



APRENDIZAGEM PROFUNDA NA PREDIÇÃO DE PREÇO DO BITCOIN

BITCOIN PRICE PREDICTION USING DEEP LEARNING

ÁREA TEMÁTICA: 6 FINANÇAS

Caio Eduardo Kikuti, UEM, Brasil, ra103235@uem.br

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

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

Resumo

As formas de investimento e acúmulo de bens vem se diversificando nas últimas décadas, como é o caso do mercado de criptomoedas. Este mercado cresceu na última década e seu principal representante é o bitcoin, cuja valorização atingiu 1300% no ano de 2017. Entretanto, Dada a volatilidade no preço da moeda digital em um curto espaço de tempo, análises técnicas e fundamentalistas passaram a compor as estratégias de compra e venda para investidores do bitcoin. A análise técnica é pautada na análise gráfica do preço de determinado ativo, comumente são utilizados inúmeros indicadores estatísticos que auxiliam na descoberta de momentos de compra, venda e manutenção do ativo. Além dos indicadores técnicos, técnicas computacionais como aprendizado profundo, também podem auxiliar na predição de tendências de compra e venda de ativos visando um maior lucro. Neste contexto, este trabalho visa apresentar dados de simulações e uma análise comparativa entre modelos que utilizam análise técnica, aprendizado profundo e ambas as técnicas na predição de tendências de compra e venda do bitcoin. Os resultados obtidos nos experimentos apontam que o modelo híbrido apresenta maior desempenho do que modelos que utilizam apenas indicadores técnicos ou aprendizado profundo.

Palavras chave: Aprendizagem profunda, Bitcoin, Análise Técnica, Mercado Financeiro.

Abstract

The forms of investment and accumulation of assets have been diversifying in recent decades, as is the case with the cryptocurrency market. This market has grown in the last decade and its main representative is bitcoin, whose appreciation reached 1300% in 2017. However, given the volatility in the price of digital currency in a short period of time, technical and fundamental analyzes began to compose the strategies buying and selling for bitcoin investors. Technical analysis is based on the graphical analysis of the price of a particular asset, commonly used innumerable statistical indicators that help in the discovery of moments of purchase, sale and maintenance of the asset. In addition to technical indicators, computational techniques such as deep learning can also help in predicting buying and selling trends for assets aiming at greater profit. In this context, this work aims to present simulation data and a comparative analysis between models that use technical analysis, deep learning and both techniques in the prediction of bitcoin buying and selling trends. The results obtained in the experiments indicate that the hybrid model presents higher performance than models that use only technical indicators or deep learning.

Keywords: Deep Learning, Bitcoin, Technical Analysis, Financial Market.

1. INTRODUÇÃO

No ano de 2008/2009, o *Bitcoin* surgiu no mercado como uma moeda totalmente digital e descentralizada utilizando a tecnologia *peer-to-peer* ou P2P, possibilitando transações financeiras sem o intermédio de um terceiro. Com a ascensão das criptomoedas, em especial o

Bitcoin, tornou-se usual a comercialização de moedas digitais, o que aumentou o interesse dos investidores em conhecerem e investirem nesse mercado.

Em 2017, o *Bitcoin* atingiu seu ápice, valorizando cerca de 1300%. Contudo, é importante destacar a alta volatilidade que o preço do *Bitcoin* apresenta em períodos relativamente curtos de tempo. Essa característica influi na forma em que os investimentos nesse ativo podem ser feitos. Para este tipo de investimento é necessário destacar a relevância da análise de risco financeiro e predição de tendências, as quais são estudadas pelas áreas de economia, contabilidade e finanças desde o século passado. Tais estudos tem se intensificado dado o crescimento, fraudes e crises dos mercados financeiros ao redor do mundo.

Alguns destes estudos tem como foco a análise técnica, para realizar a predição de momentos adequados para compra, venda e manutenção de *Bitcoins*. Segundo Vidotto, Migliato, Zambon (2009) a análise técnica baseia-se no princípio de que os preços de um ativo, em determinada data futura, são influenciados pelos preços passados, sendo possível, então, prever a tendência de movimento desses preços em determinado período de tempo.

Por outro lado, outros estudos vêm aplicando diversos algoritmos, métodos, simulações e técnicas computacionais em aprendizagem de máquina (AM) para a criação de modelos de reconhecimento de padrões e tendências em mercados de criptomoedas (Grzelak & Oosterlee, 2011). Dentro da área de AM, as técnicas de aprendizagem profunda (*deep learning*) ganharam destaque nos últimos anos para a criação desses modelos. De acordo com Deng e Yu (2014) e Shimabukuro, Galegale, Okano e Langhi (2020) a aprendizagem profunda encontra-se na interseção entre as pesquisas na área de redes neurais, inteligência artificial, modelagem gráfica, otimização, reconhecimento de padrões e processamento de sinais.

Trabalhos recentes abordam temática que alia predição do preço do *Bitcoin* e utilização de técnicas de aprendizado máquina. Phaladisailoed e Numnonda (2018), por exemplo, utilizaram bibliotecas *open-source* como *Tensorflow* e *Keras*, e compararam a eficiência e a acurácia de várias modelagens envolvendo aprendizagem profunda. A grande maioria dos estudos publicados nessa área dão ênfase à comparação de técnicas de aprendizado de máquina. Dhage e Rane (2019) realiza uma comparação entre sete modelos implementados para a predição do preço do *Bitcoin*; nesse trabalho, o modelo conhecido como NARXS (*Nonlinear Auto-Regressive with Exogenous Input Model*) demonstrou o melhor resultado. Já em Aggarwal, Gupta, Garg e Goel (2019) estudaram os impactos dos fatores socioeconômicos na predição do preço do *Bitcoin*; para a realização desse estudo três diferentes abordagens de aprendizado de máquina profundo foram utilizadas: CNN (*Convolutional Neural Network*), LSTM (*Long short Term Memory*) e GRU (*Gated Recurrent*), sendo que o modelo LSTM apresentou os melhores resultados na predição do valor do *Bitcoin* quando comparado aos outros dois modelos.

Como problema de pesquisa é importante ressaltar que diversos estudos sobre LSTM não utilizam indicadores técnicos como subsídio para sua modelagem, apenas informações básicas como preço de abertura, preço de fechamento, volume, mínimo e máximo. Desse modo, este trabalho tem como objetivo realizar uma análise de desempenho de indicadores técnicos e aprendizado profundo na predição de momentos de compra, venda ou manutenção de *bitcoins*. A partir do objetivo, o presente trabalho desenvolveu modelos utilizando apenas indicadores técnicos, visando o aprendizado profundo utilizando LSTM (*Long Short Term Memory*), e

ambas as abordagens, de modo a demonstrar que os indicadores técnicos podem contribuir em um modelo de aprendizado profundo.

2. FUNDAMENTAÇÃO TEÓRICA

2.1 BITCOIN CRIPTOMOEDAS E A TECNOLOGIA BLOCKCHAIN

Desenvolvida por Satoshi Nakamoto no ano de 2008 o *Bitcoin* atraiu atenção significativa em relação às demais já desenvolvidas. Segundo a pesquisa de Tapscott e Tapscott (2016) muitos pesquisadores acreditam que a utilização das criptomoedas possa causar um impacto severo no sistema de finanças global.

Visando ser uma moeda totalmente digital, o *Bitcoin* torna-se atrativo por não ser autorregulada e ser descentralizada, funcionando por meio de um sistema conhecido como *peer-to-peer* (P2P). P2P é uma arquitetura de sistema que conecta duas ou mais máquinas que compartilham informações e serviços sem a necessidade de um servidor central. Dessa maneira as transações envolvendo a criptomoeda são de acesso comum a todos os usuários, ou seja, qualquer pessoa que possua um computador pode legalmente verificar as transações feitas com o *Bitcoin*. Segundo Velankar, Valecha e Maji (2018), uma vez adquiridos, os *Bitcoins* ficam armazenados em uma carteira virtual, que funciona basicamente como uma conta bancária virtual.

Existem várias possibilidades e fins para o uso do *Bitcoin*. Ao olhar de muitos investidores, essa criptomoeda pode ser uma boa alternativa para o que se chama de reserva de valor, pois a quantidade de moeda que pode circular no mercado é finita, cerca de 21 milhões. Uma vez que o *Bitcoin* não está atrelado a nenhum tipo de governo ou instituição, a inflação é positiva para quem possui essa moeda, e dado que se trata de um bem finito, em certo momento a única maneira de obtenção desse bem será por meio da compra de quem já o possui.

Outro fim para o *Bitcoin* é a especulação. Tratando-se de ativos financeiros, a especulação é basicamente a compra e venda de ativos, comumente em curto ou médio prazo, visando lucro. Essa abordagem geralmente envolve a análise técnica de gráficos e indicadores estatísticos. Com o *Bitcoin* a situação não é diferente, muitos investidores enxergam essa moeda como uma boa maneira de lucrar por meio de especulação, uma vez que o mercado de compra e venda da criptomoeda é volátil e sofre inúmeras variações em um curto período de tempo.

2.2 ANÁLISE TÉCNICA

Segundo Murphy (1999) pode-se definir a análise técnica como o estudo de ativos (como ações e criptomoedas) do mercado, primordialmente a partir do uso de gráficos com o propósito de prever a tendência futura de preços. Ao citar ativos do mercado, Murphy (1999) destaca as três principais fontes de informações disponíveis e relevantes para esse tipo de análise, sendo elas: o preço, o volume e o interesse dos investidores.

A análise técnica se fundamenta em três premissas principais: 1 - O mercado reflete tudo; 2 - preços se movem em tendências; 3 - A história sempre se repete. Para Murphy (1999) a frase, "*market actions discounts everything*" forma o pilar base para a aceitação e compreensão de toda teoria por trás da análise técnica. Os investidores que utilizam a análise técnica para fazer seus investimentos e especulações, acreditam que tudo pode possivelmente influir no preço de

um ativo no mercado financeiro. Toma-se como verdade, que o estudo do preço do ativo é tudo que basta para prever seu comportamento. Os mercados de maneira geral seguem a premissa básica de que se a demanda excede a oferta, o preço sobe e que se a oferta excede a demanda o preço cai. A análise técnica pauta-se basicamente na análise gráfica e de indicadores a fim de prever momentos de compra, venda e manutenção de ativos de maneira mais exata. Como se fosse uma espécie de regra, investidores que adotam a análise técnica como estratégia, não se preocupam com a razão ou motivo pelos quais o preço de um ativo aumenta ou cai, eles simplesmente realizam a análise com a certeza de que os indicadores técnicos refletiram a situação atual de mercado.

2.2.1 INDICADORES TÉCNICOS

As informações sobre algum determinado ativo financeiro podem ser obtidas a todo instante por meio de *softwares* e sites que provém esse tipo de informação. Os dados como preço de abertura, fechamento, valor máximo, mínimo e médio do ativo e o volume de transações podem ser facilmente acessados para diferentes períodos por meio de gráficos (Brown, & Jennings, 1989).

Para complementar a análise gráfica, os analistas técnicos normalmente utilizam alguns indicadores estatísticos e financeiros que facilitam a identificação de certos padrões nos ativos. Esses indicadores foram desenvolvidos por analistas financeiros e matemáticos que enxergaram a possibilidade de utilizar as informações como preço de fechamento, abertura, volume, preço médio, máximo e mínimo, de maneira a identificar certas tendências de mercado em manter preços em alta, em baixa ou neutro (Brown, & Jennings, 1989).

De acordo com Murphy (1999), um dos indicadores mais famosos e amplamente utilizado pelos analistas atuais é a chamada média móvel simples (MMS). Isso deve-se principalmente à sua facilidade de utilização e teste. De maneira geral a média móvel serve como uma base para diversos outros indicadores. Considere uma média móvel simples de tamanho 5 e considere que os seguintes números são os preços de fechamento do ativo de uma determinada empresa: 11,12,13,14, 15 ,16,17.

$$\text{MMS do primeiro dia: } (11 + 12 + 13 + 14 + 15) / 5 = 13$$

$$\text{MMS do segundo dia: } (12 + 13 + 14 + 15 + 16) / 5 = 14$$

$$\text{MMS do terceiro dia: } (13 + 14 + 15 + 16 + 17) / 5 = 15$$

A média móvel é um dos indicadores mais confiáveis e ao mesmo tempo mais simples. Esse indicador é comumente utilizado em conjunto com outros indicadores para a obtenção de melhores resultados de análise (Brown, & Jennings, 1989). Trata-se de um indicador de tendência de momento, que serve de base para cálculo de indicadores mais complexos.

Outro indicador técnico é a média móvel exponencial (EMA - *Exponential Moving Average*) que surgiu como uma alternativa para algumas defasagens deixadas pelas SMA's. Esse indicador atribui um peso maior aos preços mais recentes. A utilização da EMA segue a mesma estratégia da média móvel simples (Murphy, 1999). Existem três passos para o cálculo desse indicador:

- Para o primeiro dia calcula-se uma média móvel simples, vale lembrar que a média móvel exponencial do n-ésimo dia é calculado utilizando a n-1 ésima média.
- É calculado o coeficiente que multiplica os preços recentes. A fórmula do coeficiente é dada por: $(2 / (\text{períodos de tempo} + 1))$
- calcula-se a média móvel exponencial por meio da fórmula:
 $\{\text{Preço de Fechamento} - \text{EMA}(\text{dia anterior})\} \times \text{multiplicador} + \text{EMA}(\text{dia anterior})$

É importante ressaltar que as médias móveis servem como base para muitos dos indicadores técnicos. O MACD ou *Moving average convergence divergence* é um exemplo de indicador que faz uso das médias móveis e é amplamente utilizado por analistas e *traders* (Murphy, 1999). De uma maneira geral o MACD transforma dois indicadores de tendência, no caso duas médias móveis, em um indicador de momento por meio da subtração da média móvel de maior período pela média móvel de menor período. O MACD trabalha com três parâmetros: a linha do MACD, a linha de sinal e o histograma. A linha do MACD é uma média móvel exponencial de 12 dias menos uma EMA de período de 26 dias. Para esse cálculo são utilizados os preços de fechamento (Murphy, 1999). A linha de sinal é definida por uma EMA da linha MACD (geralmente de 9 períodos) e é utilizada para identificar pontos de virada. Por fim, têm-se o histograma, que é dado pela subtração entre a linha do MACD e a linha de sinal. O histograma é positivo quando a linha do MACD se encontra acima da linha de sinal e o oposto ocorre quando a linha de MACD está abaixo (Murphy, 1999).

Outro indicador de momento muito utilizado é o RSI (*Relative Strength Index*) ou IFR (Índice de Força Relativo). O índice de força relativo é um indicador desenvolvido por Wilder Jr. (1986) e serve para avaliar a tendência de força de um ativo, dada a sua variação de preço. Este indicador é geralmente utilizado em conjunto com outros, e costuma indicar possíveis zonas de sobrecompra e sobrevenda (Murphy, 1999). Costumeiramente o RSI é exibido como um gráfico que atinge dois extremos, variando de 0 a 100. O cálculo do índice de força relativo é realizado por meio da seguinte fórmula:

$$RSI = 100 - \frac{100}{(1 + RS)} \quad (2.1)$$

$$RS = \frac{(\sum \text{dias de fechamento positivo em } N \text{ dias})/N}{(\sum \text{dias de fechamento negativo em } N \text{ dias})/N}$$

Calculado o indicador existem algumas inferências que podem ser feitas a respeito do valor retornado: entre 0 e 30, o RSI indica uma zona de sobrevenda, ou seja, uma boa oportunidade para compra; entre 70 e 100, indica uma zona de sobrecompra, um bom momento para venda; entre 30 e 70, momento de manutenção do ativo (Murphy, 1999).

É muito comum que para a utilização do RSI sejam usados períodos de 5, 9 ou 14 dias, ou seja, na Equação 2.2, N assumiria um desses valores.

Outro indicador de volume comumente utilizado em operações de compra e venda de ativos diárias é o oscilador estocástico. Desenvolvido por Lane (1985) o oscilador estocástico é utilizado para demonstrar a relação entre o preço de fechamento e suas máximas e mínimas durante um dado período de tempo. Assim como o RSI, esse indicador possui uma utilização

relativamente fácil e ajuda a identificar situações de sobrecompra e de sobrevenda (Lane, 1985). O oscilador estocástico é caracterizado pelo uso de duas linhas que se movimentam de maneira simultânea, a linha %K e a %D. A linha %K 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 (Lane, 1985). Por sua vez, a linha %D nada mais é do que uma média móvel simples de, usualmente, três dias dos valores encontrados em %k. Resumidamente tem-se então:

$$\%K = \left(\frac{\text{fechamento} - \text{mínima do período}}{\text{fechamento} - \text{máxima do período}} \right) * 100$$

$$\%D = \text{EMA}(\%K, 3)$$

Da mesma maneira que o RSI, o oscilador funciona por meio de valores que podem indicar uma situação no mercado, usualmente esse indicador é utilizado para determinar regiões de sobrecompra e sobrevenda. Quando a linha K ultrapassa os oitenta pontos interpreta-se que o ativo está sobrecomprado, em contrapartida quando a linha K permanece abaixo dos vinte pontos interpreta-se que o ativo está sobrevendido, portanto, tem-se uma oportunidade de compra. Valores intermediários entre vinte e oitenta, não possuem uma interpretação muito precisa e podem representar mercados lateralizados. Outra interpretação que pode ser feita utilizando as linhas do oscilador estocástico é a predição de tendências de alta e de baixa. O cruzamento de K e de D podem indicar mudanças na tendência. Quando K encontra-se acima da linha D há um indício de uma tendência de alta, ao passo que quando D está acima da linha K há indicação de uma tendência de baixa. Para a utilização do oscilador, normalmente utilizam-se períodos de 14 dias para o cálculo de K e três dias para o cálculo de D (Lane, 1985).

2.3 APRENDIZADO PROFUNDO

Um dos modelos de aprendizado profundo mais utilizados quando se trata da predição de preços de qualquer produto ou ativo financeiro é o LSTM. Segundo Gao e Wang (2018), o LSTM é uma rede neural recorrente. Esse modelo foi desenvolvido por Hochreiter e Schmidhuber (1977) com o intuito de resolver problemas de explosão e desaparecimento de gradientes. A chave do modelo LSTM está na sua estrutura interna que permite o armazenamento de padrões que se repetem inúmeras vezes e ao mesmo tempo permite o truncamento de informações quando ela é irrelevante ou desnecessária.

Uma LSTM processa as variáveis de entrada $\mathbf{x} = \{x_1, x_2, x_3, \dots, x_n\}$ incrementalmente, adicionando novos dados em um único compartimento de memória, com *gates* (portões) controlando o alcance de qual novo dado deve ser armazenado e quais dados antigos devem ser apagados. As redes neurais recorrentes produzem uma lista de estados durante o seu processamento, entretanto, no LSTM, o próximo estado computado depende unicamente do estado atual, isto é dado um estado qualquer h_t o estado h_{t+1} é completamente independente dos estados h_1, \dots, h_{t-1} , ou seja, a rede realiza sua atualização de uma maneira Markoviana, onde um estado depende única e exclusivamente do estado anterior.

Segundo Oliveira (2020) em termos de estrutura, a LSTM é composta por um instante atual de alimentação de informação da rede, identificado por x_t , o estado oculto (*hidden state*)

identificado por h_{t-1} e o estado da célula (*cell state*) identificado por c_{t-1} , sendo $t - 1$ a representação de que ambos estados provem da recorrência do instante de tempo passado t . Outra estrutura importante do LSTM, anteriormente citada são os portões ou *gates*. Esses portões basicamente controlam a passagem de informações entre dois canais. Os componentes básicos dos *gates* são mostrados na Figura 1.




Figura 1 – Estrutura dos Gates

Fonte: Fernando Matsumoto (2019).

A estrutura a esquerda da Figura 1, aplica uma função sigmóide sobre a entrada b e multiplica o resultado pelo sinal a . Uma vez que a saída da função sigmóide é um número entre 0 e 1, essa estrutura controla qual a porcentagem de de cada valor deve passar pelo *gate*.

Existem 3 tipos diferentes de portões (Figura 2): 1 - *Forget gate*: decide quais partes do *cell state* continuam relevantes; 2 - *Remember gate*: decide quais informações de curto prazo devem ser adicionadas ao *cell state*; 3 - *Output gate*: decide quais partes do *cell state* são relevantes no instante atual para gerar a saída.




Figura 2 – Estrutura completa da LSTM

Fonte: Fernando Matsumoto (2019).

Na Figura 2, a linha laranja é chamada de célula de memória, uma vez que esta armazena o *cell state*, também conhecido como memória de longo prazo. A linha abaixo, em preto, corresponde a memória de curto prazo, a qual armazena o *hidden state*. Por fim, pode-se notar que, entre a linha superior e inferior encontram-se os *gates* que controlam a passagem de informação entre os canais.

O processamento nos *gates* segue um fluxo que se inicia no *forget gate* e é finalizado no *output gate* (Figura 3). No *forget gate* determina-se as partes dos *cell state* que serão esquecidas. Matematicamente falando, os vetores h_{t-1} e x passam por uma função sigmóide dando origem a um vetor f que posteriormente é multiplicado pelo *cell state*.




FIGURA 3 – FORGOT GATE

Fonte: Fernando Matsumoto (2019).

No *input gate* são determinadas as informações da memória de curto prazo que devem ser colocadas no *cell state* (Figura 4). Esse cálculo é realizado em três etapas. A primeira etapa é o cálculo de um vetor i que determina a importância de cada informação; a segunda consiste em calcular um vetor de ativações C^+ , por meio de uma função de ativação \tanh , contendo as novas informações; por fim realiza-se a adição ao *cell state*.




FIGURA 4 – INPUT GATE

Fonte: Fernando Matsumoto (2019).

A última etapa do processamento nos gates ocorre no *output gate*, onde utiliza-se o *cell state* para o cálculo da saída h da rede. Assim, a saída do *output gate* é dado pelo seu processamento, por meio de uma função de ativação σ . Da mesma forma o estado C calculado anteriormente passa por uma função de ativação \tanh . Por fim, calcula-se o *hidden state* (h_t), por meio de uma multiplicação feita ponto a ponto, conforme mostrado na Figura 5.




Figura 5 – Output Gate

Fonte: Fernando Matsumoto (2019).

Vale ressaltar que as variáveis U , V e b vistas nas equações junto às Figuras 8, 9 e 10 referem-se aos pesos e *bias*, específicos de cada etapa, respectivamente.

3. METODOLOGIA

Na primeira etapa foram levantados os diferentes indicadores de análise técnica para a predição de momentos de compra, venda e manutenção de ativos. A partir do levantamento foram selecionados os indicadores técnicos mais utilizados para aplicação neste estudo. Também foi realizada uma revisão bibliográfica acerca das possíveis técnicas de aprendizado de máquina aplicáveis no processo de predição do movimento de preço de Bitcoin.

Na segunda etapa foram construídos os modelos de predição de preço: que utiliza apenas os indicadores técnicos (IT), o que utiliza aprendizado profundo (AP) e o modelo híbrido (IT-AP) que mescla as duas abordagens.

Na terceira etapa foi construído um simulador para testar e analisar todos os três modelos de predição do movimento de preço do Bitcoin para simular transações de compra, manutenção e/ou venda de Bitcoins a partir de dados históricos de 2020, utilizando para isto um capital hipotético de US\$ 100.000.

Na quarta etapa foi realizada a etapa de experimentos, para a realização da coleta de dados e análise comparativa dos resultados para verificar se os modelos obtiveram algum nível de lucro ou prejuízo.

4. RESULTADOS DOS EXPERIMENTOS

Nesta seção são descritos os resultados dos três modelos propostos. Primeiramente focou-se nas individualidades de cada modelo e posteriormente foi realizada uma comparação mais aprofundada entre todos os modelos enfatizando os diferenciais de cada modelo que podem ter gerado um ganho ou uma perda de desempenho, bem como uma análise do lucro dos modelos em relação à valorização do *bitcoin* no ano de 2020.

4.1 MODELO DE ANÁLISE TÉCNICA (AT)

Para o modelo que utiliza apenas a análise técnica como ferramenta de decisão de compra e venda de ativos, foram realizadas algumas variações do modelo, à título de se investigar a contribuição de cada indicador individualmente. Primeiramente foram utilizados os indicadores individualmente e realizadas algumas simulações. Posteriormente utilizou-se todos os indicadores (MMS, MME, MACD e RSI).

Ao ser utilizado apenas o indicador RSI, o modelo de investimento demonstrou-se ineficiente, uma vez que o montante final da simulação foi de US\$ 97880.28, o que representa um prejuízo de 2,1% em relação ao montante inicial. Notou-se também que, ao utilizar apenas o indicador RSI, o modelo adota um perfil mais conservador e realiza poucas transações, apenas duas compras e duas vendas durante todo o ano. O mesmo cenário se repetiu ao ser testado apenas oscilador estocástico como único indicador de tomada de decisão. O resultado da simulação apresentou um prejuízo de 37% e novamente foi encontrado um perfil conservador no modelo, sendo realizadas apenas 6 transações (três compras e três vendas). Por fim, ao ser testado apenas

o indicador MACD, constatou-se uma grande porcentagem de lucro cerca de 231,58% sendo realizadas 20 transações ao longo do ano (dez compras e dez vendas).

Ao combinar-se todos os indicadores no modelo de análise técnica pode-se notar a prevalência de um perfil conservador de investimento, ou seja, foram realizadas poucas operações de compra e venda. Analisando os dados expostos, pode-se notar que esse padrão mais conservador é observado devido ao RSI e o oscilador estocástico. Sendo assim, o modelo que utiliza todos os indicadores realiza ao longo do período de um ano, apenas 4 transações (2 compras e 2 vendas) obtendo um lucro de 190% em relação ao montante inicial (Figura 6).

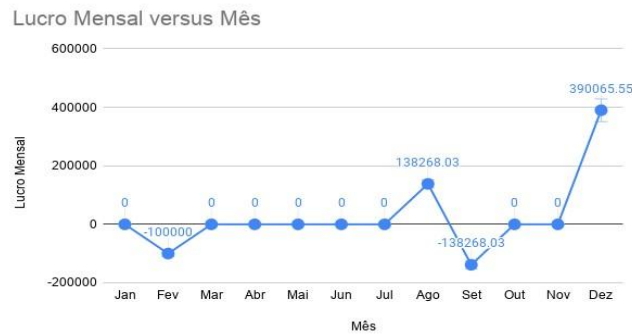


Figura 6 – Lucro mensal do modelo de análise técnica

De acordo com a Figura 6, a falta de transações observadas no primeiro mês do ano, ocorreu porque em janeiro do ano simulado ainda não foram calculados todos os indicadores para a realização da tomada de decisão. Uma vez que o MACD foi calibrado utilizando uma média móvel lenta de 26 períodos, as transações de compra só podem ocorrer no simulador a partir do vigésimo sétimo dia. Dessa forma, o modelo acaba identificando a primeira oportunidade de compra apenas no mês de fevereiro. Seguindo com o histórico de transações apresentado no gráfico da Figura 6, nota-se que a primeira venda foi realizada somente no mês de agosto. A Tabela 1 apresenta alguns dados adicionais a respeito da simulação.

Atributos da Carteira de Investimento	Valores
Montante Inicial	U\$ 100.000,00
Montante Final	U\$ 390.065,55
Número de Compras	2
Número Vendas	2
Porcentagem de Lucro	290%
Dinheiro Movimentado em Compras	U\$ 238.268,03
Dinheiro Movimentado em Vendas	U\$ 528.333,58
Quantidade Total de Bitcoin Comprado	24.98049840

Tabela 1 – Atributos finais da carteira de investimento do modelo de análise técnica

Ao se analisar a Tabela 1 é possível constatar que o número de compras e vendas realizadas durante o ano foi relativamente baixo, caracterizando um modelo de investimento mais passivo

em que não são realizados um grande número de compras nem um grande número de vendas. Uma explicação para a ocorrência desse baixo valor é a de que em diversos momentos o modelo identifica uma compra ou uma venda, mas a compra ou venda não é realmente efetivada, pois ou há falta de recurso disponível no caso da efetivação da compra ou não há *Bitcoins* para serem vendidos no caso da efetivação da venda.

Além disso, ao observar o gráfico da Figura 6 e dados da Tabela 1, embora poucas transações tenham ocorrido ao longo do período de um mês, o modelo de análise técnica apresentou um lucro alto, tendo quase triplicado o valor bruto inicial. O alto lucro obtido com um baixo número de transações pode ser explicado pela alta valorização do *bitcoin* no período em que ocorreram as transações.

Finalizando, o modelo de análise técnica obteve-se um lucro de 290%, por mais que tenha sido observada uma tendência de serem realizadas poucas transações durante o período de um ano. Esse perfil conservador no modelo de investimento ocorreu em vista da análise dos valores produzidos pelos indicadores técnicos.

4.2 MODELO DE APRENDIZADO PROFUNDO (AP)

Em relação ao modelo de aprendizado profundo verificou-se uma acurácia de cerca de 57,37% na predição da decisão de compra e venda de *bitcoins*, isto é, das 365 decisões tomadas cerca de 209 dias foram previstos de acordo com o resultado esperado. Contudo, quando se analisa separadamente as transações, as compras apresentaram uma precisão de apenas 20% e as vendas apresentaram uma precisão de 76%. Outra análise importante é em relação ao desempenho econômico do modelo de aprendizado profundo, o qual obteve um desempenho satisfatório (Figura 7).

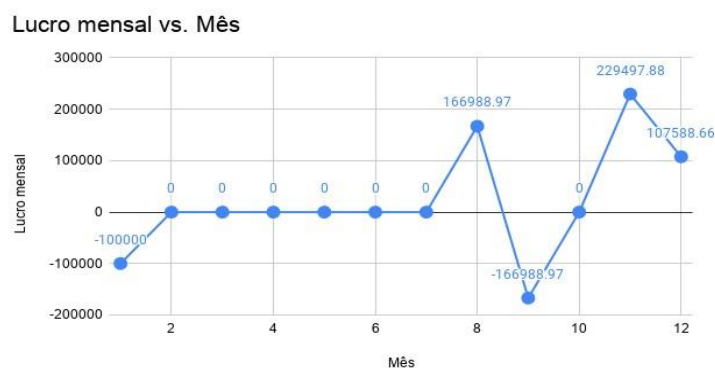


Figura 7 – Gráfico de mensal modelo que utiliza aprendizado de máquina

Ao observarmos a Figura 7, é possível observar que o dinheiro ganho no ano foi maior que os gastos gerados com a compra de *Bitcoins*, configurando um cenário de lucro. Ao somar-se os lucros obtidos nos 12 meses do ano e considerando o valor inicial investido o lucro bruto foi de US\$ 237086,55. Pode-se observar também que, em alguns meses não houve lucro e também não houve prejuízo. A Tabela 2 apresenta mais alguns dados adicionais da simulação.

Atributos da Carteira de Investimento	Valores
---------------------------------------	---------

Montante Inicial	US\$ 100.000,00
Montante Final	US\$ 337.086,55
Número de Compras	32
Número Vendas	32
Porcentagem de Lucro	237,08%
Dinheiro Movimentado em Compras	US\$ 4.646.654,67
Dinheiro Movimentado em Vendas	US\$ 4.883.741,22
Quantidade Total de Bitcoin Comprado	425.49500348

Tabela 2 – Atributos finais da carteira de investimento

Na Tabela 2 também é possível notar que uma quantidade significativa de *Bitcoins* foi comprada e vendida durante o período de 1 ano e que mais de 9 milhões de dólares foram movimentados em compras e vendas. Além disso, constata-se que o lucro médio mensal foi de US\$ 19.757,21.

Resgatando os dados da Tabela 1 é possível notar que a quantidade de *bitcoin* compradas pelo modelo de análise técnica no mesmo período foi aproximadamente 17 vezes menor, mesmo assim o lucro obtido pelo modelo de análise técnica foi 52,92% maior que o obtido pelo modelo de aprendizado de máquina.

Realizando um comparativo com o modelo de aprendizado de máquina, pode-se notar que ambos os modelos identificaram o mês de agosto como sendo um bom mês para vendas, sendo que no modelo de aprendizado de máquina este mês foi o segundo mais lucrativo. Já no mês de setembro ocorreu a última compra realizada no ano, novamente traçando um comparativo entre o modelo de análise técnica e o modelo de aprendizado de máquina nota-se que ambos modelos identificaram o mês de setembro como sendo um mês propenso a aquisição de *bitcoins*. Por fim, a última venda do modelo é realizada no último dia do ano de 2020 caracterizando o mês de dezembro como sendo o mais lucrativo para o modelo.

4.3 MODELO HÍBRIDO (IT-AP)

O modelo híbrido de investimento funciona analisando momentos de compra, por meio da análise preditiva feita pelo modelo de aprendizado de máquina, e de venda, por meio do indicador MACD, escolhido por ter desempenhado o melhor resultado individual entre os indicadores empregados nesse estudo. A Figura 8 apresenta os dados de lucro do modelo híbrido.



Figura 8 – Lucro mensal do modelo híbrido

Por meio da Figura 8 é possível perceber que o modelo obteve resultados expressivos em relação ao lucro. Também por meio da figura acima percebe-se que os meses de agosto, novembro e dezembro, assim como no modelo que utiliza aprendizado de máquina, caracterizaram os meses mais lucrativos. Conforme pode-se constatar nos dados apresentados na Tabela 3, a porcentagem de lucro atingida pelo modelo foi a maior entre os três desenvolvidos, atingindo uma porcentagem de lucro de cerca de 301% no período analisado. Ainda observando a tabela, nota-se que esse modelo apresentou o segundo maior volume de compra de *bitcoins* em 2020, ficando atrás apenas do modelo que utiliza AP, que adquiriu cerca de 2.12 vezes mais *bitcoins*.

Para a realização dos experimentos dos modelos o cenário escolhido foi o ano de 2020, ano em que o *bitcoin* teve uma alta de aproximadamente 303% em relação ao preço do dólar.

Atributos da Carteira de Investimento	Valores
Montante Inicial	U\$ 100.000,00
Montante Final	U\$ 401726,25
Número de Compras	14
Número Vendas	14
Porcentagem de Lucro	301,72%
Dinheiro Movimentado em Compras	U\$ 2.000.570,81
Dinheiro Movimentado em Vendas	U\$ 2.302.297,07
Quantidade Total de Bitcoin Comprado	199.77809551

Tabela 3 – Atributos finais da carteira de investimento do modelo híbrido

Ao se analisar os dados da Tabela 3, nota-se que o maior volume de *bitcoins* adquiridos está relacionado com o maior número de transações realizados pelo modelo. Conforme foi mencionado anteriormente, a fim de evitar que o modelo ficasse menos restritivo, optou-se pelo uso de apenas um indicador técnico na tomada de decisão de venda. Dessa maneira o modelo híbrido realizou, ao longo do período do ano de 2020, 28 transações, movimentando um total de U\$ 4302867,88 e caracterizando um perfil de investimento moderado.

Analisando os meses de maior atividade e realizando um comparativo com o gráfico apresentado na Figura 8, é possível notar que alguns meses apresentaram um certo número de transações, entretanto, essas transações foram feitas erroneamente, ou seja, o indicador de compra aponta para um momento compra, ao passo que o MACD indica um período de venda. Portanto, logo que o ativo é comprado, ele é logo vendido pelo mesmo preço de fechamento, é o caso dos meses de maio e junho. Na simulação com o modelo híbrido notou-se que o mês de maior atividade em relação a número de transações não foi o mês com maior lucro e, assim como no modelo que utiliza apenas AP, o mês que apresentou o maior lucro foi o mês de novembro.

4.4 COMPARATIVO ENTRE OS MODELOS

Nesta seção são discutidos e comparados os resultados dos três modelos em relação a valorização do preço do *bitcoin* no ano de 2020, dado pela compra do ativo no primeiro dia do ano e venda do ativo no último dia do ano ou estratégia *buy and hold* (Figura 9).



Figura 9 – Porcentagem de lucro dos modelos desenvolvidos em comparação a valorização do bitcoin

Observando a Figura 9 nota-se que nenhum dos três modelos desenvolvidos conseguiu atingir um desempenho melhor do que a própria valorização do *bitcoin* no ano de 2020. No período estudado, o *bitcoin* atingiu uma alta de quase 303% em relação ao dólar, moeda utilizada neste estudo. Também por meio da análise da figura nota-se que o modelo híbrido quase atingiu a valorização do ativo tendo um desempenho aproximado, 1,79% abaixo. O bom resultado do modelo híbrido está atrelado ao uso do indicador MACD na análise da decisão de venda do ativo. Atribui-se o bom desempenho do modelo à tomada de decisão do momento de venda e não de compra, pelo fato do modelo utilizar a saída computada por meio do aprendizado de máquina para a tomada de decisão de compra, e esta possuir uma precisão de apenas 20%.

O baixo desempenho do modelo que utiliza AP em relação a valorização do *bitcoin* pode ter sido ocasionado pela má tomada de decisão nos momentos de compra do ativo. Essa hipótese é suportada pelos dados obtidos a partir das Tabelas 1 e 2. Na Tabela 2, em específico pode-se notar que para a classificação de momentos de compra e venda atingiu-se uma acurácia de apenas 57,37%. Dessa forma, pode-se inferir que o modelo classifica a transação de maneira correta na maioria das vezes, mas ainda comete cerca de 42,63% de imprecisões. Além disso, é possível notar especificamente que para a classificação dos momentos de compra o modelo atingiu apenas 20% de precisão. Sendo assim, pode-se afirmar que existe uma grande dificuldade por parte deste modelo de identificar bons momentos de compra de *bitcoins*, podendo ocasionar compras em momentos não propícios.

No caso do modelo de análise técnica, nota-se por meio da Figura 9 que o desempenho do modelo foi melhor do que o modelo que utiliza aprendizado profundo, sendo aproximadamente 52,92% mais lucrativo. Vale a ressalva de que o modelo que utiliza análise técnica tem o perfil de investimento mais conservador realizando apenas duas compras e duas vendas ao longo do ano todo. Dessa maneira, este modelo faz bom uso da valorização do ativo.

4.5 CONCLUSÃO

Este trabalho propôs a implementação de três diferentes modelos de investimentos para a criptomoeda *bitcoin*. Para que os modelos pudessem ser desenvolvidos, foi realizada uma

revisão bibliográfica dos tópicos relativos a cada modelo. Buscando na literatura recente, que une os tópicos especulação, investimento e computação, chegou-se a decisão pela utilização da tecnologia LSTM para os modelos que utilizassem aprendizado profundo. Em relação ao modelo de análise técnica, a abordagem foi a mesma, e optou-se pela utilização dos indicadores, MACD, índice de força relativo (RSI) e oscilador estocástico. Para a criação do modelo híbrido, decidiu-se pela utilização do aprendizado de máquina para computar os dias de compra e pela utilização do indicador mais lucrativo, MACD, para realizar a identificação dos momentos de venda.

No que se refere a calibragem dos indicadores técnicos, foram utilizados valores padrões apresentados na literatura de indicadores técnicos voltados para o mercado acionário. O principal enfoque do trabalho realizado, diz respeito à rentabilidade dos modelos desenvolvidos. Para tanto foram escolhidas métricas que mensurassem os lucros e auxiliassem no entendimento de como cada modelo se comportou abordando a compra e venda no período estudado. Em especial, para avaliação do modelo de aprendizado de máquina, optou-se pela adição de mais três métricas que são comumente utilizadas para avaliação de modelos de AM, são elas: *F1-score*, *Mean Squared error* e *Accuracy*. Essas métricas foram fundamentais para o entendimento dos comportamentos tanto do modelo que utilizou apenas aprendizado de máquina, como do modelo híbrido.

Em relação aos resultados obtidos, pode-se concluir que foram satisfatórios, uma vez que todos os modelos desenvolvidos apresentaram um investimento com um lucro maior que 200% em relação ao montante inicial. Dado os resultados dos três modelos, concluiu-se que, é possível desenvolver estratégias individuais de investimento utilizando análise técnica e aprendizado de máquina, bem como unir ambas as técnicas em um modelo, obtendo resultados expressivos (300%). Realizando uma comparação entre os três modelos e levando em conta a valorização do *bitcoin* no ano de 2020, observou-se que os experimentos foram realizados em um cenário favorável ao lucro, uma vez que no ano de 2020 o *bitcoin* atingiu uma alta de 303%. Sendo assim concluiu-se também que, para o ano de 2020, embora todos os modelos tenham obtido lucro no período, a estratégia *buy and hold* seria mais vantajosa em relação as estratégias adotadas nos modelos desenvolvidos. Vale a ressalva de que nesse estudo não foram consideradas taxas de transação na avaliação dos modelos.

Como proposta de trabalhos e análises futuras, podem ser exploradas novas métricas em relação aos riscos que cada modelo apresenta, outra análise complementar pertinente é a utilização dos modelos em cenários desfavoráveis ao *bitcoin*, ou seja, cenários onde a criptomoeda sofre grande desvalorização.

REFERÊNCIAS

Aggarwal, A. Gupta, I., Garg, N. & Goel, A. (2019). Deep learning approach to determine the impact of socio economic factors on bitcoin price prediction. *2019 Twelfth International Conference on Contemporary Computing (IC3)*, 2019. p. 1–5.

Brown, D.P., & Jennings, R. H. (1989). On Technical Analysis. *The Review of Financial Studies*, v. 2, n. 4, p. 527-551.

- Deng, L., Yu, D. (2014). *Deep learning: methods and applications*. Now Publishers, Inc., v. 7, n. 3–4, p. 197–387, 2014.
- Dhage, S. N., Rane, P. V. (2019). Systematic erudition of bitcoin price prediction using machine learning techniques. *2019 5th International Conference on Advanced Computing Communication Systems (ICACCS)*, p. 594–598.
- Gao, Q., Wang, C. (2018). High and low prices prediction of soybean futures with lstm neural network. *2018 IEEE 9th International Conference on Software Engineering and Service Science (ICSESS)*. [S.l.: s.n.], p. 140–143.
- Grzelak, L. A. & Oosterlee, C. W. (2011). On the heston model with stochastic interest rates. *SIAM Journal on Financial Mathematics*, SIAM, v. 2, n. 1, p. 255–286.
- Lane, G. C. (1985). Lane’s stochastics: the ultimate oscillator. *Journal of Technical Analysis*, v. 21, p. 37–42.
- Matsumoto, F. (2019). Redes Neurais | LSTM: Como lidar com perda de memória com Machine Learning. Acesso em: 21/04/2021]. Disponível em: <<https://medium.com/turing-talks/turing-talks-27-modelos-de-predi%C3%A7%C3%A3o-lstm-df85d87ad210>>.
- Murphy, J. J. (1999). *Technical analysis of the financial markets: A comprehensive guide to trading methods and applications*. EUA: New York Institute of Finance.
- Oliveira, E. V. de. (2020). *Análise de desempenho de método baseado em rede LSTM para classificação de falhas em um processo de controle de nível*. Dissertação (Mestrado) — Universidade Federal do Rio Grande do Norte.
- Phaladisailoed, T.; Numnonda, T. (2018). Machine learning models comparison for bitcoin price prediction. *2018 10th International Conference on Information Technology and Electrical Engineering (ICITEE)*, p. 506–511.
- Shimabukuro, C. I., Galegale, N. V., Okano, M. T., Langhi, C. (2020). Deep learning aplicado à negociação de ações por algoritmos: Uma revisão descritiva da literatura. *South American Development Society Journal*, v. 6, n. 17, p. 237.
- Tapscott, D., & Tapscott, A. (2016). *Blockchain revolution: how the technology behind bitcoin is changing money, business, and the world*. Penguin.
- Velankar, S., Valecha, S. & Maji, S. (2018). Bitcoin price prediction using machine learning. *2018 20th International Conference on Advanced Communication Technology (ICACT)*, p. 144–147.
- Vidotto, R. S., Migliato, A. L., Zambon, A. C. (2009). O moving average convergence-divergence como ferramenta para a decisão de investimentos no mercado de ações. *Revista de Administração Contemporânea*, v. 13, n. 2, p. 291–309.
- Wilder Jr, J. W. (1986). The relative strength index. *Journal of Technical Analysis of Stocks and Commodities*, 4, 343-346.