



UFOP

Universidade Federal
de Ouro Preto

**Universidade Federal de Ouro Preto
Instituto de Ciências Exatas e Aplicadas
Departamento de Computação e Sistemas**

**Previsão da variação de preços
aplicada ao mercado de opções
binárias com o uso de redes neurais
LSTM**

Rangel Magalhães Melo

**TRABALHO DE
CONCLUSÃO DE CURSO**

**ORIENTAÇÃO:
Sarah Negreiros de Carvalho Leite**

**Junho, 2022
João Monlevade–MG**

Rangel Magalhães Melo

**Previsão da variação de preços aplicada ao
mercado de opções binárias com o uso de redes
neurais LSTM**

Orientador: Sarah Negreiros de Carvalho Leite

Monografia apresentada ao curso de Engenharia da Computação do Instituto de Ciências Exatas e Aplicadas, da Universidade Federal de Ouro Preto, como requisito parcial para aprovação na Disciplina “Trabalho de Conclusão de Curso II”.

Universidade Federal de Ouro Preto

João Monlevade

Junho de 2022

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

M528p Melo, Rangel Magalhaes.

Previsão da variação de preços aplicada ao mercado de opções binárias com o uso de redes neurais LSTM. [manuscrito] / Rangel Magalhaes Melo. - 2022.

52 f.: il.: color., gráf., tab..

Orientadora: Profa. Dra. Sarah Negreiros de Carvalho Leite.

Monografia (Bacharelado). Universidade Federal de Ouro Preto. Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia de Computação .

1. Aprendizado do computador. 2. Bitcoin. 3. Bolsa de valores. 4. Mercado de ações - Previsão. 5. Mercado financeiro. 6. Redes neurais (Computação). I. Leite, Sarah Negreiros de Carvalho. II. Universidade Federal de Ouro Preto. III. Título.

CDU 336.76:004

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



FOLHA DE APROVAÇÃO

Rangel Magalhães Melo

Previsão da variação de preços aplicada ao mercado de opções binárias com o uso de redes neurais LSTM

Monografia apresentada ao Curso de Engenharia de Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Engenharia de Computação.

Aprovada em 20 de junho de 2022.

Membros da banca

Profa. Dra. Sarah Negreiros de Carvalho Leite - Orientadora - Universidade Federal de Ouro Preto
Prof. Dr. Luiz Carlos Bambirra Torres - Universidade Federal de Ouro Preto
Me. Weld Lucas Cunha - SiDi

Profa. Dra. Sarah Negreiros de Carvalho Leite, orientadora do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 27/06/2022.



Documento assinado eletronicamente por **Sarah Negreiros de Carvalho Leite, PROFESSOR DE MAGISTERIO SUPERIOR**, em 27/06/2022, às 21:53, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0352657** e o código CRC **6E600DAD**.

Agradecimentos

Agradeço primeiramente a Deus que me capacitou e me deu forças em toda minha caminhada durante a graduação. Minha família e amigos que estiveram junto comigo em todo esse tempo e que colaboraram de alguma forma para que isso fosse possível.

Agradeço a todos os meus amigos da República “Toca do Tatu”, que me acolheram em João Monlevade, onde convivemos durante anos compartilhando momentos que ficarão marcados para toda vida.

Agradeço a todos os professores que dedicam parte de suas vidas a nos ensinar, orientar e nos formar como profissionais. À professora Sarah Negreiros, que me orientou, esteve presente durante todo o trabalho e não hesitou em momento algum a me ajudar quando precisei, toda a minha gratidão.

“Ambition is the path to success. Persistence is the vehicle you arrive in.”

(Bill Bradley)

Resumo

Prever o movimento dos ativos do mercado financeiro sempre foi um desafio para os investidores devido a vários fatores influentes. No mercado de opções binárias, o que importa para os investidores é apenas se o movimento será de alta ou de baixa, ou seja, acertar em um determinado período de operação se o preço do ativo irá subir ou descer. Este estudo visa através do uso de modelos de redes neurais prever a variação do preço do Bitcoin e do índice NASDAQ Composite considerando o modelo de operação do mercado de opções binárias, com o objetivo de reduzir os riscos dos investimentos e melhorar a taxa de assertividade das operações, conseguindo uma assertividade superior a 50%. O modelo construído utiliza uma rede LSTM multivariada e utiliza como dados de entrada os valores de preço de abertura do período (*Open*), preço de fechamento do período (*Close*), preço mais alto atingido no período (*High*) e preço mais baixo atingido no período (*Low*). Além desses dados, que foram obtidos via API do Yahoo Finance, foram adicionados os seguintes indicadores técnicos: *Simple Moving Average* (SMA), *Exponential Moving Average* (EMA), *Moving Average Convergence Divergence* (MACD) e *Relative Strength Index* (RSI). O modelo que utilizou dados do índice NASDAQ Composite, apresentou um erro médio absoluto de 1.66% no valor de predição do valor de fechamento no período e uma assertividade de 58%, quando aplicado ao modelo de opções binárias. Enquanto que, o modelo utilizando dados do Bitcoin, apresentou um erro médio absoluto de 2.69% no valor de predição do valor de fechamento no período e uma assertividade próxima a 55%, quando aplicado ao modelo de opções binárias.

Palavras-chaves: LSTM. Aprendizado de Máquina. Mercado Financeiro. Bitcoin. NASDAQ.

Abstract

Predicting the movement of financial market assets has always been a challenge for investors due to several influential factors. In the binary options market, what matters to investors is only whether the movement will be up or down, that is, set in a certain period of operation whether the price of the asset will go up or down. Through the use of neural network models, this study aims to predict the price variation of Bitcoin and the NASDAQ Composite index considering the operating model of the binary options market, to reduce the risks of investments and improve the assertiveness rate operations, achieving an assertiveness of over 50%. The model constructed uses a multivariate LSTM network and uses as input data the values of the opening price of the period (Open), the closing price of the period (Close), the highest price reached in the period (High) and the lowest price achieved in the period (Low) and in addition to these quoted data that are provided via the Yahoo Finance API, were added Technical indicators data: Simple Moving Average (SMA), Exponential Moving Average (EMA), Moving Average Convergence Divergence (MACD) and Relative Strength Index (RSI). The model using data from the NASDAQ Composite index presented an average absolute error of 1.66% in the prediction value of the closing value in the period and when applied to the binary options model, and assertiveness of 58%. The model using Bitcoin data, on the other hand, presented an average absolute error of 2.69% in the prediction value of the closing value in the period, and when applied to the binary options model, assertiveness is close to 55%.

Key-words: LSTM. Machine Learning. Financial Market. Bitcoin. NASDAQ.

Lista de ilustrações

Figura 1 – Gráfico da Petrobrás mostrando as marcações de suporte e resistência, e formando um canal lateral.	19
Figura 2 – Gráfico da Ibovespa mostrando fundos ascendentes marcados pelas setas formando uma LTA.	20
Figura 3 – Gráfico da Gerdau mostrando fundos descendentes marcados pelas setas formando uma LTB.	20
Figura 4 – Gráfico da Ibovespa mostrando fundos e topos ascendentes marcados por setas verdes e vermelhas respectivamente formando um canal de alta.	21
Figura 5 – Gráfico da Gerdau mostrando fundos e topos descendentes marcados por setas verdes e vermelhas respectivamente formando um canal de baixa.	22
Figura 6 – Modelo de aprendizagem supervisionado para a classificação de e-mails.	26
Figura 7 – Imagem Ilustrativa de aprendizagem não supervisionado para a detecção de cães e gatos.	27
Figura 8 – Modelo de um neurônio.	28
Figura 9 – Modelo de um neurônio artificial.	28
Figura 10 – Modelo de uma rede neural artificial.	29
Figura 11 – Modelo de rede <i>feedforward</i> e uma RNN.	29
Figura 12 – Representação de realimentação de uma célula de RNN em função do tempo.	29
Figura 13 – Representação da estrutura de realimentação de uma célula de RNN padrão.	30
Figura 14 – Representação da estrutura de realimentação de uma célula de rede LSTM.	31
Figura 15 – Representação do estado celular de uma estrutura LSTM.	31
Figura 16 – Representação do <i>Forget Gate</i> de uma estrutura LSTM.	32
Figura 17 – Representação do <i>Memory Gate</i> de uma estrutura LSTM.	32
Figura 18 – Representação do <i>Output Gate</i> de uma estrutura LSTM.	33
Figura 19 – Modelo de predição com dados de 5 anos (2017/2021) do Bitcoin usando uma janela de 90 dias.	37
Figura 20 – Modelo de predição de 05-21 a 12-21 com dados de 5 anos (2017/2021) do Bitcoin usando uma janela de 90 dias.	37
Figura 21 – Modelo de predição com dados de 5 anos (2017/2021) do Bitcoin usando uma janela de 10 dias.	38
Figura 22 – Modelo de predição de 06-21 a 12-21 com dados de 5 anos (2017/2021) do Bitcoin usando uma janela de 10 dias.	39

Figura 23 – Modelo de predição com dados dos últimos 2780 dias do Bitcoin usando uma janela de 50 dias.	40
Figura 24 – Modelo de predição de 11-20 a 05-22 com dados dos últimos 2780 dias do Bitcoin usando uma janela de 50 dias.	41
Figura 25 – Modelo de predição com dados dos últimos 1500 dias do Bitcoin usando uma janela de 50 dias.	42
Figura 26 – Modelo de predição de 08-21 a 06-22 com dados dos últimos 1500 dias do Bitcoin usando uma janela de 50 dias.	42
Figura 27 – Modelo de predição com dados dos últimos 12 anos do índice NASDAQ Composite usando uma janela de 50 dias.	44
Figura 28 – Modelo de predição de 01-20 a 06-22 com dados dos últimos 12 anos do índice NASDAQ Composite usando uma janela de 50 dias.	45

Lista de tabelas

Tabela 1 – Demonstração de uma operação usando 2 martingales com um <i>payout</i> de 90%.	25
Tabela 2 – Base de dados diária do Bitcoin de cerca de 8 anos.	34
Tabela 3 – Base de dados diária da NASDAQ de cerca de 12 anos.	35
Tabela 4 – Parâmetros da rede LSTM - primeiro cenário.	36
Tabela 5 – Taxa de assertividade no mercado de opções binárias - janela de 90 dias e 196 épocas.	38
Tabela 6 – Taxa de assertividade no mercado de opções binárias - janela de 10 dias e 500 épocas.	38
Tabela 7 – Parâmetros da rede LSTM - segundo cenário.	40
Tabela 8 – Resultados de predição do valor de fechamento do modelo com dados dos últimos 2780 dias - segundo cenário.	41
Tabela 9 – Taxa de assertividade no mercado de opções binárias - dados dos últimos 2780 dias e janela de 50 dias.	41
Tabela 10 – Resultados de predição do valor de fechamento do modelo com dados dos últimos 1500 dias - segundo cenário.	43
Tabela 11 – Taxa de assertividade no mercado de opções binárias - dados dos últimos 1500 dias e janela de 50 dias.	43
Tabela 12 – Parâmetros da rede LSTM - terceiro cenário.	44
Tabela 13 – Resultados de predição do valor de fechamento do modelo com dados dos últimos 12 anos - terceiro cenário.	45
Tabela 14 – Taxa de assertividade no mercado de opções binárias - dados dos últimos 12 anos e janela de 50 dias.	45
Tabela 15 – Avaliação do retorno de operação seguindo o modelo aplicado ao mercado de opções binárias - primeiro cenário.	46
Tabela 16 – Avaliação do retorno de operação seguindo o modelo aplicado ao mercado de opções binárias - segundo cenário.	46
Tabela 17 – Avaliação do retorno de operação seguindo o modelo aplicado ao mercado de opções binárias - terceiro cenário.	46
Tabela 18 – Avaliação do retorno de operação seguindo o modelo aplicado ao mercado de opções binárias com <i>payout</i> de 80% - segundo cenário.	47

Sumário

1	INTRODUÇÃO	13
1.1	Motivação	13
1.2	Objetivos	14
2	REVISÃO BIBLIOGRÁFICA	15
3	DESENVOLVIMENTO	17
3.1	<i>Price Action</i>	17
3.2	Análise Técnica	18
3.2.1	Suporte e Resistência	18
3.2.2	Tendência	18
3.2.2.1	Linha de Tendência	19
3.2.3	Canal de Alta e de Baixa	21
3.2.4	Indicadores	22
3.2.4.1	SMA (<i>Simple Moving Average</i>)	23
3.2.4.2	EMA (<i>Exponential Moving Average</i>)	23
3.2.4.3	MACD (<i>Moving Average Convergence Divergence</i>)	23
3.2.4.4	RSI (<i>Relative Strength Index</i>)	24
3.3	Análise Probabilística	24
3.3.1	Martingale	24
3.4	Aprendizado de Máquinas	25
3.4.1	Processos de Aprendizado	25
3.4.1.1	Aprendizado Supervisionado	26
3.4.1.2	Aprendizado Não Supervisionado	26
3.4.2	Rede Neural Artificial	27
3.4.2.1	Redes LSTM	30
3.5	Base de Dados	33
3.5.1	Bitcoin	33
3.5.2	NASDAQ Composite	34
4	RESULTADOS	36
4.1	Primeiro Cenário	36
4.2	Segundo Cenário	39
4.3	Terceiro Cenário	43
4.4	Discussões	46

5	CONCLUSÃO	48
5.1	Trabalho Futuros	48
	REFERÊNCIAS	50

1 Introdução

O mercado de opções binárias é diferente do mercado financeiro tradicional, em que se opera na bolsa de valores, por exemplo, comprando ações por determinado preço e vendendo posteriormente com o preço mais alto, com o intuito de se ganhar nessa variação dos preços (HULL, 2016). Nesse mercado, o investidor tenta prever a variação do preço em um intervalo de tempo predeterminado, e “aposta” se o preço do ativo irá subir (*call*) ou descer (*put*) no intervalo de tempo estabelecido, caso acerte seu investimento terá o retorno fixo independentemente de quanto o preço variar, o retorno gira em torno de 80% a 87%, podendo chegar a até 99% dependendo da corretora que se usa, do horário do dia e de como o mercado está reagindo. Caso ele erre, o valor do investimento é totalmente perdido. No mercado de opções binárias, além de ações (Ex: Facebook, Twitter, Apple), outros ativos também podem ser operados, como criptomoedas (Ex: Bitcoin, Ethereum, Ripple) e os pares cambiais de moedas (Ex: EUR/USD, EUR/JPY, EUR/GBP).

Neste projeto foi desenvolvido um modelo de predição utilizando a estrutura de rede neural recorrente, em especial um modelo de rede LSTM (*Long Short-Term Memory*), com o intuito de prever as variações dos ativos do mercado de ações, utilizou-se dados históricos do preço do Bitcoin e dados de índice da bolsa de valores NASDAQ (do inglês, *National Association of Securities Dealers Automated Quotations*) em um determinado espaço de tempo estabelecido. De acordo com as variações previstas, pode-se operar no mercado de opções binárias indicando com mais assertividade a direção da variação dos preços dos ativos. Com isso, os investidores podem utilizar combinações de técnicas operacionais junto às previsões do modelo e aumentar os lucros perante o mercado.

1.1 Motivação

Para operar no mercado financeiro, investidores primeiramente analisam o gráfico dos ativos que pretendem operar antes de realizar uma ação de venda ou de compra. Uma técnica usada é o *Price Action* ou ‘ação do preço’, que é um fundamento de leitura de mercado baseado na análise do comportamento dos preços dos ativos ao longo do tempo. De maneira geral, a função da análise de *Price Action* para o investidor é mostrar os padrões de movimentação do preço para tentar prever os movimentos futuros (GRIMES, 2012).

Levando em consideração um cenário binário randômico, onde se tem duas opções de movimentação do preço (alta ou baixa), a probabilidade de acerto em uma operação seria de 50%. Afim de aumentar a probabilidade de acerto em uma operação pode-se recorrer a técnicas, como o martingale (WILLIAMS, 1991). Esta técnica consiste em

aumentar o valor da entrada referente à entrada anterior, a fim de recuperar o capital perdido anteriormente e ainda ganhar a taxa inicial desejada.

Contudo, muitos fatores externos podem influenciar no movimento do mercado, como notícias relacionadas à economia e política, e conseqüentemente nas análises dos gráficos que podem não serem percebidas pelos investidores, podendo ocasionar a perda das operações. Um modelo de predição automático da movimentação dos preços, que apresente uma boa taxa de assertividade, pode auxiliar os investidores a tomarem suas decisões e, com isso, aumentarem seus lucros.

1.2 Objetivos

O objetivo principal do projeto é prever variações dos ativos do mercado financeiro em um determinado espaço de tempo estabelecido por meio de algoritmos de redes neurais recorrentes LSTM. E de acordo com as variações previstas, aplicar ao modelo de operação do mercado de opções binárias, ou seja, prever a direção da variação dos preços com o intuito de obter uma assertividade superior a 50%. Uma vez obtidos esses valores, investidores podem utilizar combinações de técnicas operacionais junto às previsões do modelo e aumentar os lucros perante o mercado.

2 Revisão bibliográfica

(DEEPAK; UDAY; MALATHI, 2017) propõe uma abordagem de Rede Neural Artificial (RNA), essa rede foi treinada a partir dos dados de índice da Bolsa de Valores de Bombaim (BSE), a principal bolsa de valores da Índia, e então realiza as previsões. Parâmetros como “Média Móvel Convergente e Divergente” e “Estocástico” foram incluídos nos dados para a regra de negociação.

(NABIPOUR et al., 2020) faz um comparativo entre algoritmos de aprendizado de máquina e aprendizado profundo que utilizam dados contínuos com algoritmos que utilizam dados binários, ambos com o intuito de fazer previsões de ativos da bolsa de Teerã, a bolsa de valores do Irã. No estudo, nove modelos de *Machine Learning* são comparados (árvore de decisão, *Random Forest*, *Adaptive Boosting* (Adaboost), *eXtreme Gradient Boosting* (XGBoost), *Support Vector Classifier* (SVC), *Naive Bayes*, *K-Nearest Neighbors* (KNN), Regressão Logística e Rede Neural Artificial), além de dois métodos de aprendizagem profunda *Recurrent Neural Network* (RNN) e *Long short-term memory*. Dez indicadores técnicos de dez anos de dados históricos foram usados como entrada de dados dos algoritmos. Os estudos mostraram que houve uma melhora significativa no desempenho dos modelos quando eles usavam dados binários ao invés vez de dados contínuos.

(SHYNKEVICH et al., 2017) estuda a importância do tamanho da janela usada nos algoritmos feitos para realizar previsões da variação do preço de ativos do mercado financeiro. O tamanho da janela é usado para calcular os indicadores técnicos que são usados como dados de entrada.

(YANG; ZHAI; TAO, 2020) apresenta uma estrutura de predição utilizando técnicas de aprendizado profundo com redes convolucionais e LSTM para prever a direção do movimento do preço das ações. Para isso foram usados dados de onze índices de ações que são: S&P 500, NASDAQ, DJIA, RUSSELL, NYSE, DAX, N225, FTSE, CAC40, HSI e SSE.

(LIMA, 2017) fez um estudo sobre o mercado de opções binárias e sobre como investidores faziam suas operações. Após estudos sobre como o mercado se comportava montou-se um algoritmo de *deep learning* com uma estrutura de rede neural recorrente. Escolheu-se dois ativos do mercado para serem analisados, que foram os pares cambiais de moedas USD/JPY (dólar/iene japonês) e o AUD/JPY (dólar australiano/iene japonês). Além disso, para a base de dados foram escolhidas 11 entradas, das quais são indicadores percebidos por (LIMA, 2017) que eram mais utilizados por investidores em suas análises, dentre eles a EMA (Média móvel exponencial), SMA (Média móvel simples) e o RSI (Índice de força relativa). O modelo para previsão multi-classe construído foi baseado em

uma LSTM, com o uso de *Dropout*, função de ativação ReLU e o algoritmo de otimização utilizado foi o Adam. Ao final dos estudos, foi feito um teste utilizando o algoritmo como indicação para operações na plataforma Binary.com, que oferece uma conta de demonstração com \$10.000,00. Ao final do período de operações o valor dos rendimentos foi de \$10.778,75, ou seja, um lucro de \$778,75.

(MÜLLER, 2020a) implementou um algoritmo de *deep learning* com uma estrutura de rede neural recorrente. O modelo utiliza camadas LSTM e o intuito de se fazer previsões de séries temporais multivariadas. Foi utilizada uma base de dados do índice de ações NASDAQ, com as seguintes variáveis de entrada do modelo: *High* (preço mais alto atingido no período), *Low* (preço mais baixo atingido no período), *Open* (preço na abertura do período), *Close* (preço no fechamento do período), Volume (volume de negociação do período).

Além disso, nesse estudo, (MÜLLER, 2020b) realiza a previsão de dados de índice de ações S&P 500, implementando uma rede neural recorrente com camadas LSTM e prevendo dados de uma semana à frente.

(ZOU; QU, 2020) construiu modelos de *Deep Learning* e RNN de última geração, para realizar previsões de preços de ações do dia seguinte. Foram implementados modelos de redes LSTM, *Stacked LSTM* e *Attention-Based LSTM*, juntamente com o modelo ARIMA tradicional. Foram usados como entrada da rede uma base de dados contendo informações como ‘preço de fechamento de ajuste’, ‘volume de negociação’, ‘relação dívida/capital’, ‘retorno sobre o patrimônio’, ‘margem de lucro’, ‘lucro diluído por ação’ e ‘beta da empresa’ das maiores empresas norte-americanas da SP 500. Pode-se observar que o modelo com melhores resultados perante o mercado foi a *Attention-Based LSTM*.

(MOGHAR; HAMICHE, 2020) desenvolveu uma estrutura de rede neural recorrente, em especial uma estrutura de rede LSTM contendo quatro camadas de rede LSTM, outras quatro camadas de *Dropout* e uma camada *Dense* com uma única saída. Foram usados dados de ações da Nike e da Google para treinamento e validação da rede. Foram testadas diferentes combinações de dados de treinamento da rede, com épocas igual a 12, 25, 50 e 100. Pôde-se observar que com uma base de dados menor e o número maior de épocas, os dados da previsão eram mais significativos.

3 Desenvolvimento

Como diz (BRITO, 2019) “*A natureza humana muitas vezes caracteriza-se pelo inter-relacionamento lógico entre comportamentos, atitudes e ações. No mercado financeiro, o comportamento esperado às vezes torna-se incoerente*”. Esses comportamentos inesperados se dão principalmente pela forma como os seres humanos agem no dia-a-dia, tomando decisões muitas vezes inundados pela emoção e não pela razão.

Emoções e sentimentos, muitas vezes, tornam comportamentos lógicos em comportamentos inesperados, em consequência, o mercado financeiro não segue uma matemática exata. Existem diferentes variáveis que podem influenciar no comportamento do mercado e que não se pode prever, por exemplo, decisões que são tomadas por governos ou por grandes empresas e são noticiadas, gerando uma oscilação no mercado, tanto positiva quanto negativa.

Mesmo com questionamentos e dúvidas, o que se busca no mercado é entender o comportamento e determinados padrões de movimentação. Entretanto, existem técnicas usadas por investidores para analisar os gráficos de ativos do mercado, fazer a leitura e tomar suas decisões.

3.1 *Price Action*

Segundo (GRIMES, 2012), o *Price Action* ou “ação do preço” é um assunto complexo e que pode ser interpretado de maneiras diferentes por pessoas atuantes no mercado ou *Traders*. Os movimentos dos preços no mercado geram padrões aleatórios nos gráficos. Contudo, é possível identificar alguns pontos menos aleatórios nos quais o movimento do mercado é percebido com mais facilidade e são esses pontos que os *Traders* buscam para lucrar.

Basicamente, é visto por muitos como uma técnica de leitura de mercado baseada na análise do comportamento dos preços dos ativos ao longo do tempo. De maneira geral, a função da análise de *Price Action* para o investidor é mostrar os padrões de movimentação dos preços dos ativos do mercado.

Para basear as análises, investidores utilizam alguns fundamentos básicos para leitura dos gráficos (geralmente plotados em *candlestick*).

3.2 Análise Técnica

A análise técnica teve seus primeiros registros por volta do século XVII, em Osaka - Japão (sede da Bolsa de Arroz Dojima, fundada em 1654), quando famílias japonesas passaram a acompanhar a variação do preço do arroz (PIAZZA, 2010).

Segundo (PINHEIRO, 2005), a análise técnica, tem como objetivo o estudo dos movimentos históricos dos preços do mercado, para determinar o estado atual ou as condições futuras deste mercado.

O princípio básico da análise técnica é que os preços dos ativos do mercado se correlacionam em função do tempo, ou seja, os preços futuros são influenciados pelos preços passados, e com isso a previsão desses preços futuros seria algo possível.

3.2.1 Suporte e Resistência

Segundo (LEMOS, 2015), suporte e resistência são considerados os principais conceitos na análise técnica, e são conceitos que precisam ser bem entendidos para conseguir bons resultados no mercado.

É chamada de suporte uma região onde o preço não passa mais que um limite, não rompendo essa região para baixo, respeitando essa análise por um determinado tempo.

Pode-se detectar um suporte observando no gráfico uma sequência na qual o preço chega em uma região, ganha uma força de alta, e volta a buscar essa região novamente, repetindo o movimento e consolidando uma região forte de suporte do preço.

Resistência segue o mesmo raciocínio do suporte, mas para a alta do preço. É uma região na qual o preço não rompe para cima e segue este comportamento por um determinado tempo.


Observa-se uma lateralização na imagem, formando um canal, onde se tem um suporte e uma resistência consolidados.

Após uma sequência de toques, a região de resistência é rompida. Suportes e resistências não são uma regra universal, porém tais estratégias ajudam os investidores a entenderem melhor a evolução do ativo.

3.2.2 Tendência

(LEMOS, 2015) descreve tendência como, a direção dos preços para qual o mercado está se movimentando. Identificando uma tendência no mercado, o investidor consegue lucrar com essa movimentação de preço comprando um ativo por um preço baixo e vendendo por um valor mais alto, por exemplo. Nos gráficos de histórico de preço dos ativos, as linhas de tendência ajudam a marcar e identificar as mesmas.

Figura 1 – Gráfico da Petrobrás mostrando as marcações de suporte e resistência, e formando um canal lateral.



Fonte: (DESCUBRA... , 2020).

3.2.2.1 Linha de Tendência

Linhas de tendência são usadas para interligar pontos de fundos ou topos de um gráfico que não estão na mesma altura. Matematicamente, poderia se dizer que as linhas de tendência funcionam como uma função de primeiro grau, ou função afim, já as linhas de suporte e resistência funcionam com uma função constante.

As linhas de tendência apresentam as mesmas características de regiões de suporte e resistência, mas para fundos e topos em valores distintos. Para identificar cada tipo, denomina-se Linha de Tendência de Alta (LTA) e Linha de Tendência de Baixa (LTB).

Uma linha de tendência de alta se caracteriza por topos e fundos se formando de maneira ascendente no gráfico. Assim que notados, basta traçar uma linha nessa região formando uma LTA. Na Figura 2 é possível perceber fundos ascendentes marcados pelas setas. A linha que une os pontos é a LTA. Ao analisar regiões de suporte e resistência, não é necessário ter uma precisão milimétrica, dependendo do tempo de operação e tipo de análise, pequenos rompimentos podem ser desconsiderados.

Uma linha de tendência de baixa, se caracteriza por topos e fundos se formando de maneira descendente no gráfico. Assim que notados, basta traçar uma linha nessa região formando uma LTB, como pode-se ver na figura 3.

(LEMOS, 2015) diz que quanto maior duração de um suporte, resistência e das linhas de tendência, o volume negociado sob as demarcações dos mesmos, a quantidade de vezes em que são respeitados os níveis e quanto mais recente ocorrer um movimento sob os mesmos, mais forte é a região de preço demarcada no gráfico.

Figura 2 – Gráfico da Ibovespa mostrando fundos ascendentes marcados pelas setas formando uma LTA.



Fonte: (TENDÊNCIAS..., 2010).

Figura 3 – Gráfico da Gerdau mostrando fundos descendentes marcados pelas setas formando uma LTB.



Fonte: (TENDÊNCIAS..., 2010).

3.2.3 Canal de Alta e de Baixa

De acordo com (LEMOS, 2015) a linha de canal também é chamada de linha de retorno. É um caso particular das linhas de tendência, onde os preços dos ativos oscilam entre duas linhas paralelas.

As linhas de tendência costumam mostrar qual a tendência atual do gráfico, se o gráfico está em uma tendência de alta ou de baixa. E além disso, outra forma de visualizar essa tendência são com os canais de alta e de baixa.


Um canal é formado por duas linhas paralelas, marcando uma região com topos e fundos bem definidos

Figura 4 – Gráfico da Ibovespa mostrando fundos e topos ascendentes marcados por setas verdes e vermelhas respectivamente formando um canal de alta.



Fonte: (TENDÊNCIAS..., 2010).

Figura 5 – Gráfico da Gerdau mostrando fundos e topos descendentes marcados por setas verdes e vermelhas respectivamente formando um canal de baixa.



Fonte: (TENDÊNCIAS..., 2010).

3.2.4 Indicadores

(LEMOS, 2015) trata como indicador técnico conjunto de dados derivados de ferramentas matemáticas ou aplicação de fórmulas sob os preços dos ativos do mercado. Estes preços podem ser combinações de abertura, fechamento, máximo e mínimo no período analisado, além do tamanho da janela ou número de períodos considerados.

Os indicadores são utilizados para auxiliar os investidores nas análises gráficas, dando uma perspectiva diferente e, conseqüentemente, ajudando nas tomadas de decisões. Dentre vários indicadores, alguns mostram a tendência do mercado, probabilidade de reversão, volatilidade, retração e vários outros aspectos que auxiliam as análises técnicas dos investidores.

No contexto de modelos de redes neurais para o mercado financeiro, os indicadores podem servir como dados de entrada para os modelos (NABIPOUR et al., 2020).

Sob a visão de (THAWORNWONG; DAGLI; ENKE, 2001), investidores têm o costume de usar indicadores em suas análises e a ausência dos mesmos pode acarretar em modelos ruins de previsão, utilizando redes neurais. É importante que informações que se correlacionam sejam inseridas nos modelos para se obter bons resultados.

A seguir são apresentados alguns dos indicadores mais utilizados e que foram escolhidos para servir como dados de entrada do modelo de rede neural multivariado

implementado neste trabalho.

3.2.4.1 SMA (*Simple Moving Average*)

Uma média móvel simples (SMA) calcula a média de preço de fechamento de um ativo do mercado em um intervalo de tempo selecionado.

As médias calculadas em um curto período respondem rapidamente às mudanças no preço dos ativos, já as médias calculadas em um espaço de tempo maior, são mais lentas em relação às mudanças de preço. Este indicador pode ajudar a visualizar a tendência do mercado (HAYES, 2022). A SMA é calculada pela fórmula:

$$SMA_t(n) = (C_t + C_{t-1} + \dots + C_{t-n+1})/n$$

sendo:

C_t : valor de fechamento do ativo no instante t

n : número de períodos para o cálculo da SMA

3.2.4.2 EMA (*Exponential Moving Average*)

A média móvel exponencial também é conhecida como média móvel exponencialmente ponderada, tem a mesma ideia da SMA mas, coloca pesos maiores nos dados mais recentes e com isso a reação em relação às mudanças de preço mais recentes são mais significativas (CHEN, 2022). A EMA é calculada pela fórmula:

$$EMA(K)_t = EMA(K)_{t-1} \times \left(1 - \frac{2}{K+1}\right) + C_t \times \frac{2}{K+1}$$

sendo:

C_t : valor de fechamento do ativo no instante t

K : número de períodos considerados para o cálculo da EMA

3.2.4.3 MACD (*Moving Average Convergence Divergence*)

A média móvel convergente e divergente (MACD) é um indicador que relaciona duas médias móveis do preço de fechamento de um ativo. A MACD é calculada subtraindo a média móvel exponencial de 26 períodos (EMA) da EMA de 12 períodos.

A MACD ajuda os investidores a entender os movimentos de alta ou de baixa no preço, analisando se o movimento está forte ou fraco mostrando movimentos consolidados ou duvidosos (FERNANDO, 2022a). A MACD é calculada pela fórmula:

$$MACD_t = EMA(12)_t - EMA(26)_t$$

3.2.4.4 RSI (*Relative Strength Index*)

Índice de Força Relativa (RSI) é um indicador que mede a velocidade e a mudança dos movimentos de preços. O RSI oscila entre zero e 100 e é considerado sobrecomprado quando acima de 70 e sobrevendido quando abaixo de 30 (FERNANDO, 2022b). O RSI é calculado pela fórmula:

$$RSI_t(n) = 100 - \frac{100}{1 + \left(\frac{\sum_{i=1}^{n-1} UP_{t-i}}{\sum_{i=1}^{n-1} DW_{t-i}} \right)}$$

sendo:

n : número de período para cálculo do RSI

UP_t : aumento de preço no instante t

DW_t : diminuição de preço no instante t

3.3 Análise Probabilística

Em um cenário de mercado binário onde se têm duas opções de movimentação do preço (alta ou baixa), a probabilidade de acerto em uma operação seria de 50%, levando em consideração a aleatoriedade do cenário. Contudo, técnicas de manipulação das ordens de compra e venda feitas, podem fazer com que essa probabilidade aumente, lembrando que o contexto considera a aleatoriedade.

3.3.1 Martingale

No contexto da probabilidade em opções binárias, o martingale é uma técnica usada para melhorar a taxa de assertividade da estratégia usada (DOOB, 1971). A técnica consiste em aumentar o valor da entrada referente a entrada anterior a fim de recuperar o capital perdido anteriormente e ainda ganhar a taxa inicial desejada.

No cenário binário (operando em gráficos de *candlesticks*) onde a chance de dar uma vela vermelha é de 50% e de dar uma vela verde é de 50%, suponha que a análise feita é para a vela ser verde e utilizando 2 martingales. Nesse cenário se tem 3 entradas no máximo: 1 entrada inicial, outra no 1º martingale, outra no 2º martingale, se necessário.

Neste cenário, para que a operação seja bem-sucedida, precisa-se que alguma dessas 3 velas seja verde, para que a operação seja perdida é necessário que as 3 velas seguidas sejam vermelhas. Levando em consideração um cenário binário, se tem 50% de dar vermelha na primeira, 50% na segunda e 50% na terceira, a probabilidade dessa sequência ocorrer seria de $0,5 * 0,5 * 0,5 = 0,125$ ou 12,5% de chance. Logo a chance de se ter uma série vitoriosa é o restante, ou seja, 87,5%. Vamos analisar como seriam as entradas com um retorno de 90% em caso de vitória:

Tabela 1 – Demonstração de uma operação usando 2 martingales com um *payout* de 90%.

Valor de Entrada	Retorno	Ganho Final
R\$ 10,00	R\$ 9,00	R\$ 9,00
R\$ 21,11	R\$ 19,00	R\$ 9,00
R\$ 44,57	R\$ 40,11	R\$ 9,00

Fonte: Pelo autor.

Supondo que a primeira entrada seja perdida, o valor da entrada para recuperar os R\$ 10,00 perdidos e ainda lucrar os R\$ 9,00 iniciais previstos seria de R\$ 21,11. Em caso de vitória, se recupera o valor perdido inicialmente e ainda se lucra o valor previsto. Mas caso perca novamente, se entra com R\$ 44,57, a fim de recuperar as duas entradas perdidas anteriormente e ainda lucrar o valor inicial previsto. Caso a última entrada seja perdida novamente, o valor total perdido será de R\$ 75,68, ou seja, para recuperar esse valor perdido serão necessárias pelo menos 9 vitórias com o mesmo cenário descrito. O martingale é capaz de aumentar muito a assertividade de uma estratégia, mas ao mesmo tempo é uma técnica agressiva que é capaz de acabar com todo o capital de um investidor em pouco tempo.

3.4 Aprendizado de Máquinas

Entende-se como *Machine Learning* ou "Aprendizado de Máquinas", uma área de estudos da Inteligência Artificial, capaz de dar à máquina a capacidade de aprender algo sem ter sido programada diretamente para esse aprendizado. Com outras palavras, a capacidade de aprender por meio de uma extensa análise de dados.

Os algoritmos de *Machine Learning*, são utilizados para que por meio dessa análise de dados, o sistema desenvolvido crie, ou melhor, aprenda maneiras ou regras, para devolver as respostas esperadas.

De acordo com (ALPAYDIN, 2010), técnicas de *Machine Learning* são usadas em casos nos quais não é possível estabelecer uma expressão analítica específica que determine o resultado desejado, como prever o comportamento do mercado financeiro.

3.4.1 Processos de Aprendizado

Processos de aprendizado de máquina estão intimamente ligados à capacidade dos algoritmos de interpretar e aprender com os dados oferecido pelo sistema e resolver o problema que é exposto (NEGREIROS, 2021).

A capacidade de aprendizado de um modelo está relacionada com o quão assertivo ele é com os resultados das saídas, obtidos por meio dos dados de entrada e das tomadas de decisões, ou seja, o quão eficiente ele é na resolução do problema em questão.


Os processos de aprendizado de máquinas, podem ser classificados em dois principais grupos, supervisionados e não supervisionados.

3.4.1.1 Aprendizado Supervisionado

Aprendizado supervisionado está relacionado a capacidade de se aprender utilizando modelos de exemplo, ou seja, a base de dados oferecida ao modelo possui valores de entradas e seus respectivos valores de saída. De acordo com esses dados de treinamento, o modelo deve aprender a como resolver o problema.

Um exemplo de aprendizado supervisionado comum no dia-a-dia é a detecção de e-mail spam. Uma base de dados é oferecida com vários tipos de e-mails e suas características, além disso o resultado da classificação dizendo se o e-mail é considerado um spam ou não. De acordo com esses dados oferecidos, o algoritmo deve ser capaz de dizer se os e-mails podem ser considerados spam (SILVA, 2021).

Figura 6 – Modelo de aprendizagem supervisionado para a classificação de e-mails.



Fonte: (SILVA, 2021).

3.4.1.2 Aprendizado Não Supervisionado

Aprendizado Não Supervisionado está relacionado à capacidade de se aprender utilizando uma base de dados que não possui rótulos. O algoritmo deve aprender por si só a dar sentido aos dados. Esses algoritmos buscam, por exemplo, padrões ocultos de características e realizam agrupamentos das entradas semelhantes.

Um exemplo de aprendizado não supervisionado, seria fornecer uma base de dados com imagens de animais, por exemplo, gatos e cachorros, e o algoritmo iria detectar semelhanças entre as imagens e agrupá-las de acordo com suas semelhanças e com isso conseguir detectar se uma imagem oferecida é um gato ou um cachorro (SILVA, 2021).

Figura 7 – Imagem Ilustrativa de aprendizagem não supervisionado para a detecção de cães e gatos.



Fonte: (PAPEL... , 2022).

3.4.2 Rede Neural Artificial


Uma rede neural artificial tenta simular os processos que ocorrem em uma rede neural biológica. As redes neurais humanas são formadas por bilhões de neurônios, conectados entre si, recebendo informações através de estímulos e realizando os processos sinápticos, ou seja, a tomada de decisão de disparar ou não um sinal, gerando uma resposta, de como agir referente às entradas, e essas simulam diversas situações distintas (NEGREIROS, 2021).

Para entender o processo de uma maneira simplificada, os dendritos captam os sinais gerados pelos sentidos humanos e levam até o corpo celular para ser processado, podendo disparar sinais a outros neurônios ou não. Esse envio de sinal ocorre através do axônio.

O neurônio artificial recebe as entradas da base de dados simulando os sinais enviados pelos sentidos humanos e recebidos pelos dendritos. As entradas são ponderadas pelos pesos sinápticos e somadas. A função de ativação recebe e simula o processo sináptico de disparar um sinal ou não.


A maneira de se distribuir os neurônios e suas conexões formam a arquitetura de uma rede neural. Dessa maneira, pode-se observar na Figura 10 que a rede é formada pela

Figura 8 – Modelo de um neurônio.



Fonte: (NEURÔNIOS, 2022).

Figura 9 – Modelo de um neurônio artificial.




Fonte: (PACHECO, 2015).

camada de entrada de dados, pelas camadas ocultas ou intermediárias e pela camada de saída, onde são gerados os resultados finais, de acordo com o processo descrito acima.

Essa arquitetura vai depender de cada tipo de problema a ser resolvido. No exemplo da Figura 10, tem-se uma rede *feedforward*, onde o fluxo das informações é em apenas uma direção, ou unidirecional.


Para os estudos de predição de mercado, o modelo mais adequado a ser usado é um modelo de rede neural recorrente (RNN). O motivo é que uma rede do tipo *feedforward*, não consegue tratar de uma maneira adequada problemas dinâmicos. Nas redes neurais recorrentes o fluxo de informação é bidirecional, com isso neurônios são capazes de realimentar neurônios de camadas inferiores, além dele mesmo, ou seja, é possível que neurônios da camada de saída realimentam neurônios da camada de entrada, produzindo um tipo de memória de curto prazo.

Figura 10 – Modelo de uma rede neural artificial.



Fonte: (VINICIUS, 2017).


Figura 11 – Modelo de rede *feedforward* e uma RNN.



Fonte: (PEKEL; KARA, 2017).

As RNNs podem produzir modelos de redes neurais mais complexas, mesmo com um número de parâmetros reduzidos. As realimentações e loops das camadas ocultas permitem o armazenamento de padrões (NEGREIROS, 2021).


Figura 12 – Representação de realimentação de uma célula de RNN em função do tempo.



Fonte: (OLAH, 2015).

As RNNs padrão têm a estrutura de loop da célula relativamente simples, com uma única camada de \tanh .

Figura 13 – Representação da estrutura de realimentação de uma célula de RNN padrão.




Fonte: (OLAH, 2015).

3.4.2.1 Redes LSTM

As redes LSTM foram propostas por (HOCHREITER; SCHMIDHUBER, 1997) e são uma melhoria no que tange o tratamento da memória de longo prazo das RNNs. As RNNs deveriam lidar com casos onde memórias de longo prazo são exigidas, mas na prática não é o que acontece. Se uma sequência for longa, as RNNs têm dificuldades de guardar informações para próximas etapas, ou transportar essas informações. De acordo com (MEDSKER; JAIN, 2001), esse problema ocorre devido ao problema da dissipação do gradiente, ou seja, a medida que a informação vai se propagando através da rede neural, o gradiente diminui se tornando muito pequeno ao ponto de não contribuir mais com o processo de aprendizagem. Para tratar esse problema, foram introduzidas as redes LSTM que são capazes de lidar e tratar problemas de curto e longo prazo. Diferentemente da RNN padrão, a estrutura de realimentação da rede LSTM conta com 4 camadas que interagem entre si, formando 3 *gates*, responsáveis pela filtragem dos dados importantes para o aprendizado da rede e contribuindo com a memória de longo prazo. Cada camada sigmóide pode assumir um valor binário de 0 ou 1, com 0 descartando todas as informações do canal e 1 mantendo todas as informações no canal (MOGHAR; HAMICHE, 2020).

Figura 14 – Representação da estrutura de realimentação de uma célula de rede LSTM.




Fonte: (OLAH, 2015).

Na LSTM se tem o “estado celular” representado pela linha horizontal que atravessa a parte superior do diagrama.

O estado celular percorre por toda a cadeia, com apenas algumas pequenas interações lineares. Desse modo, permite que o fluxo de informações percorra toda a estrutura. Através do estado celular consegue-se obter uma memória de longo prazo.


Figura 15 – Representação do estado celular de uma estrutura LSTM.



Fonte: (OLAH, 2015).


Além do estado celular, temos os 3 *gates* que são:

Forget Gate: Remove as informações inúteis no estado da célula. Este portão considera a entrada atual $X(t)$ e o valor da saída anterior $h(t-1)$.

Figura 16 – Representação do *Forget Gate* de uma estrutura LSTM.


Fonte: (OLAH, 2015).

Memory Gate: Adiciona informações úteis ao estado da célula. Primeiro, uma camada sigmóide seleciona os valores a serem lembrados. Em seguida, uma camada tanh variando entre $[-1,+1]$ cria um vetor de novos valores candidatos que podem ser adicionados ao estado.

Figura 17 – Representação do *Memory Gate* de uma estrutura LSTM.

Fonte: (OLAH, 2015).

Output Gate: decide qual será a saída de cada célula e a entrada para a próxima célula. O valor de saída será baseado no estado da célula ao longo da estrutura com os dados filtrados e adicionados mais recentes.

Figura 18 – Representação do *Output Gate* de uma estrutura LSTM.

Fonte: (OLAH, 2015).

3.5 Base de Dados

As bases de dados utilizadas neste trabalho foram obtidas do Yahoo Finance via API. Utilizou-se duas bases distintas: Bitcoin e índice NASDAQ Composite.

3.5.1 Bitcoin

De acordo com (ULRICH, 2017), o Bitcoin é uma moeda digital independente de uma autoridade central criada em 2008 por um programador, conhecido apenas pelo nome, Satoshi Nakamoto.

A criação do Bitcoin se tornou revolucionária, porque foi a primeira moeda que possibilitou que transações fossem feitas sem a necessidade de terceiros. Todas as transações de Bitcoin realizadas são registradas em uma espécie de registro público de transações, um grande banco de dados público chamado de *blockchain*. E cada transação passa por uma verificação nesse banco de dados, para garantir a integridade da mesma.

A base de dados do bitcoin utilizada possui frequência diária desde 2014 até o dia atual e oferece dados como: data, preço de abertura do período (*Open*), preço de fechamento do período (*Close*), preço mais alto atingido no período (*High*) e preço mais baixo atingido no período (*Low*). Além dos dados fornecidos pela API do Yahoo Finance, foram adicionados os dados de indicadores técnicos: SMA(20), EMA(25), MACD e RSI(28).

Para o treinamento da rede, foi usada cerca de 80% das amostras e as outras 20%, para validação.

Tabela 2 – Base de dados diária do Bitcoin de cerca de 8 anos.

	Open	High	Low	Close	SMA	EMA	MACD	RSI
Date								
2014-10-19	391.253998	393.938995	386.457001	389.545990	368.726001	384.530943	0.433399	41.111428
2014-10-20	389.230988	390.084015	378.252014	382.845001	368.521051	384.401255	-0.134491	40.259995
2014-10-21	382.420990	392.645996	380.834015	386.475006	368.664052	384.560774	0.165427	40.947051
2014-10-22	386.118011	388.575989	382.248993	383.157990	369.068352	384.452868	-0.111903	40.505606
2014-10-23	382.962006	385.048004	356.446991	358.416992	369.013602	382.450108	-2.076936	37.387809
...
2022-05-25	29653.134766	30157.785156	29384.949219	29562.361328	30609.625879	32042.146763	-214.302445	39.136490
2022-05-26	29564.777344	29834.160156	28261.906250	29267.224609	30270.941016	31828.691213	-221.361311	38.711259
2022-05-27	29251.140625	29346.943359	28326.613281	28627.574219	29927.222070	31582.451444	-255.359760	37.788443
2022-05-28	28622.625000	28814.900391	28554.566406	28814.900391	29665.003809	31369.562901	-220.773303	38.235606
2022-05-31	31734.792969	31774.306641	31496.826172	31685.613281	29734.436816	31393.874469	25.211996	44.567651

Fonte: Pelo autor.

3.5.2 NASDAQ Composite

A NASDAQ é considerada a segunda maior bolsa de valores dos Estados Unidos, com cerca de 3,3 mil ações negociadas, atrás apenas da bolsa de valores de Nova York (NYSE).

Desde a sua criação, a NASDAQ priorizou o uso de tecnologia avançada, e hoje abrange as maiores empresas do setor de tecnologia do mundo como Google, Apple, Amazon e Facebook.

De acordo com (REIS, 2018) o NASDAQ Composite é o índice ponderado pela capitalização de mercado das ações que integram a bolsa de valores NASDAQ, ou seja, o índice representa a rentabilidade dessas empresas.

O índice NASDAQ Composite é um dos mais importantes e reconhecidos dentro do mercado internacional. Além disso, de acordo com este índice, consegue-se entender a performance das empresas ligadas ao setor de tecnologia de modo geral.

A base de dados da NASDAQ Composite utilizada neste trabalho possui frequência diária desde 2010 e oferece os mesmos dados que foram citados na base de dados do Bitcoin. Posteriormente, os mesmos dados de indicadores foram acrescentados a esta base de dados. Para treinamento da rede LSTM foi usado cerca de 80% das amostras e as restantes 20% foram empregadas para validação do modelo.

Tabela 3 – Base de dados diária da NASDAQ de cerca de 12 anos.

	Open	High	Low	Close	SMA	EMA	MACD	RSI
Date								
2010-04-20	2492.719971	2501.250000	2480.699951	2500.310059	2440.829016	2429.202288	6.145116	64.950475
2010-04-21	2506.610107	2510.500000	2490.189941	2504.610107	2445.297522	2435.002890	6.015439	65.330962
2010-04-22	2483.520020	2521.020020	2468.260010	2519.070068	2451.313025	2441.469596	6.706214	66.595551
2010-04-23	2514.850098	2530.149902	2507.600098	2530.149902	2457.950024	2448.291158	7.074213	67.536495
2010-04-26	2529.850098	2535.280029	2521.510010	2522.949951	2464.341028	2454.034142	5.955687	66.278376
...
2022-05-23	11396.280273	11552.070312	11304.559570	11535.269531	11997.889990	12165.738314	-54.484956	40.241685
2022-05-24	11326.440430	11351.610352	11092.480469	11264.450195	11936.575488	12096.408458	-71.897628	38.655139
2022-05-25	11225.030273	11511.900391	11211.849609	11434.740234	11883.866016	12045.510903	-52.782650	40.192708
2022-05-26	11409.839844	11796.969727	11406.160156	11740.650391	11827.322021	12022.060094	-24.319357	42.860733
2022-05-27	11869.690430	12131.660156	11856.820312	12131.129883	11817.146533	12030.450078	8.700724	46.046778

Fonte: Pelo autor.

4 Resultados

Da revisão de literatura, percebeu-se que os trabalhos da área de predição de mercado financeiro, apresentam bons resultados empregando modelos de redes neurais recorrentes do tipo LSTM. No contexto de predição de preços de ativos do mercado financeiro, utilizar a rede LSTM na predição, torna possível ter acesso a valores passados para realizar previsões futuras. Este modelo foi adequado para um problema de regressão linear de mercado, onde se quer prever a movimentação futura de acordo com a movimentação passada.

O trabalho conta com 3 cenários de predição, na qual o primeiro cenário é um modelo univariado que utiliza a base de dados do Bitcoin, o segundo e o terceiro cenário são modelos multivariado, com 8 variáveis de entrada cada um. Além disso, o segundo cenário também utiliza a base de dados do Bitcoin e o terceiro cenário utiliza a base de dados do índice NASDAQ composite.

4.1 Primeiro Cenário


O primeiro cenário constitui de um modelo univariado, que emprega o preço de fechamento. Na análise, foi utilizada a base de dados do Bitcoin de 5 anos (2017/2021). A tabela 4 apresenta as principais configurações do modelo. Durante as simulações foram testadas janelas de dados considerando o preço de fechamento de 90 e 10 dias anteriores para estimar o preço de fechamento seguinte.

Tabela 4 – Parâmetros da rede LSTM - primeiro cenário.

Camada de Entrada
1 variável janela - 90 e 10 dias
Camada Oculta
2 LSTM - 50 neurônios
Camada de Saída
1 Dense - 1 neurônio - função de ativação linear
Compilador
Otimizador - Adam Função de Custo - Erro Quadrático Médio Épocas - 196 e 500 <i>Batch Size</i> - 50


Fonte: Pelo autor.

Figura 19 – Modelo de predição com dados de 5 anos (2017/2021) do Bitcoin usando uma janela de 90 dias.



Fonte: Pelo autor.

Figura 20 – Modelo de predição de 05-21 a 12-21 com dados de 5 anos (2017/2021) do Bitcoin usando uma janela de 90 dias.



Fonte: Pelo autor.

Como o intuito do modelo é aplicar a predição para o mercado de opções binárias, o importante para esse mercado é conseguir prever a direção da variação. A fim de saber como se comportaria essa predição no mercado binário, foi feita uma análise de direção da variação do preço diária dos dados observados em relação aos dados previstos. Caso o preço de fechamento “i” for maior que o preço de fechamento “i-1”, a variação foi positiva,

logo o ativo subiu de preço, caso contrário, o ativo caiu de preço. Caso não tenha variação no preço a amostra é desconsiderada.

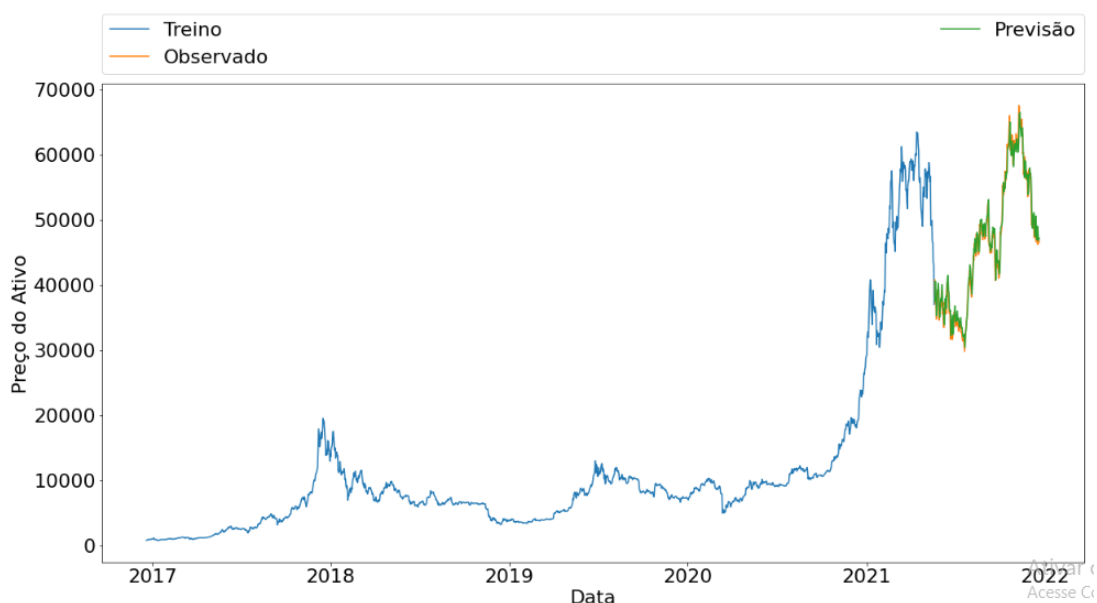
Tabela 5 – Taxa de assertividade no mercado de opções binárias - janela de 90 dias e 196 épocas.

Ação	Valores
Acertos	94
Erros	116
Taxa de assertividade	44.76%

Fonte: Pelo autor.

Modelo de predição com tamanho da janela 10 e 500 épocas.

Figura 21 – Modelo de predição com dados de 5 anos (2017/2021) do Bitcoin usando uma janela de 10 dias.



Fonte: Pelo autor.

Tabela 6 – Taxa de assertividade no mercado de opções binárias - janela de 10 dias e 500 épocas.

Ação	Valores
Acertos	95
Erros	115
Taxa de assertividade	45.24%

Fonte: Pelo autor.

Pode-se perceber que a curva de previsão do gráfico da figura 22 do segundo modelo é um pouco melhor em relação a curva de previsão do gráfico da figura 20 do primeiro

modelo. Além disso, a taxa de assertividade também foi ligeiramente superior à do primeiro modelo. Entretanto, ambos não tiveram uma boa taxa de assertividade se considerar o contexto do mercado de opções binárias.

Figura 22 – Modelo de predição de 06-21 a 12-21 com dados de 5 anos (2017/2021) do Bitcoin usando uma janela de 10 dias.



Fonte: Pelo autor.

4.2 Segundo Cenário

O segundo cenário, também utilizando a base de dados do Bitcoin, foi um modelo multivariado utilizando 8 (oito) variáveis de entrada: preço de abertura do período, preço de fechamento do período, preço mais alto atingido no período, preço mais baixo atingido no período, SMA(20), EMA(25), MACD e RSI(28).

Os parâmetros que foram os melhores resultados estão destacados em negrito na tabela 7.


Além destes parâmetros, também foram testados modelos variando o tamanho da base de dados. Testou-se um modelo com o tamanho da base de 2780 dias e outro modelo com uma base de dados menor e considerando os dados mais atuais de 1500 dias.

Tabela 7 – Parâmetros da rede LSTM - segundo cenário.

Camada de Entrada
8 variáveis janela - 2; 10; 50 ; 70; 100; 150; 200 dias
Camada Oculta
1; 2 ; 3 LSTM - 100; 150; 200; 250; 300; 350; 400 ; 450; 500 neurônios 1 Dens - 5 ; 50; 100; 200 neurônios - função de ativação relu ; sigmoid; tanh; linear
Camada de Saída
1 Dens - 1 neurônio - função de ativação linear ; sigmoid; tanh
Compilador
Otimizador - Adam ; sgd; rmsprop Função de Custo - Erro Quadrático Médio Épocas - 50; 100 ; 200; 300; 500 <i>Batch Size</i> - 25 ; 50; 100; 150; 200

Fonte: Pelo autor.


Figura 23 – Modelo de predição com dados dos últimos 2780 dias do Bitcoin usando uma janela de 50 dias.



Fonte: Pelo autor.

Os resultados de predição do valor de fechamento do preço no período do modelo que utiliza dados dos últimos 2780 dias estão apresentados na tabela 8.

Figura 24 – Modelo de predição de 11-20 a 05-22 com dados dos últimos 2780 dias do Bitcoin usando uma janela de 50 dias.



Fonte: Pelo autor.

Tabela 8 – Resultados de predição do valor de fechamento do modelo com dados dos últimos 2780 dias - segundo cenário.

Erro médio absoluto (MAE): 3718.91 U\$
Percentagem de erro médio absoluto (MAPE): 8.0 %
Mediana Percentagem erro absoluto (MDAPE): 8.12 %

Fonte: Pelo autor.

Tabela 9 – Taxa de assertividade no mercado de opções binárias - dados dos últimos 2780 dias e janela de 50 dias.

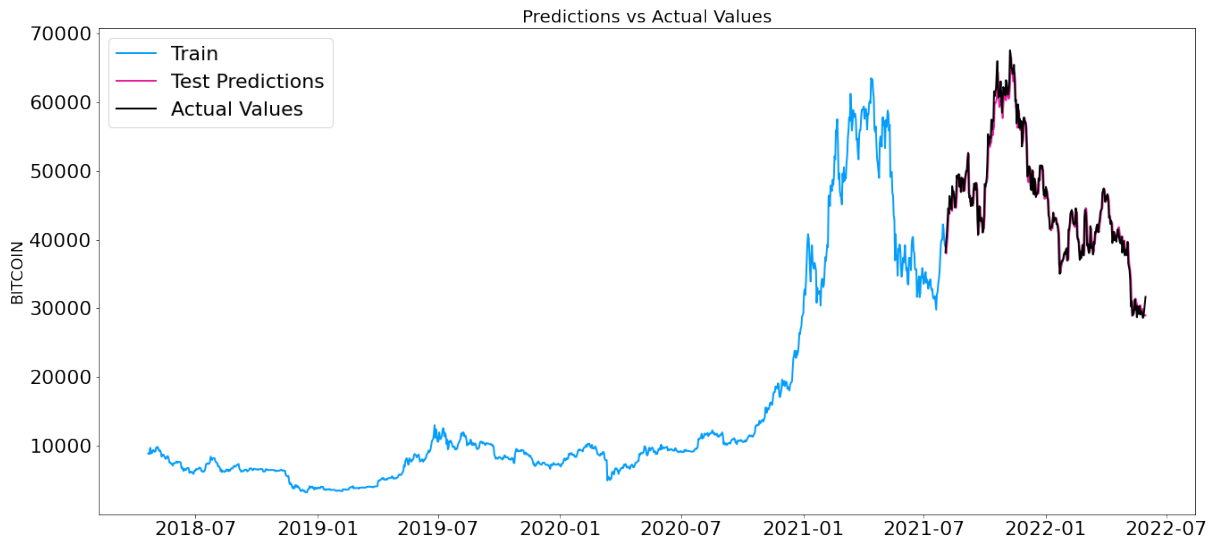
Ação	Valores
Acertos	268
Erros	288
Taxa de assertividade	48.2%

Fonte: Pelo autor.

Já o modelo treinado com os dados dos últimos 1500 dias, apresentou melhores resultados. Isso sugere que movimentações passadas e dados totalmente distintos do cenário atual, podem atrapalhar o treinamento da rede.

Pode-se observar nos gráficos das Figuras 25 e 26, que a predição segue valores mais próximos dos dados observados quando comparados com os gráficos das Figuras 23 e 24.

Figura 25 – Modelo de predição com dados dos últimos 1500 dias do Bitcoin usando uma janela de 50 dias.



Fonte: Pelo autor.

Figura 26 – Modelo de predição de 08-21 a 06-22 com dados dos últimos 1500 dias do Bitcoin usando uma janela de 50 dias.



Fonte: Pelo autor.

Tabela 10 – Resultados de predição do valor de fechamento do modelo com dados dos últimos 1500 dias - segundo cenário.

Erro médio absoluto (MAE): 1224.16 U\$
Percentagem de erro médio absoluto (MAPE): 2.69 %
Mediana Percentagem erro absoluto (MDAPE): 1.91 %

Fonte: Pelo autor.

Quando aplicada à predição para o modelo do mercado de opções binárias, se obteve os resultados:

Tabela 11 – Taxa de assertividade no mercado de opções binárias - dados dos últimos 1500 dias e janela de 50 dias.

Ação	Valores
Acertos	164
Erros	136
Taxa de assertividade	54.6%

Fonte: Pelo autor.

É possível perceber que o modelo em que a predição segue valores mais próximos dos dados observados e conseqüentemente possui dados de erro médio absoluto (informações apresentadas nas tabelas 8 e 10) menor, possui uma taxa de assertividade superior no mercado de opções binárias.

4.3 Terceiro Cenário

O terceiro cenário empregou a base de dados de índice NASDAQ Composite, também foi um modelo multivariado utilizando as mesmas 8 (oito) variáveis de entrada do segundo cenário.

Foram testados todos os parâmetros da rede LSTM e do compilador, listados na Tabela 12. Em negrito estão os valores dos parâmetros adotados na melhor configuração da rede neural obtida.

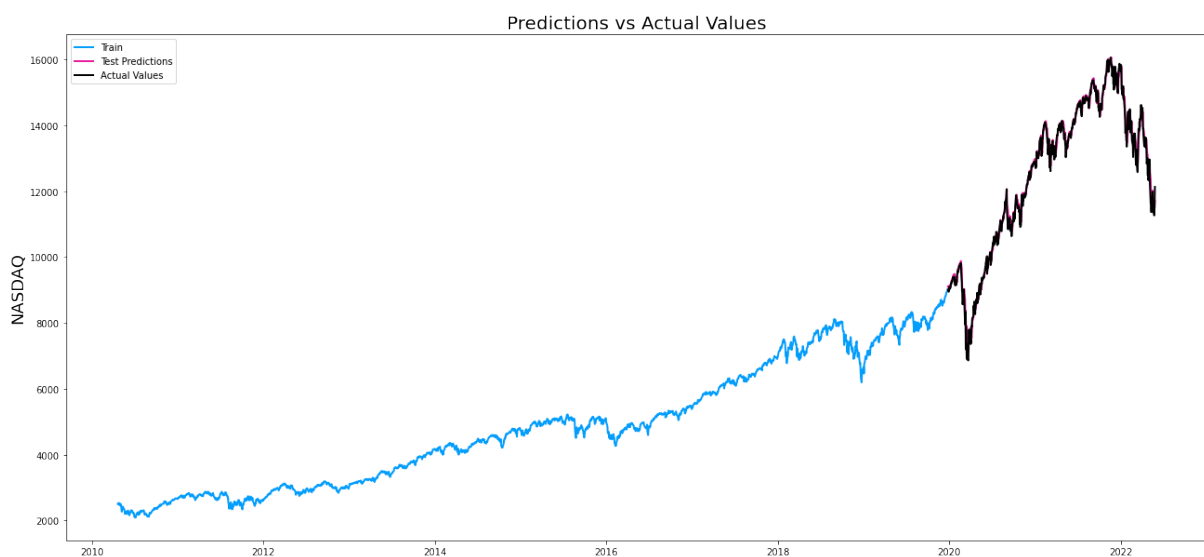
Tabela 12 – Parâmetros da rede LSTM - terceiro cenário.

Camada de Entrada
8 variáveis janela - 2;10; 50 ;70;100;150;200 dias
Camada Oculta
1; 2 ;3 LSTM - 100;150;200;250;300;350; 400 ;450;500 neurônios 1 Dens - 5 ;50;100;200 neurônios - função de ativação linear ;sigmoid;tanh;relu
Camada de Saída
1 Dens - 1 neurônio - função de ativação linear ; sigmoid; tanh
Compilador
Otimizador - Adam ; sgd; rmsprop Função de Custo - Erro Quadrático Médio Épocas - 50 ; 100; 200; 300; 500 <i>Batch Size</i> - 25 ; 50; 100; 150; 200

Fonte: Pelo autor.


O Terceiro cenário tem o modelo de configuração da rede bem próximo ao segundo cenário, mudando a função de ativação da camada Dens oculta para Linear e o número de épocas do compilador para 50. Além destes parâmetros, foram testados modelos com a base de dados menor, com dados mais recentes. Nesse caso não se obteve diferenças satisfatórias nos resultados.

Figura 27 – Modelo de predição com dados dos últimos 12 anos do índice NASDAQ Composite usando uma janela de 50 dias.



Fonte: Pelo autor.

Figura 28 – Modelo de predição de 01-20 a 06-22 com dados dos últimos 12 anos do índice NASDAQ Composite usando uma janela de 50 dias.



Fonte: Pelo autor.

Os resultados de predição do valor de fechamento do preço no período do modelo estão apresentados na Tabela 13.

Tabela 13 – Resultados de predição do valor de fechamento do modelo com dados dos últimos 12 anos - terceiro cenário.

Erro médio absoluto (MAE): 196.64 U\$
Percentagem de erro médio absoluto (MAPE): 1.66 %
Mediana Percentagem erro absoluto (MDAPE): 1.25 %

Fonte: Pelo autor.

Quando aplicada à predição para o modelo do mercado de opções binárias, se obteve os resultados:

Tabela 14 – Taxa de assertividade no mercado de opções binárias - dados dos últimos 12 anos e janela de 50 dias.

Ação	Valores
Acertos	357
Erros	258
Taxa de assertividade	58.05%

Fonte: Pelo autor.

Comparando e analisando os resultados dos modelos multivariados, é interessante ressaltar que o terceiro cenário obteve as menores porcentagens de erro na predição do valor de fechamento no período. Além disso, foi a melhor taxa de assertividade no mercado de opções binárias dentre todos os cenários.

4.4 Discussões

Temos 3 cenários e resultados diferentes. O primeiro cenário, modelo univariado, obteve resultado abaixo dos 50% de assertividade, quando aplicado ao mercado de opções binárias, conseqüentemente um modelo que daria prejuízo aos investidores. O segundo e o terceiro cenário, ambos modelos multivariados e ambos modelos com assertividade acima dos 50% quando aplicados ao modelo de operação de opções binárias, mas o que não se traduz, necessariamente, em um modelo lucrativo.

Considerando um modelo de operação onde se opere com mãos fixas R\$ 100,00 e *payout* de 90% com uma taxa de assertividade de 45%, 54% e 58%:

Tabela 15 – Avaliação do retorno de operação seguindo o modelo aplicado ao mercado de opções binárias - primeiro cenário.

Nº Entradas	Valor da Entrada	Retorno da Entrada	Retorno total
45 acertos	R\$100,00	R\$90,00	R\$4050,00
55 erros	R\$100,00	-R\$100,00	-R\$5500,00
		Total	-R\$1450,00

Fonte: Pelo autor.

Tabela 16 – Avaliação do retorno de operação seguindo o modelo aplicado ao mercado de opções binárias - segundo cenário.

Nº Entradas	Valor da Entrada	Retorno da Entrada	Retorno total
54 acertos	R\$100,00	R\$90,00	R\$4860,00
46 erros	R\$100,00	-R\$100,00	-R\$4600,00
		Total	R\$260,00

Fonte: Pelo autor.

Tabela 17 – Avaliação do retorno de operação seguindo o modelo aplicado ao mercado de opções binárias - terceiro cenário.

Nº Entradas	Valor da Entrada	Retorno da Entrada	Retorno total
58 acertos	R\$100,00	R\$90,00	R\$5220,00
42 erros	R\$100,00	-R\$100,00	-R\$4200,00
		Total	R\$1020,00

Fonte: Pelo autor.

Pode-se perceber que o segundo e terceiro cenário foram lucrativos para o investidor com o *payout* de 90%, mas o mercado de opções binárias é variável, e o *payout* muda ao

decorrer do dia e dos ativos. Com o *payout* 80%, o segundo cenário passaria a ser um modelo que geraria perda ao investidor, veja:

Tabela 18 – Avaliação do retorno de operação seguindo o modelo aplicado ao mercado de opções binárias com *payout* de 80% - segundo cenário.

Nº Entradas	Valor da Entrada	Retorno da Entrada	Retorno total
54 acertos	R\$100,00	R\$80,00	R\$4320,00
46 erros	R\$100,00	-R\$100,00	-R\$4600,00
		Total	-R\$280,00

Fonte: Pelo autor.

A importância de se ter um modelo com assertividade maior que 50%, é que se torna possível realizar uma análise para saber quanto deve ser a taxa de *payout* para que o modelo seja lucrativo, tendo em vista que a taxa de *payout* em alguns momentos pode chegar em 98%.

O modelo com uma assertividade abaixo dos 50% nunca será lucrativo, utilizando um operacional com os valores de entrada fixo, sabendo que a taxa de *payout* nunca será acima dos 100%. Para conseguir lucros com uma assertividade baixa, estratégias como o Martingale, por exemplo, podem ser aplicadas para contornar esse problema, mas é importante ressaltar que é uma estratégia de alto risco, visto que a perda pode ser exponencial. Combinando um modelo que me garanta uma assertividade acima dos 50% com o Martingale, é possível diminuir o risco da estratégia e ainda alavancar os lucros operacionais.

5 Conclusão

No primeiro cenário, se tinha um modelo univariado, usando base de dados do Bitcoin e considerando apenas o valor do fechamento do período. Apesar do modelo ser capaz de acompanhar a curva do andamento real do valor de fechamento, o desempenho do modelo no mercado de opções binárias foi abaixo ($<50\%$), ou seja, o modelo deste primeiro cenário de avaliação daria prejuízo ao investidor, levando em consideração entradas de valores fixos.

No segundo cenário foi avaliado um modelo multivariado com 8 variáveis de entrada: *Open*, *Close*, *High*, *Low*, SMA(20), EMA(25), MACD e RSI(28), também com a base de dados do Bitcoin. Este modelo apresentou um desempenho interessante empregando janelas temporais menores, com menor erro absoluto do valor de fechamento previsto e maior taxa de assertividade quando aplicado ao mercado de opções binárias. Em sua melhor configuração, o segundo cenário apresentou uma assertividade de 54,6% que pode ser lucrativo ao investidor numa análise de aplicação com entradas de valores fixos e *payout* de 90%.

O terceiro cenário empregou um modelo de rede neural recorrente LSTM com 8 variáveis de entrada, semelhante ao do segundo cenário, aplicado à base de dados de índice NASDAQ Composite. Não foram observadas diferenças significativas quando utilizou-se janelas menores, que consideram somente os dados mais recentes para treinamento da rede. Tanto considerando o aspecto do valor de erro absoluto do valor de fechamento previsto, quanto para o valor de assertividade obtido aplicando a predição da rede no mercado de opções binárias. Nesse cenário, foi possível atingir uma assertividade de 58% que em um cenário de mercado com *payout* de 90% é um modelo que seria lucrativo ao investidor, levando em consideração entradas de valores fixos.

Ambos os cenários com assertividade acima dos 50% podem ser ainda mais lucrativos se combinados com estratégias como Martingale, por exemplo, e com garantia de uma assertividade de 55% ou 58%, o risco da estratégia diminui, tendo em vista que a perda utilizando essa estratégia é exponencial.

Portanto, os resultados apresentados foram satisfatórios, atendendo às expectativas e objetivos do trabalho.

5.1 Trabalho Futuros

Para trabalhos futuros sugere-se treinamento de modelos utilizando base de dados com frequência de dados de tempo menor, 5 minutos, 15 minutos, 30 minutos e 1 hora.

Além disso, uma abordagem interessante seria a previsão de janelas de tempo a frente, por exemplo, atualmente nossa base de dados utiliza uma frequência de dados diários, a previsão de 7 períodos acarretaria na previsão de dados de 1 semana.

Um cenário comum no *Machine Learning* é o *overfitting*, que é quando o modelo apresenta um ótimo desempenho com treinamento feito com os dados utilizados, mas quando o modelo é exposto a um novo conjunto de dados o desempenho é afetado. Caso o modelo se encaixe nesse cenário, em algum momento que o mercado apresentar novas movimentações, o modelo irá perder desempenho. Portanto, para trabalhos futuros, é um ponto importante a ser levantado.

Por fim, a construção de um software que automatize as entradas no mercado de opções binárias utilizando o modelo de predição implementado.

Referências

- ALPAYDIN, E. *Introduction to Machine Learning*. [S.l.]: The MIT Press, 2010. Citado na página 25.
- BRITO, O. *Mercado financeiro*. [S.l.]: Saraiva Educação SA, 2019. Citado na página 17.
- CHEN, J. *Exponential Moving Average (EMA)*. 2022. <<https://www.investopedia.com/terms/e/ema.asp>>. Acessado em 23/05/2022. Citado na página 23.
- DEEPAK, R. S.; UDAY, S. I.; MALATHI, D. Machine learning approach in stock market prediction. *International Journal of Pure and Applied Mathematics*, v. 115, n. 8, p. 71–77, 2017. Citado na página 15.
- DESCUBRA o que são suportes e resistências e melhore seus trades. 2020. <<https://smarttbot.com/trader/o-que-sao-suportes-e-resistencias/>>. Acessado em 24/05/2022. Citado na página 19.
- DOOB, J. L. What is a martingale? *The American Mathematical Monthly*, Taylor & Francis, v. 78, n. 5, p. 451–463, 1971. Citado na página 24.
- FERNANDO, J. *Moving Average Convergence Divergence (MACD)*. 2022. <<https://www.investopedia.com/terms/m/macd.asp>>. Acessado em 23/05/2022. Citado na página 23.
- FERNANDO, J. *Relative Strength Index (RSI)*. 2022. <<https://www.investopedia.com/terms/r/rsi.asp>>. Acessado em 23/05/2022. Citado na página 24.
- GRIMES, A. *The art and science of technical analysis: market structure, price action, and trading strategies*. [S.l.]: John Wiley & Sons, 2012. v. 544. Citado 2 vezes nas páginas 13 e 17.
- HAYES, A. *Simple Moving Average (SMA)*. 2022. <<https://www.investopedia.com/terms/s/sma.asp>>. Acessado em 23/05/2022. Citado na página 23.
- HOCHREITER, S.; SCHMIDHUBER, J. Long Short-Term Memory. *Neural Computation*, v. 9, n. 8, p. 1735–1780, 11 1997. ISSN 0899-7667. Disponível em: <<https://doi.org/10.1162/neco.1997.9.8.1735>>. Citado na página 30.
- HULL, J. C. *Opções, futuros e outros derivativos*. [S.l.]: Bookman Editora, 2016. Citado na página 13.
- LEMOS, F. Análise técnica dos mercados financeiros: um guia completo e definitivo dos métodos de negociação de ativos. *Saraiva Educação*. São Paulo, 2015. Citado 4 vezes nas páginas 18, 19, 21 e 22.
- LIMA, J. \$ 778,75 em um dia investindo no mercado financeiro com uma Deep Neural Network. 2017. Disponível em: <<https://medium.com/@joaogabriellima/778-75-em-um-dia-investindo-no-mercado-financieiro-com-uma-deep-neural-network-2b5a917e31d4>>. Acessado em 11/11/2021. Citado na página 15.

- MEDSKER, L. R.; JAIN, L. Recurrent neural networks. *Design and Applications*, v. 5, p. 64–67, 2001. Citado na página 30.
- MOGHAR, A.; HAMICHE, M. Stock market prediction using lstm recurrent neural network. *Procedia Computer Science*, Elsevier, v. 170, p. 1168–1173, 2020. Citado 2 vezes nas páginas 16 e 30.
- MÜLLER, F. *Stock Market Prediction using Multivariate Time Series and Recurrent Neural Networks in Python*. 2020. Disponível em: <<https://www.relataly.com/stock-market-prediction-using-multivariate-time-series-in-python/1815/#h-prerequisites>>. Acessado em 01/04/2022. Citado na página 16.
- MÜLLER, F. *Stock Market Prediction – Adjusting Time Series Prediction Intervals in Python*. 2020. Disponível em: <<https://www.relataly.com/changing-prediction-intervals-for-time-series-forecasting-models/169/>>. Acessado em 01/04/2022. Citado na página 16.
- NABIPOUR, M. et al. Predicting stock market trends using machine learning and deep learning algorithms via continuous and binary data; a comparative analysis. *IEEE Access*, IEEE, v. 8, p. 150199–150212, 2020. Citado 2 vezes nas páginas 15 e 22.
- NEGREIROS, S. *Ciência de Dados - Redes Neurais Artificiais e Deep Learning*. [S.l.: s.n.], 2021. Citado 3 vezes nas páginas 25, 27 e 29.
- NEURÔNIOS. 2022. <<https://www.coladaweb.com/biologia/histologia/neuronios>>. Acessado em 24/05/2022. Citado na página 28.
- OLAH, C. *Understanding LSTM Networks*. 2015. <<http://colah.github.io/posts/2015-08-Understanding-LSTMs/>>. Acessado em 28/05/2022. Citado 5 vezes nas páginas 29, 30, 31, 32 e 33.
- PACHECO, A. *Introdução a Redes Neurais Artificiais*. 2015. <<http://computacaointeligente.com.br/algoritmos/conceitos/redes-neurais-artificiais/>>. Acessado em 24/05/2022. Citado na página 28.
- PAPÉL de Parede. 2022. <<https://wallhere.com/pt/wallpaper/>>. Acessado em 24/05/2022. Citado na página 27.
- PEKEL, E.; KARA, S. S. A comprehensive review for artificial neural network application to public transportation. *Sigma Journal of Engineering and Natural Sciences*, v. 35, n. 1, p. 157–179, 2017. Citado na página 29.
- PIAZZA, M. O melhor da análise técnica de ações. *São Paulo: Saraiva*, 2010. Citado na página 18.
- PINHEIRO, J. L. Mercado de capitais, 3ª. *Edição. Editora*, 2005. Citado na página 18.
- REIS, T. *Nasdaq Composite: um dos principais índices de mercado dos EUA*. 2018. <<https://www.suno.com.br/artigos/nasdaq-composite/>>. Acessado em 29/05/2022. Citado na página 34.
- SHYNKEVICH, Y. et al. Forecasting price movements using technical indicators: Investigating the impact of varying input window length. *Neurocomputing*, Elsevier, v. 264, p. 71–88, 2017. Citado na página 15.

- SILVA, L. *Tipos de aprendizado de máquina e algumas aplicações*. 2021. <<http://www2.decom.ufop.br/terralab/tipos-de-aprendizado-de-maquina-e-algumas-aplicacoes/>>. Acessado em 24/05/2022. Citado na página 26.
- TENDÊNCIAS, linha de tendência e canal de tendência. 2010. <<http://www.investpedia.com.br/artigo/Tendencias+linha+de+tendencia+e+canal+de+tendencia.aspx>>. Acessado em 24/05/2022. Citado 3 vezes nas páginas 20, 21 e 22.
- THAWORNWONG, S.; DAGLI, C. H.; ENKE, D. L. Using neural networks and technical analysis indicators for predicting stock trends. American Society of Mechanical Engineers (ASME), 2001. Citado na página 22.
- ULRICH, F. *Bitcoin: a moeda na era digital*. [S.l.]: LVM Editora, 2017. Citado na página 33.
- VINICIUS. *Redes Neurais Artificiais*. 2017. <<https://www.monolitonimbus.com.br/redes-neurais-artificiais/>>. Acessado em 04/06/2022. Citado na página 29.
- WILLIAMS, D. *Probability with martingales*. [S.l.]: Cambridge university press, 1991. Citado na página 13.
- YANG, C.; ZHAI, J.; TAO, G. Deep learning for price movement prediction using convolutional neural network and long short-term memory. *Mathematical Problems in Engineering*, Hindawi, v. 2020, 2020. Citado na página 15.
- ZOU, Z.; QU, Z. Using lstm in stock prediction and quantitative trading. *CS230: Deep Learning, Winter*, 2020. Citado na página 16.