biblioteca *Keras*. Foi utilizado um modelo sequencial, de cinco camadas, sendo as três primeiras compostas por 128 nós do tipo LSTM cada, e duas dense, uma de 32 e outra de 2 nós. No processo de treinamento foram utilizadas as configurações: *BatchNormalization*, *Dropout* nas primeiras quatro camadas, função de ativação *softmax* e função de custo de entropia cruzada (ou *Cross-Entropy Cost Function*).

Na criação do modelo LSTM, um dos passos cruciais é o treinamento do modelo utilizando uma porção dos dados coletados como entrada. Para tal, os dados de cada criptomoeda disponíveis na API da Yahoo Finance foram separados de forma que do início dos registros até o final do ano de 2020 fossem usados para o treinamento e validação do modelo, sendo 5% utilizado para a validação e o restante para o treinamento (Tabela 1).

Criptomoeda	Período de treinamento	Período de validação
Bitcoin (BTC)	01/10/2014 - 06/09/2020	07/09/2020 - 31/12/2020
Ethereum (ETH)	01/12/2017 - 05/11/2020	05/11/2020 - 31/12/2020
Binance Coin (BNB)	01/12/2017 - 05/11/2020	05/11/2020 - 31/12/2020
XRP	01/12/2017 - 05/11/2020	05/11/2020 - 31/12/2020
Dogecoin (DOGE)	01/12/2017 - 05/11/2020	05/11/2020 - 31/12/2020

Tabela 1 – Período utilizado para cada criptomoeda

As simulações de investimento utilizaram dados referentes ao ano de 2021.

5. ANÁLISE DE DADOS

5.1 Modelo LSTM

O modelo LSTM obteve um desempenho satisfatório, tendo feito várias transações durante o período usado nos testes. Ao observar a Figura 1, é possível notar que em todos os meses houve uma movimentação considerável de dinheiro, tendo o mês de outubro como o que mais teve gastos, com aproximadamente US\$202.114,00, e o de dezembro o mês de maior lucro, com mais de 330 mil dólares.

Por meio da Figura 1 é possível constatar o alto número de compras de criptomoedas realizadas durante o ano de 2021, tendo sido o mês de outubro o qual mais foram feitas aquisições de ativos. Pode-se notar uma relação, uma vez que na Figura 1 este mesmo mês foi o que mais teve gastos. Vale ressaltar que isso pode ter colaborado para o lucro no mês de dezembro, visto que os meses de outubro e novembro foram os que mais tiveram transações de compra. Outro ponto à ser levado em conta é o modo de treinamento do modelo, tendo em vista que um dos passos

do pré-processamento dos dados foi classificar os dias do período de teste como bons para compra ou venda com base no preço de fechamento do próximo dia, seguindo a lógica de que se o preço de fechamento do dia posterior for maior do que o atual, caracteriza-se um momento bom para compra.

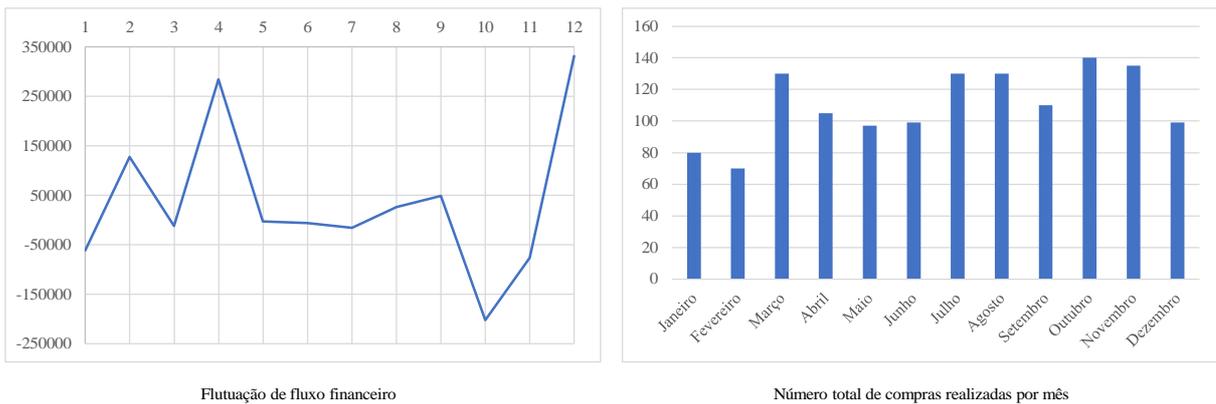


Figura 1 – Flutuação de fluxo financeiro e Número total de compras realizadas por mês

Tomando como base a Bitcoin, que foi o ativo mais comprado no mês de outubro (Figura 3), pode-se notar que este mês foi um dos meses em que a Bitcoin mais valorizou (Figura 2), cerca de 33%, além de ter vários dias consecutivos em que aumentou o valor do ativo.

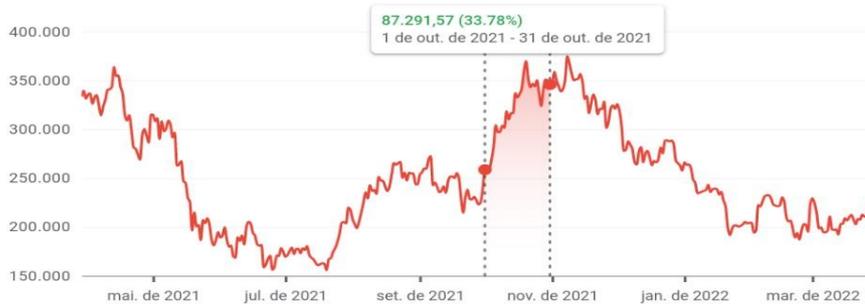


Figura 2 – Variação de preço do Bitcoin

Fonte: Google Finanças (2022)

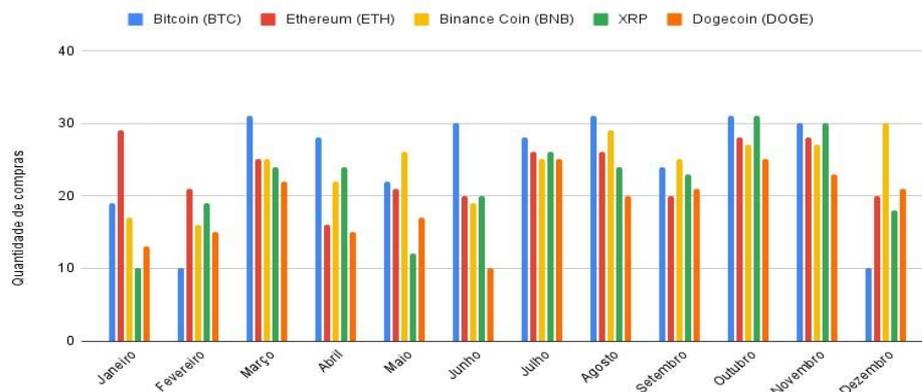


Figura 3 – Número de compras por criptomoeda realizadas por mês

De forma correlata às compras, pode-se associar o grande número de vendas de ativos no mês de Maio, de acordo com o Figura 4, à queda de preço da Bitcoin, representado pela Figura 5, a qual, juntamente da XRP e da Dogecoin, foram as criptomoedas que mais tiveram transações de venda no mês em questão, como representado na Figura 6. Ademais, observa-se que nos meses de outubro e novembro em que houve uma grande valorização da Bitcoin, o número de vendas realizadas diminuiu drasticamente.

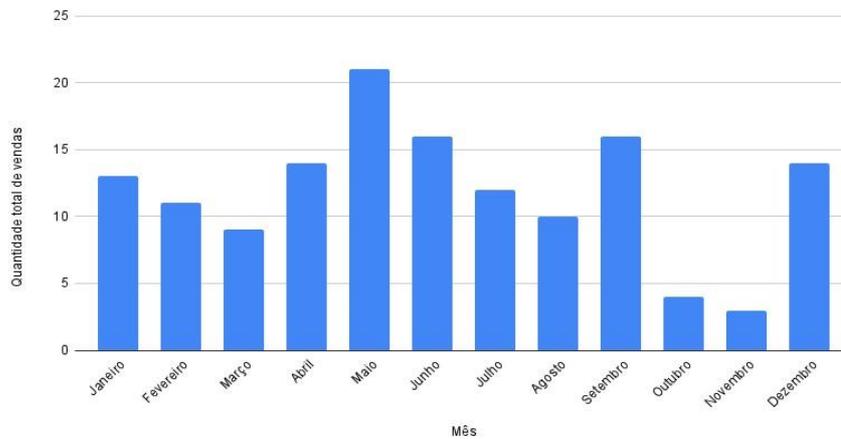


Figura 4 – Número total de vendas realizadas por mês

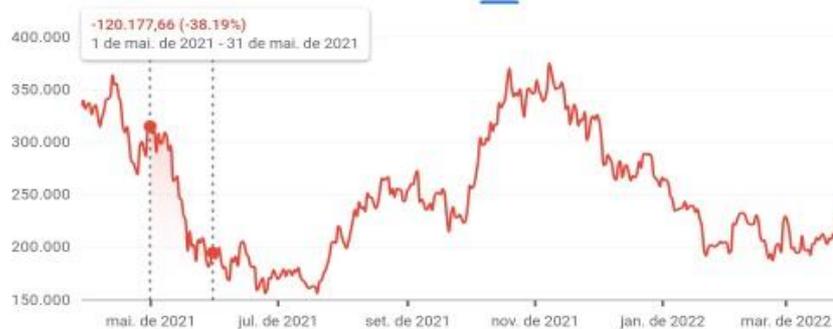


Figura 5 – Gráfico Bitcoin Maio 2021

Fonte: Google Finanças (2022)

Ao analisar as informações presentes na Tabela 2, é possível constatar que o número de compras e vendas realizadas durante o ano de 2021 foi consideravelmente alto, totalizando 1493 transações, sendo 1350 de compra — onde a Bitcoin foi a criptomoeda mais adquirida, participando de 294 transações — e 143 de venda, tendo como destaque a XRP com 37 transações. Desta forma, pode-se dizer que a simulação demonstrou que a tomada de decisão do modelo segue uma linha mais agressiva, onde várias transações são realizadas.

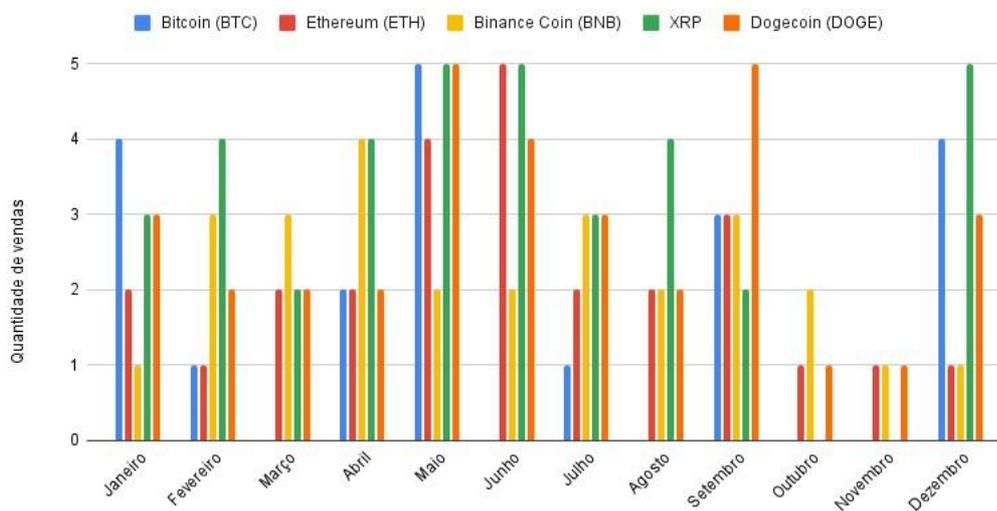


Figura 6 – Número de vendas por criptomoeda realizadas por mês

Carteira	Valores
Montante inicial	100.000
Montante final	375.296,48
Lucro bruto	275,3%
Número de compras	1350
Número de vendas	143
Ativo mais comprado	Bitcoin - 294
Ativo mais vendido	XRP - 37

Tabela 2 – Estado final da carteira

Para explicar o alto número de transações, é necessário ater-se ao objetivo deste modelo. Ao implementar o modelo LSTM, desde o começo foi levado em conta a necessidade de torná-lo equiparável ao modelo utilizando indicadores técnicos e a API da Binance. Desta forma, tanto a base de dados quanto o ambiente de simulação foram criados pensando em formas de o modelo realizar um grande número de transações e diversificar sua carteira de investimento. Assim, além da junção da base de dados de cinco criptomoedas diferentes, a cada transação de compra é utilizado apenas 2% do valor disponível na carteira. Desta forma, nunca há falta de dinheiro para investir em novos ativos, logo, todas as decisões de compra que o modelo tomou foram realizadas.

5.2 Robô de investimento utilizando indicadores técnicos

Para a obtenção dos resultados do robô de investimentos foi utilizada a plataforma de testes disponibilizada pela Binance. Além disso, as chamadas feitas pelo algoritmo foram todas a partir da API da própria plataforma. As tomadas de decisões do robô foram pautadas apenas na análise de três indicadores técnicos, sendo eles o MACD, RSI e Oscilador Estocástico. A

execução do algoritmo era realizada a cada cinco minutos, e para a obtenção dos valores usados para construir os indicadores técnicos, eram recuperados da API os gráficos de vela dos últimos 15 minutos de cada um dos ativos passíveis de transação.

É importante notar que o ambiente da Binance é uma plataforma de testes. Além disso, uma vez que o mercado de criptomoeda é descentralizado — as transações acontecem sem a existência de uma entidade mediadora — e o preço destes ativos são autorreguláveis, seguindo a lei da oferta e demanda, o preço das criptomoedas são diferentes dos reais, já que a plataforma é desacoplada do ambiente real, tendo seus próprios usuários e suas próprias transações.

Para a obtenção dos resultados, o robô ficou operante durante um período de 30 dias, de 18 de fevereiro à 20 de Março de 2022, sendo executado a cada 5 minutos. Transformando este período em minutos, pode-se dizer que o robô ficou em funcionamento durante 43200 minutos, e neste tempo, a rotina foi executada 8640 vezes. Ao final da execução, os resultados obtidos são os apresentados pela Tabela 3, onde pode-se observar um lucro de apenas US\$ 3.843,79 durante o período de 30 dias em que o robô operou.

Carteira da Binance	Valores
Montante inicial	US\$ 100.000
Montante final	US\$ 103.843,79
Porcentagem de lucro	3,84%
Dinheiro movimentado em compras	US\$ 2.284.176,02
Dinheiro movimentado em vendas	US\$ 2.388.019,81

Tabela 3 – Estado final da carteira

Ademais, durante a execução do robô foram compradas e/ou vendidas 94 diferentes criptomoedas e realizadas mais de 82 mil transações, conforme o exposto na Tabela 4. Dentre as mais de 90 criptomoedas, a que menos participou de transações foi a StormX (STMX), com apenas duas aparições, e a Dash (DASH) a que mais participou de transações, com mais de 4700, de acordo com a Figura 7.

Transações	Quantidade
Vendas	2423
Compras	80228
Total	82651

Tabela 4 – Número de transações realizadas pelo robô

Como pode ser observado pela Figura 8, a criptomoeda que mais integrou transações de vendas foi a Bitcoin Dominance Perps (BTCDOM), participando de 203, uma quantidade

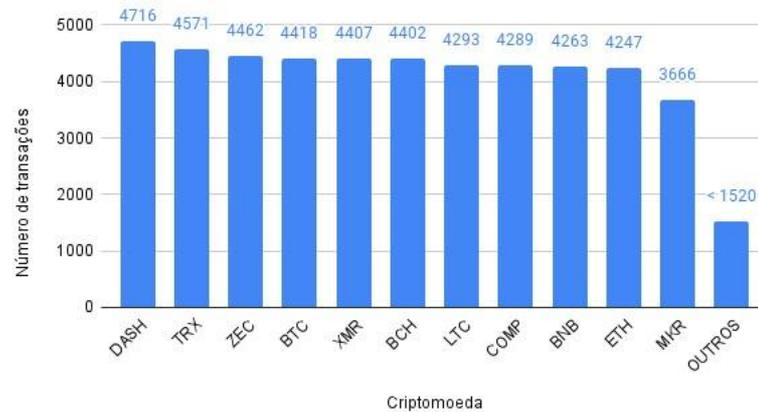


Figura 7 – Número total de transações realizadas por criptomoeda

153% maior do que o número de compras envolvendo o ativo Zcash (ZEC), o segundo colocado em vendas. De acordo com a Binance, a BTCDOM é um índice de preço de criptomoedas que reflete o desempenho da dominância de mercado da Bitcoin, sendo uma métrica que pode ser utilizada para obter rapidamente uma noção do valor da Bitcoin em relação ao panorama geral do mercado de criptomoedas. Apesar da grande quantidade de vendas envolvendo a BTCDOM, ela aparece apenas em 16^a na lista das criptomoedas que mais participaram de transações de compra. Como pode ser observado na Figura 9, diversos ativos participaram de mais de 4000 ações de compra realizadas pelo algoritmo, entre eles o Ethereum, a Binance Coin, a Bitcoin, entre outros, sendo a DASH a criptomoeda que mais foi comprada, participando de 4668 transações.

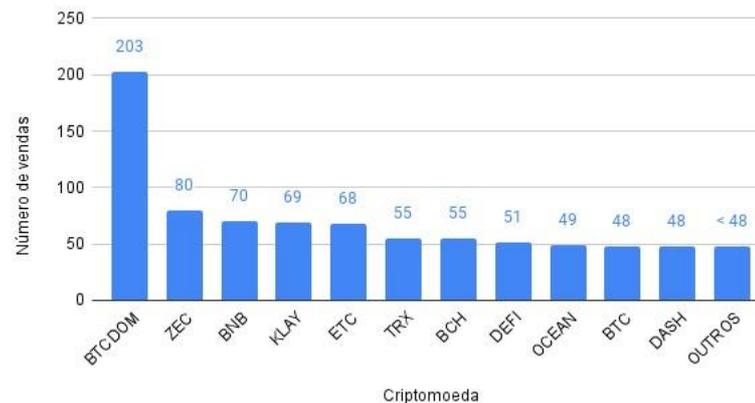


Figura 8 – Número total de vendas realizadas por criptomoeda

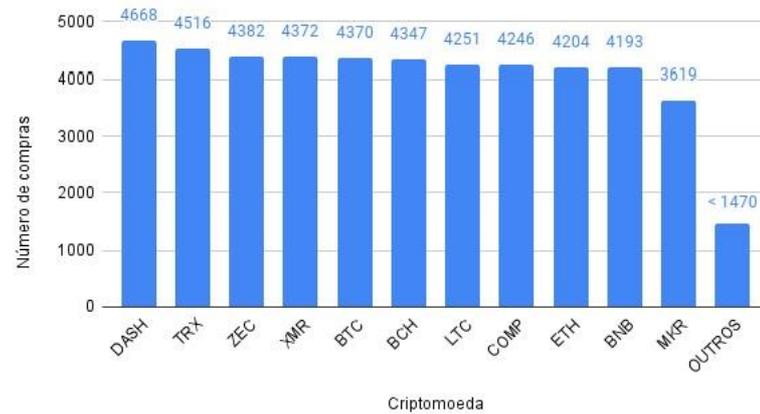


Figura 9 – Número total de compras realizadas por criptomoeda

A Figura 10 representa uma relação entre o montante gasto com compras e vendas das 11 criptomoedas que mais movimentaram dinheiro em transações de compras, a fim de analisar qual foi o ativo que mais causou lucro e o que mais causou prejuízo durante a execução do robô de investimentos. Além do montante gasto com compras e vendas, também é apresentado na figura o percentual de lucro de cada criptomoeda analisada. Relembrando que a cada compra realizada pelo robô, apenas 2% do saldo disponível na carteira era gasto, porém nas transações de venda, toda a quantidade do ativo presente na carteira era vendida.

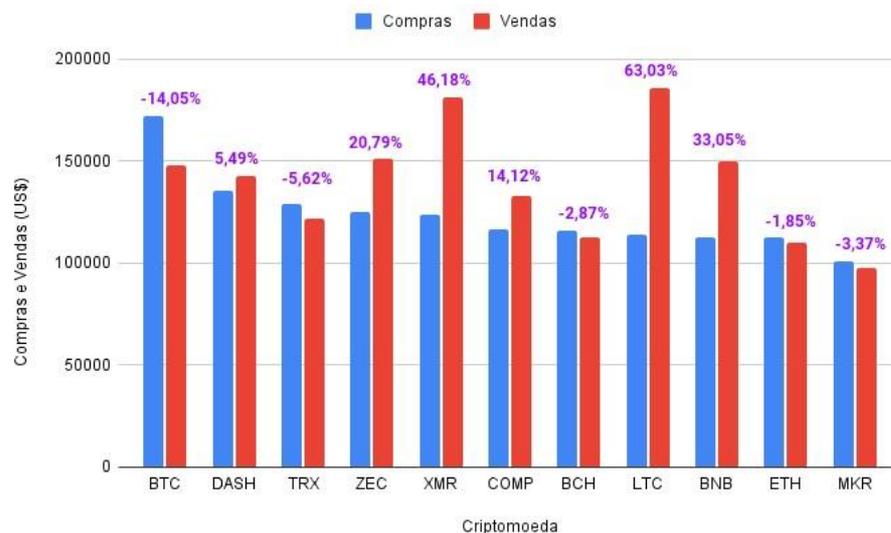


Figura 10 – Relação entre o montante gasto com compras e vendas

Como pode ser observado, a criptomoeda que mais causou prejuízo foi a Bitcoin, a qual apresentou uma perda de mais de 24 mil dólares. Em contrapartida, têm-se a Litecoin (LTC) como a criptomoeda que mais lucrou durante a simulação, com um ganho de aproximadamente US\$ 72.000.

5.3 Comparativo entre as simulações

A comparação foi realizada com a média mensal do modelo LSTM com o robô de investimentos, dado que o robô ficou operando durante 30 dias, desta forma, pode-se ter uma comparação mais real dos resultados. Para o simulador utilizando LSTM, o lucro foi obtido por meio da simulação, onde ao final de cada mês era armazenado em uma lista o lucro ou prejuízo do mês. Para o simulador utilizando a plataforma de testes da Binance, o lucro foi calculado pelo saldo na carteira ao final da simulação, que foi realizada durante os meses de fevereiro e março de 2022. O lucro de cada uma das estratégias pode ser observado pela Figura 11, em laranja. Além disso, a título de ilustração, foram adicionados os lucros de três criptomoedas caso fossem comercializadas em uma estratégia *buy and hold*.

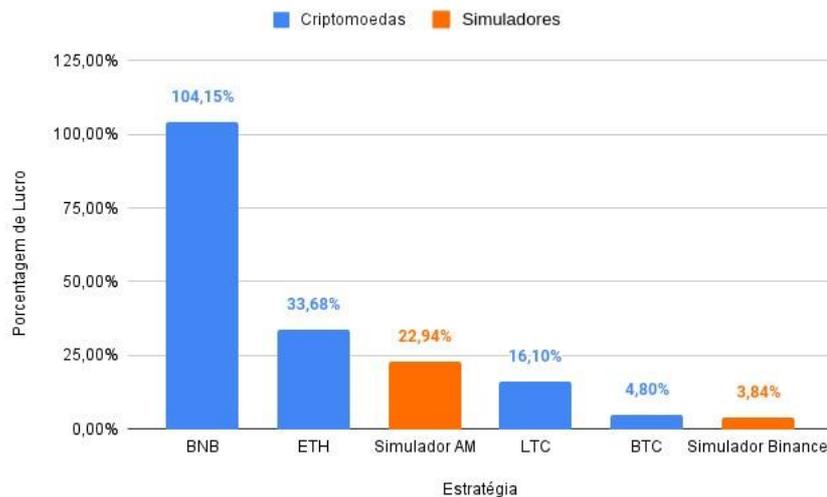


Figura 11 – Porcentagem de lucro mensal das diferentes estratégias

As moedas analisadas na Figura 11 foram algumas das que mais influenciaram em ambas as simulações, por exemplo a Bitcoin, que foi a que mais causou prejuízo no simulador utilizando indicadores técnicos. Os dados para o cálculo da média de lucro mensal das criptomoedas foram retirados do Yahoo Finance. Para a obtenção do valor, foi utilizada a seguinte fórmula:

$$valorizacao\ anual = \frac{Fechamento\ 31/12/2021}{Fechamento\ 01/01/2021} \cdot 100 - 100$$

$$valorizacao\ mensal = \frac{valorizacao\ anual}{12}$$

Portanto, nota-se que apesar do baixo desempenho do robô de investimentos operando na plataforma de teste da Binance, sendo o pior dentre os analisados, foi alcançado um lucro mensal próximo à valorização da Bitcoin. Além disso, para o período de 1 mês, o simulador utilizando dados históricos e Aprendizado de Máquina obteve um desempenho 497,39% superior ao simulador utilizando dados em tempo real e indicadores técnicos.

O baixo desempenho do simulador utilizando indicadores técnicos pode ter sido causado pela alta frequência de execução da rotina do algoritmo. Como o robô operava a cada 5 minutos utilizando dados dos últimos 15 minutos para decidir se havia alguma moeda em bom momento

para a compra ou venda, apenas 1/3 do gráfico de velas não tinha sido analisado anteriormente, e caso tivesse sido tomada uma decisão errônea na execução anterior, a chance de ela ser tomada novamente era maior. Outro ponto a se atentar é que não há nenhum mecanismo de parada caso algo anormal aconteça durante a operação do algoritmo. Tiveram momentos em que o robô decidiu comprar Bitcoin em mais de 10 execuções seguidas, e muitas vezes esse ativo foi vendido posteriormente por um preço menor, ocasionando um grande prejuízo à simulação.

6. CONCLUSÃO

Este trabalho propôs realizar a comparação entre duas técnicas de predição de preço, envolvendo o momento de compra e venda de criptomoedas: um robô de investimentos utilizando indicadores técnicos em um ambiente simulado da Binance e um simulador de investimentos que utiliza um modelo LSTM de aprendizagem de máquina.

Em relação à simulação feita na plataforma de testes da Binance utilizando indicadores técnicos, buscou-se na literatura os principais indicadores técnicos utilizados no processo de compra e venda de ativos financeiros, dos quais foram utilizados o MACD, o Índice de Força Relativo (RSI) e o Oscilador Estocástico. O modelo LSTM foi treinado utilizando preço de abertura, preço de fechamento, preço mínimo, preço máximo e volume de transações.

Em relação aos resultados obtidos, pode-se concluir que, apesar de nenhum deles ter chegado ao final do período de simulação com um saldo negativo, todos ficaram abaixo da própria valorização de algumas das criptomoedas utilizadas no trabalho. O desempenho do simulador utilizando indicadores técnicos foi 25% menor do que a própria valorização da Bitcoin. Além disso, a estratégia utilizada com indicadores técnicos demonstrou-se inferior ao modelo utilizando LSTM. Um dos fatores que podem ter ocasionado esta diferença de desempenho foi a utilização apenas de indicadores técnicos para a tomada de decisão, visto que o robô realizava a execução da rotina de compra e venda a cada 5 minutos, e possivelmente os dados coletados dos últimos 15 minutos não fossem suficientes para a tomada de decisão correta. Outro fator para o baixo desempenho foi a falta de um mecanismo de segurança que pausasse a compra de um determinado ativo financeiro caso ele tenha sido comprado em muitas execuções seguidas, visto que, tomando como exemplo o caso da Bitcoin – a moeda que mais causou prejuízo à simulação – que em diversos momentos foi feita a compra em mais de 10 execuções seguidas e, na maioria dos casos, foi vendida por um preço menor do que a compra, sendo interessante aperfeiçoar a estratégia de venda.

Como proposta de trabalhos futuros, têm-se a oportunidade de unir o modelo LSTM, o qual obteve um desempenho satisfatório, com os indicadores técnicos para auxiliar na tomada de decisão do robô de investimento, dentro do ambiente de simulação da Binance. Além disso, a exploração de outras técnicas de Aprendizado de Máquina, quanto de análise técnica que possam ser integradas aos simuladores desenvolvidos, também são uma possibilidade de ampliação dos conhecimentos produzidos neste trabalho.

REFERÊNCIAS

Alessandretti, L., El Bahrawy, A. Aiello, L. M. & Baronchelli, A. Anticipating cryptocurrency prices using machine learning. *Complexity*, v. 2018, p. 1–16, 11 2018.

- Géron, A. *Hands-on Machine Learning with Scikit-Learn and TensorFlow: Concepts, tools, and techniques to build intelligent systems*. O'Reilly Media, 2017. ISBN 9781491962299.
- Google Finanças. *Gráficos, comparações e notícias sobre finanças*. 2022. [Online; acessado Março 28, 2021]. Disponível em: <<https://www.google.com/finance/>>.
- Hochreiter, S. & Jürgen, S. Long Short-Term Memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, 11 1997. ISSN 0899-7667.
- Klein, T., Thu, H. P. & Waltherad, T. Bitcoin is not the new gold – a comparison of volatility, correlation, and portfolio performance. *International Review of Financial Analysis*, v. 59, p. 105–116, 2018. ISSN 1057-5219.
- Mitchell, T.M. *Machine Learning*. McGraw-Hill, 1997. (McGraw-Hill International Editions). ISBN 9780071154673.
- Murphy, J.J. *Technical Analysis of the Financial Markets: A comprehensive guide to trading methods and applications*. New York Institute of Finance, 1999.
- Pring, M. J. *Technical Analysis Explained: The successful investor's guide to spotting investment trends and turning points*. McGraw-Hill Education, 2002. ISBN 9780071816199.
- Qian, F. & Chen, X. Stock prediction based on lstm under different stability. In: *2019 IEEE 4th International Conference on Cloud Computing and Big Data Analysis (ICCCBDA)*. Chengdu, Sichuan, China, 2019. p. 483–486.
- Samuel, A. L. Some studies in machine learning using the game of checkers. *IBM Journal of Research and Development*, v. 3, n. 3, p. 210–229, 1959.
- Stockcharts. Moving Averages - Simple and Exponential. 2021. [Online; acessado Novembro 21, 2021]. Disponível em: <https://school.stockcharts.com/doku.php?id=technical_indicators:moving_averages>.
- Walter, R. G. Análise fundamentalista e avaliação de títulos: aspectos teóricos. *Revista de Administração de Empresas*, SciELO Brasil, v. 14, p. 15–32, 1974.
- Wang, C. & Gao, Q. High and low prices prediction of soybean futures with lstm neural network. In: *2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS)*. [S.l.: s.n.], 2018. p. 140–143.
- Yuan, Y. & Wang, F. Y. Blockchain and cryptocurrencies: Model, techniques, and applications. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, v. 48, n. 9, p. 1421–1428, 2018.