

UNIVERSIDADE FEDERAL DE OURO PRETO
DEPARTAMENTO DE COMPUTAÇÃO

CHARLLON LOBO ALMEIDA

**PREDIÇÃO DE SÉRIES TEMPORAIS
APLICADA AO MERCADO DE
CRIPTOMOEDAS**

Ouro Preto, MG
2019

CHARLLON LOBO ALMEIDA

UNIVERSIDADE FEDERAL DE OURO PRETO

DEPARTAMENTO DE COMPUTAÇÃO

Monografia II apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como parte dos requisitos necessários para a obtenção do grau de Bacharel em Ciência da Computação.

Orientador: Prof. Dr. Eduardo José da Silva Luz

Coorientador: Prof. Dr. Julio Cesar Araujo da Silva Junior

Ouro Preto, MG
2019

A447p

Almeida, Charllon Lobo.

Predição de séries temporais aplicada ao mercado de criptomoedas
[manuscrito] / Charllon Lobo Almeida. - 2019.

32f.: il.: color; grafs; tabs.

Orientador: Prof. Dr. Eduardo José da Silva Luz.

Coorientador: Prof. Dr. Julio Cesar Araujo da Silva Junior.

Monografia (Graduação). Universidade Federal de Ouro Preto. Instituto de
Ciências Exatas e Biológicas. Departamento de Computação.

1. Transferência eletrônica de fundos . 2. Bitcoin. 3. Aprendizagem . 4.
Mercado financeiro . I. Luz, Eduardo José da Silva. II. Silva Junior, Julio
Cesar Araujo da . III. Universidade Federal de Ouro Preto. IV. Titulo.

CDU: 004.738

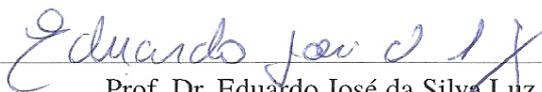
Catálogo: ficha.sisbin@ufop.edu.br

CHARLLON LOBO ALMEIDA

**PREDIÇÃO DE SÉRIES TEMPORAIS APLICADA AO MERCADO DE
CRIPTOMOEDAS**

Monografia II apresentada ao Curso de Ciência da Computação da Universidade Federal de Ouro Preto como parte dos requisitos necessários para a obtenção do grau em Bacharel em Ciência da Computação.

Aprovada em Ouro Preto, 20 de dezembro de 2019.



Prof. Dr. Eduardo José da Silva Luz
Universidade Federal de Ouro Preto - UFOP
Orientador



Prof. Dr. Julio Cesar Araujo da Silva Junior
Universidade Federal de Viçosa - UFV
Coorientador



Prof. Dr. Jadson Castro Gertrudes
Universidade Federal de Ouro Preto - UFOP
Examinador



Profa. Dra. Valéria de Carvalho Santos
Universidade Federal de Ouro Preto - UFOP
Examinadora

Resumo

O Bitcoin é uma moeda digital descentralizada, que surgiu com a finalidade de substituir os meios de pagamento atuais, porém ele enfrenta grandes desconfiças dos investidores e usuários devido à volatilidade de seus valores. Uma forma de mitigar essa volatilidade é aplicar inteligência computacional baseada em algoritmos de aprendizado de máquina, com o intuito de prever os valores de sua cotação. Este trabalho busca aplicar uma Rede Neural Recorrente (RNN) utilizando-se da série histórica do Bitcoin para realizar a predição da curva relativa ao valor de fechamento diário. Para realizar o treinamento do algoritmo, foi utilizada a base de dados *Bitstamp* da *CryptoDataDownload*. Os dados utilizados são relativos à paridade BTCUSD no período de 28/11/2014 até 29/11/2019. Diversos indicadores foram avaliados e combinados para verificar a qualidade da geração do modelo, porém o melhor resultado obtido utilizou apenas o indicador de curva (valor de fechamento diário) com uma raiz quadrada do erro quadrático médio (do Inglês *root mean square error* - RMSE) de 260.137, sendo esse valor um parâmetro para pesquisas futuras.

Palavras-chave: Criptomoedas. Bitcoin. Deep Learning. Volatilidade. Mercado financeiro. Indicadores financeiros. Rede Neural artificial.

Abstract

Bitcoin is a decentralized digital currency that has emerged to replace current payment methods. However it faces distrust from investors and users due to the volatility of its values. One way to mitigate this volatility is to apply computational intelligence based on machine learning algorithms to predict their quotation values. Thus, this work aims to apply a Recurrent Neural Network (RNN), using Bitcoin's historical series, to predict the curve relative to the daily closing value. This work uses the Bitstamp database of the CryptoDataDownload webpage for training the algorithm. The data used are for BTCUSD parity from 11/28/2014 to 11/29/2019. Several indicators were evaluated and combined to verify the quality of the solution, however, the best result obtained was only the curve indicator (daily closing value) with a square root of the mean square error root mean square error (RMSE) of 260,137, being a parameter value for future researches.

Keywords: Cryptocurrencies. Bitcoin. Deep Learning. Volatility. Financial market. Financial indicators. Artificial Neural Network.

Lista de Ilustrações

Figura 1.1 – Variação do BTC/USD no período de 30 dias	2
Figura 2.1 – Passo a passo do funcionamento da <i>blockchain</i>	5
Figura 2.2 – Binance, maior exchange de criptomoedas	8
Figura 2.3 – Gráfico do Bitcoin / USDT na POLONIEX	8
Figura 2.4 – Médias Móveis Simples em BTCUSDT entre JAN/2019 a JUN/2019	9
Figura 2.5 – Bandas de Bollinger em BTCUSDT entre JAN/2019 a JUN/2019	10
Figura 2.6 – MACD, Sinal e Histograma MACD	11
Figura 2.7 – SAR em BTCUSDT entre JAN/2019 a JUN/2019	12
Figura 2.8 – RSI em BTCUSDT entre JAN/2019 a JUN/2019	13
Figura 2.9 – Entrada/Saída de uma rede neural recorrente.	15
Figura 2.10–Representação da estrutura da LSTM.	15
Figura 4.1 – Visualização gerada pelo TensorFlow do modelo.	23
Figura 5.1 – Curva real da base de dados de 28/11/2014 até 29/11/2019.	25
Figura 5.2 – Experimentos do período I de 2014 à 2019	25
Figura 5.3 – Experimentos com dados da Curva dos teste.	26
Figura 5.4 – Experimentos com dados da Curva + RSI + SMA + SAR	26

Lista de Tabelas

Tabela 4.1 – Amostra de dados do dia 28/01/2019 ao dia 01/02/2019	21
Tabela 4.2 – Amostra do dia 25/11/19 à 29/11/19 do vetor de características	22
Tabela 5.1 – Comparativo do RMSE da permutações da Curva + Indicadores	27

Lista de Algoritmos

4.1	Ordenação do banco de dados	21
4.2	Cópia do Fechamento para vetor de características	21
4.3	Biblioteca Ta-Lib em Python	21
4.4	Concatenação de indicadores	22
4.5	Remoção de valores nulos	22
4.6	Normalização do vetor de características	22
4.7	Modelo proposto	23
5.1	Divisão de dados de treinamento e teste	24

Lista de Abreviaturas e Siglas

BB	Bandas de Bollinger
BTC	BITCOIN
DECOM	Departamento de Computação
UFOP	Universidade Federal de Ouro Preto
ETH	Ethereum
LTC	Litecoin
MACD	Moving Average Convergence Divergence
IFR / RSI	Índice de Força Relativa
SAR	Stop and Reversal
SMA	Média Móvel Simples
MME / EMA	Média Móvel Exponenciais
MA	Média Móvel
RNA	Redes Neurais Artificiais
RMSE	Raiz Quadrada do Erro Quadrático Médio
ROI	Retorno sobre o investimento
RNR / RNN	Redes Neurais Recorrentes
LSTM	Long short-term memory
ARIMA	Autoregressive Integrated Moving Average
GPU	Graphics Processing Unit
CPU	Unidade Central de Processamento
MLP	Multilayer Perceptron
MAE	Mean Absolute Error

Sumário

1	Introdução	1
1.1	Justificativa	2
1.2	Objetivos	3
1.3	Organização do Trabalho	3
2	Fundamentação Teórica	4
2.1	Criptomoedas	4
2.2	<i>Blockchain</i>	4
2.3	O Bitcoin	5
2.3.1	Geração e Fluxo de Bitcoins	5
2.3.2	Mercado de câmbio e Volatilidade do Bitcoin	6
2.4	Indicadores financeiros	8
2.4.1	Médias Móveis Simples (SMA)	9
2.4.2	Bandas de Bollinger (BB)	9
2.4.3	Relação entre <i>Moving Average Convergence Divergence</i> (MACD) e o Sinal	10
2.4.4	Stop And Reversal (SAR)	11
2.4.5	Índice de Força Relativa (RSI)	12
2.4.6	Biblioteca Ta-Lib	13
2.5	Redes Neurais Artificiais	13
2.5.1	Aprendizagem em profundidade (Deep Learning)	14
2.5.2	Redes neurais recorrentes	14
2.6	Raiz Quadrada do Erro Quadrático Médio - RMSE	15
3	Trabalhos Relacionados	17
4	Desenvolvimento	20
4.1	Base de Dados	20
4.2	Pré-Processamento	21
4.3	Modelagem	22
5	Experimentos e Resultados	24
5.1	Discussão dos Resultados	26
6	Conclusão	28
6.1	Trabalhos Futuros	28
	Referências	30

1 Introdução

Desde antigas civilizações a moeda é usada como meio de troca em produtos e serviços, sendo utilizadas diversas moedas de acordo com o país, região, entre outros. Em um mundo globalizado é necessário o câmbio de moedas, estabelecendo valores equivalentes de uma para a outra. Câmbio, de acordo com Sandroni (SANDRONI, 2004), é a operação financeira de vender, comprar ou trocar valores em moedas de outros países ou papéis que representem moedas de outros países, utilizando cheques, moedas, notas bancárias, letras de câmbio, ordens de pagamento e outros. Há vários tipos de regimes cambiais, que são as regras e/ou acordos estabelecidos para que se efetuem os pagamentos internacionais (MEDEIROS; FRANCHINI, 2007). Alguns exemplos são: fixo, variável, variável com intervenção. No câmbio fixo, o Banco Central tem a função de comprar ou vender moeda estrangeira, em geral o dólar, para manter essa moeda a um valor fixo em moeda nacional (FREITAS, 2008). Ainda segundo o mesmo, no câmbio flutuante, o valor de equivalência entre moedas de diferentes países é modificado de acordo com a oferta e procura do mercado, como no Brasil atualmente.

Nesse contexto, surgem em 2009 as criptomoedas como uma alternativa às tradicionais moedas mundiais, sendo o Bitcoin a pioneira. Segundo Nakamoto (NAKAMOTO, 2009), são a versão peer-to-peer¹ do dinheiro eletrônico que permite pagamentos online diretamente de uma pessoa para a outra sem passar por uma instituição financeira. São baseadas em blockchain (NAKAMOTO, 2009)², garantindo a máxima segurança e confiabilidade nas transações realizadas. Além do meio peer-to-peer, o bitcoin e as demais criptomoedas podem ser obtidos a partir do câmbio por moedas convencionais a partir de corretoras online ou de transferências diretas entre pessoas.

Em relação ao câmbio, uma das principais características do bitcoin é a variabilidade do preço. Segundo Bukovina e Martiček (BUKOVINA; MARTIČEK et al., 2016), o Bitcoin é extremamente volátil, comparado ao dólar, euro, libra esterlina ou iene. Tress e Anastacio (TRESS, 2017) nos relata que, ao mesmo tempo que gera desconfiança, atrai investidores de maior experiência, vendo-o como oportunidade de lucro. No entanto, para investidores comuns, a variabilidade de preço (volatilidade) é um ponto negativo por poder ter uma súbita desvalorização, transformando-se em um ativo financeiro de risco (Figura 1.1).

¹ arquitetura de redes de computadores onde cada computador recebe e envia dados para outros computadores da rede

² banco de dados descentralizado peer-to-peer de computadores ao redor do mundo



Figura 1.1 – Variação do BTC/USD no período de 30 dias

Por essa variabilidade, é muito difícil decidir o momento e qual operação fazer de compra ou venda de bitcoins, fazendo investidores terem grande interesse na previsão das alterações do mercado. Com isso, surgiram várias técnicas para predição, usando-se inclusive modelos de redes neurais para tal tarefa.

IGNÁCIO et al. (2016) explica as redes neurais como uma subárea de aprendizagem de máquinas que facilitam a descoberta de padrões em séries temporais e previsão de dados a partir dos dados obtidos. Essa tecnologia pode ser usada para prever a variabilidade de preço do bitcoin, se utilizada uma combinação de indicadores confiáveis para nortear a decisão de compra-venda da moeda. *Deep learning* vem conseguindo resultados estado-da-arte em diversos problemas, inclusive para previsão e séries temporais (FABER, 2016). Assim, pretende-se investigar o uso de *deep learning* para o problema de predição de curvas de cripto ativos. Com o auxílio da *deep learning*, pode-se ter a compreensão de dados gráficos anteriores para melhorar a previsibilidade do algoritmo de decisão devido ao uso de várias camadas de redes neurais, e, com essa previsão mecânica, eliminar o fator emocional, que muitas vezes fazem investidores tomarem decisões erradas sobre o momento de negociação de criptomoedas.

A proposta do trabalho é investigar e aplicar uma rede neural artificial recorrente, que, por meio do processamento de indicadores financeiros (SAR, RSI e SMA - Sessão 2.4), identifique padrões de variação do preço do Bitcoin. Conjuntamente, propomos um melhor preço para compra/venda, baseado na predição da rede.

1.1 Justificativa

Como a volatilidade das criptomoedas é muito grande, o investidor muitas vezes, por falta de conhecimento do mercado financeiro, notícias tendenciosas ou especulações, acaba tomando

decisões de compra e venda equivocadas, gerando prejuízos. A rede neural artificial a ser explorada seria uma ferramenta para tomada de decisão ou automatizar o câmbio de criptomoedas, tendo uma base fundamentada no que diz respeito ao momento certo e que tipo de transação fazer, objetivando maximizar os lucros.

Até o momento, não encontramos abordagem baseadas em redes profundas, que estejam centradas em analisar o impacto destes modelos em momentos de difícil previsão, como o que aconteceu com o Bitcoin nos anos de 2017 e 2018.

1.2 Objetivos

O objetivo do presente projeto de pesquisa é desenvolver um modelo utilizando uma rede neural artificial que ajude a prever o melhor momento de comercialização (compra e venda) de Bitcoin, utilizando a combinação da curva bruta da criptomoeda com indicadores técnicos: Stop and Reversal (SAR), Médias Móveis Simples (SMA) e Índice de Força Relativa (RSI).

O trabalho propõe uma contribuição ao analisar o desempenho e comportamento dos métodos de predição em mercados de forte tendência de alta e baixa. Visto que em alguns ciclos do mercado ocorrem grande euforia, devido a notícias e grandes aparições na mídia. Um exemplo ocorreu no final de 2017 com um movimento absurdamente forte de alta, atingindo a máxima histórica até então, e posteriormente um movimento grande de baixa no início de 2018 que se estendeu ao longo de tal ano.

1.3 Organização do Trabalho

Este trabalho está organizado da seguinte forma:

O Capítulo 2 é um embasamento de conceitos gerais abordados no trabalho. O Capítulo 3 mostra trabalhos anteriores relacionados e os métodos utilizados ao tema em si. O Capítulo 4 trata do desenvolvimento do trabalho, com os métodos abordados. As experimentações realizadas no código estão no Capítulo 5. Os resultados obtidos e analisados estão no Capítulo ???. O Capítulo 6 encerra o trabalho com sua conclusão e trabalhos a serem feitos no futuro a respeito do tema.

2 Fundamentação Teórica

Apresentamos aqui os fundamentos básicos para o entendimento do trabalho, incluindo trabalhos e pesquisas anteriores na área.

2.1 Criptomoedas

A moeda digital, como explica [Vicente \(2017\)](#), desde sua criação, é considerada um grande potencial para opção de pagamentos e até como meio de investimento. [BARBOSA \(2016\)](#) frisa que moedas digitais são valores armazenados e circulados pela internet oferecendo métodos acessíveis de liquidações instantâneas para transferência de fundos e condução de negócios em escala global.

Criptomoeda, pela definição de [Vicente \(2017\)](#), é uma moeda digital descentralizada que surgiu prometendo substituir os meios de pagamento atuais. [Rodrigues \(2017\)](#) mostra que essa situação faz com que a criptomoeda esteja teoricamente protegida de interferências governamentais, impedindo de estabelecer custos e taxas. [Kim et al. \(2016\)](#) caracterizam as criptomoedas com marcante flutuações nos preços e número de transações. [Rodrigues \(2017\)](#) nos conta que, por ser criptografada, é primordialmente impedida a falsificação das criptomoedas. E ainda, os clientes das transações são reconhecidos apenas como números criptografados por suas assinaturas digitais, sem identificação nominal, preservando suas identidades.

[Kim et al. \(2016\)](#) apontam diversas criptomoedas surgindo desde 2008, sendo classificadas por [Catania, Grassi e Ravazzolo \(2018\)](#) como as mais importantes em termos de difusibilidade e capitalização de mercado Bitcoin, Ethereum, Litecoin e Ripple, sendo que as apresentadas representam 73% do valor de mercado total de criptomoedas.

2.2 *Blockchain*

De acordo com [Rodrigues \(2017\)](#), a operação do sistema Bitcoin é basicamente pautada na gerência eficaz de um livro-razão denominado de *blockchain*, que é o mais popular exemplar dessa tecnologia, como esclarece [Crosby et al. \(2016\)](#): um *blockchain* é um banco de dados de registros distribuídos, ou razão de todas as transações ou eventos digitais que foram executados e compartilhados entre as partes participantes. De acordo com os autores, cada transação no registro público é verificada por um consenso da maioria dos participantes do sistema (ver Figura 2.1), e uma vez inserida, a informação nunca poderá ser apagada. [Silva \(2016\)](#) nos aponta que no *blockchain* é onde se encontram registradas todas as movimentações envolvendo Bitcoins. [Parino, Beiró e Gauvin \(2018\)](#) contam que o banco de dados de *blockchain* completo de Bitcoin

é livremente acessível a partir da Internet.

2.3 O Bitcoin

BARBOSA (2016) aponta o Bitcoin como principal representante das moedas digitais no mundo. Crosby et al. (2016), em 2009, alguém usando o pseudônimo de Satoshi Nakamoto publicou um artigo criando todo o conceito de Bitcoin, chamado 'Bitcoin: a Peer-To-Peer Electronic Cash System' (NAKAMOTO, 2009). O autor permanece anônimo ainda hoje.

De acordo com Guo e Antulov-Fantulin (2018), Bitcoin é um novo sistema de moeda digital que funciona sem controle governamental, sendo os pagamentos feitos por uma rede digital peer-to-peer. Explica Vicente (2017) que, na rede, o usuário pode ser cliente ou servidor, requisitando e/ou distribuindo informações.

O Bitcoin, no relato de ULRICH (2014) nasce como meio de transformar o mercado financeiro, agindo como moeda independente de vínculos econômicos, cuja troca e validação são exclusivamente realizadas na Internet.

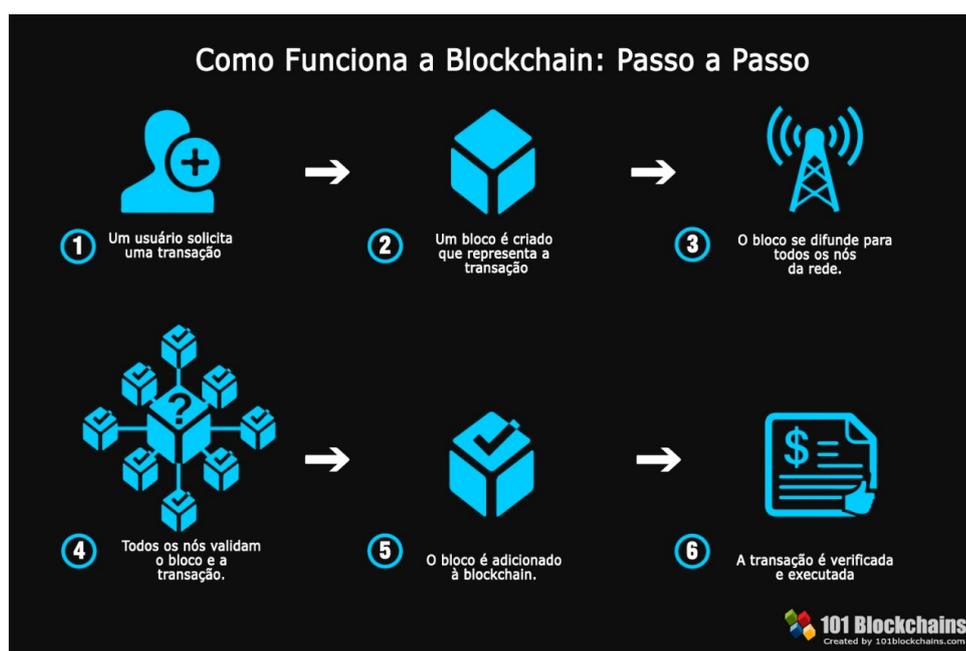


Figura 2.1 – Passo a passo do funcionamento da blockchain¹.

2.3.1 Geração e Fluxo de Bitcoins

O processo de mineração de Bitcoins, salientado por Silva (2016), é peça chave para a operação do sistema, e a partir dele que novas moedas são criadas, transações validadas e torna viável a autonomia da rede. Como explica Antonopoulos (2014), na criação de Bitcoins por

¹ <<https://bit.ly/38Qpybu>>

mineração há o envolvimento da resolução de um problema matemático para validar a transação. Segundo Crosby et al. (2016), para um novo bloco minerado ser aceito no *blockchain*, o mesmo deve conter a solução de um problema matemático muito especial, e esse enigma matemático, não é de fácil resolução, podendo a complexidade ser ajustada de forma que, em média, leve-se dez minutos para um minerador da rede de Bitcoin dar um palpite certo e gerar um bloco.

Como apresentado por Tress (2017), mineradores são programadores que legitimam e constroem o *Blockchain*. Crosby et al. (2016) afirmam que há uma possibilidade remota de mais de um bloco ser gerado no sistema concomitantemente. Silva (2016) nos explica que os blocos são adicionados à *blockchain* linearmente e em ordem cronológica. Já Tress (2017) traz à tona que cada mineração de sucesso, o minerador da mesma recebe um pagamento por operação, que é reajustado a cada 210 mil blocos minerados ou 4 anos, de acordo com ARAGÃO (2016), para interromper a emissão de moedas e evitar uma possível inflação.

Os Bitcoins, como aponta Vicente (2017), também podem ser obtidos em casas de câmbio específicas para criptomoedas, conhecidas como *exchanges*², dos mesmos ou em recebimento de venda e prestação de serviço, os quais devem ser armazenados em uma carteira digital denominada “digital wallet”. Crosby et al. (2016) relatam que qualquer transação necessita de verificação para ser validada antes de ser gravada no ledger público. Na validação da transação, como conta ARAGÃO (2016) há uma taxa sobre transação, que funciona como um tipo de gorjeta paga pelo realizador da mesma transação ao usuário que inclui-la na *blockchain*.

Stevenson (2013) conta que o Bitcoin possui limite predefinido no seu algoritmo apontando que só podem existir 21 milhões de Bitcoins, e, segundo BARBOSA (2016), deverão cessar as minerações no ano de 2140. Silva (2016) esclarece que, como todas as movimentações financeiras foram gravadas desde a primeira transação com Bitcoin no *blockchain*, é praticamente impossível que ocorram falsificações. Vicente (2017) analisou a força de segurança das transações do sistema Bitcoin e recebeu resultados contundentemente positivos.

2.3.2 Mercado de câmbio e Volatilidade do Bitcoin

A volatilidade, segundo Downes e Goodman (1993), é a característica de aumento ou queda brusca do preço de um valor mobiliário, commodity ou mercado em um período curto. Existem várias maneiras de medição dela.

Ensina Silva (SILVA, 2016), que a volatilidade é o maior problema do Bitcoin. Para Guo e Antulov-Fantulin (2018) volatilidade como forma de contar a flutuação de preços tem um importante impacto em estratégias de comércio e decisões de investimento. Esclarecem Catania, Grassi e Ravazzolo (2018) que semelhante à outras moedas, criptomoedas apresentam volatilidade variável com o tempo, observações extremas e reações assimétricas e voláteis comparadas ao passado.

² plataformas que facilitam a compra, a venda e a troca de criptomoedas

Vicente (2017) e Mohnot (2011) frisam a importância da lei de oferta e procura na instabilidade de mercado.

BARBOSA (2016) encontrou como resultado que o Bitcoin é 4 vezes mais volátil do que as moedas tradicionais e 2,2 vezes mais volátil que a moeda tradicional de maior volatilidade, o Real. Para Vicente (2017), a descrença em relação ao Bitcoin advém exatamente dessa oscilação pela volatilidade, que não o deixa manter uma estabilidade confiável, aumentando e diminuindo constantemente o valor e deixando incertezas quanto à sua credibilidade. Tress (2017) aponta que a volatilidade coloca a criptomoeda sendo um ativo financeiro de risco, como uma ação ou *commodity*, ao invés de garantir aos usuários reserva de valor e unidade de conta.

Neves (2018) cita três grandes variáveis influenciando o preço do Bitcoin: i) macroeconômicas e financeiras, como exemplo cotação do dólar e índice de bolsa de valores; ii) atratividade, aumento do interesse pelo ativo por sua valorização ao longo dos anos e iii) dinâmica entre demanda e oferta. Também conta que eventos ligados à atividade das criptomoedas e eventos exógenos, de cunho macroeconômico, mostram ter uma muita influência sobre o preço do Bitcoin nos momentos em que ocorrem, como ataques cibernéticos e imposição de regulação por entidades soberanas foram decisivas na queda do valor do Bitcoin em períodos de incerteza quanto ao futuro das moedas digitais. Crises, muitas vezes não relacionadas às moedas virtuais, parecem estarem diretamente ligadas a um eventual aumento do preço do Bitcoin.

Bukovina, Martiček et al. (2016) complementam indicando fatores menos racionais, como, investimentos especulativos ou atenção da sociedade como fatores plausíveis da volatilidade do Bitcoin de acordo com a literatura.

Guo e Antulov-Fantulin (2018) salientam o Bitcoin como um pioneiro no renascimento financeiro do *blockchain*, e possui papel principal em todo mercado de sistema de capitalização de criptomoeda (Exemplo de plataforma na Figura 2.2), sendo importante para a mineração de dados e comunidade de aprendizado da máquina poder prever flutuações de preços de Bitcoin e dar sinais para entender o impulsionamento da volatilidade Bitcoin, estimando melhor os riscos associados à criptomoeda. Porém, alerta Radityo, Munajat e Budi (2017), devido à sua volatilidade, é necessária uma ferramenta de previsão para auxiliar os investidores a considerar decisões de investimento em câmbio de criptomoedas.

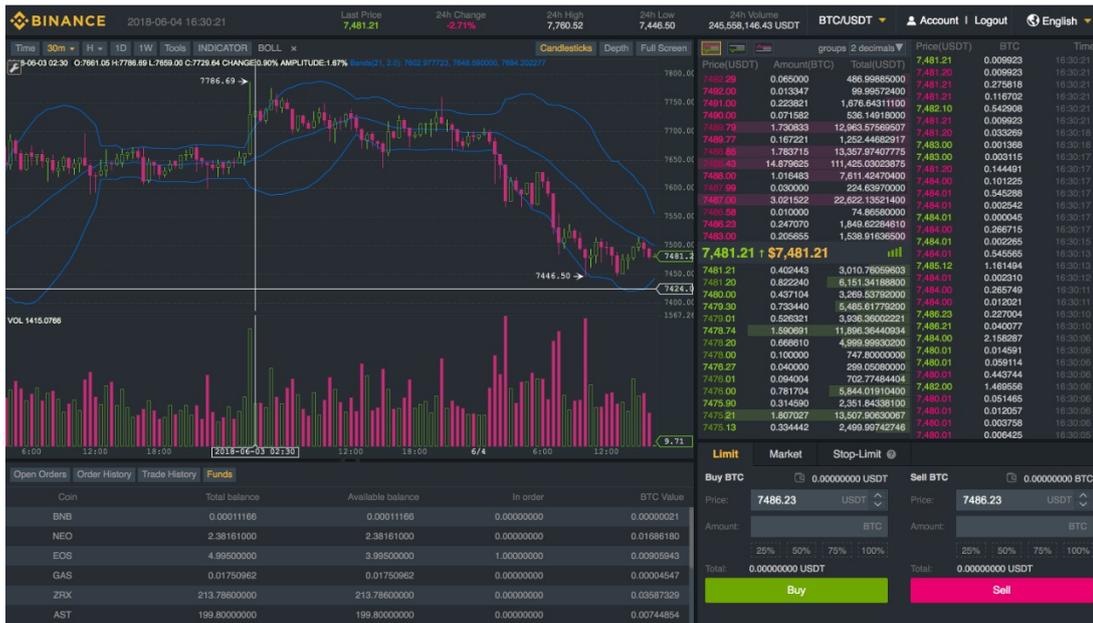


Figura 2.2 – Binance, maior exchange de criptomoedas³

2.4 Indicadores financeiros

Vidotto et al. (2009) explicam que indicadores técnicos como ferramenta de compreensão da movimentação de preços dos ativos negociados em bolsa de valores tem uma crucial importância, pois podem auxiliar na identificação das tendências e de seus pontos de reversão.

Vamos usar como base o gráfico do Bitcoin no período de 01/JAN/2019 a 04/JUN/2019 (Figura 2.3) para a inserção dos indicadores que estão listados a seguir.



Figura 2.3 – Gráfico do Bitcoin / USDT na POLONIEX

2.4.1 Médias Móveis Simples (SMA)

De acordo com Vidotto et al. (2009), a média móvel é uma fotografia do mercado combinando o preço de determinado período. O mercado possui fluxos enormes e a média móvel identifica o sentido da movimentação do mesmo.

As médias móveis são representada por uma linha através do ativo, indicando a média dos preços pelo período analisado. Na Figura 2.4 temos um período de 9 dias, gerando-se uma linha amarela para os valores encontrados a partir do indicador SMA.



Figura 2.4 – Médias Móveis Simples em BTCUSDT entre JAN/2019 a JUN/2019

Uma média móvel simples com período de 5 dias (5-SMA), com os valores diários de fechamento sendo: 11, 12, 13, 14, 15, 16, 17. Podemos observar o cálculo de 3 dias com seus respectivos valores para uma curva de média móvel:

$$\text{Dia 1} : (11 + 12 + 13 + 14 + 15)/5 = 13$$

$$\text{Dia 2} : (12 + 13 + 14 + 15 + 16)/5 = 14$$

$$\text{Dia 3} : (13 + 14 + 15 + 16 + 17)/5 = 15$$

Analisada isoladamente pode não expressar um resultado muito relevante para uma análise técnica, com isso, outros indicadores propuseram melhorias utilizando como base as médias móveis, é o caso do indicador de Bandas de Bollinger.

2.4.2 Bandas de Bollinger (BB)

Como explica o próprio Bollinger (BOLLINGER, 2002), são curvas desenhadas dentro e no entorno da estrutura de preços, consistindo, frequentemente, de uma média móvel (a linha ao

centro), uma banda superior e uma banda inferior, que satisfazem o questionamento se os preços estão altos ou baixos em uma base relativa, funcionando melhor se a banda do meio é escolhida para refletir tendências a médio prazo, sendo a informação de tendência combinadas com dados de níveis relativos de preço.



Figura 2.5 – Bandas de Bollinger em BTCUSDT entre JAN/2019 a JUN/2019

Como observado na Figura 2.5, temos 3 bandas formando as Bandas de Bollinger, sendo elas:

- Banda média = média móvel simples de 20 dias (20-SMA)
- Banda superior = 20-SMA + (20 dias de desvio padrão do preço x 2)
- Banda inferior = 20-SMA - (20 dias de desvio padrão do preço x 2)

2.4.3 Relação entre *Moving Average Convergence Divergence* (MACD) e o Sinal

A Média móvel exponencial (MME ou EMA) é um indicador de tendência, sendo uma média móvel que dá um peso maior para os preços mais recentes, diferentemente da Média Móvel Simples (ver Seção 2.4.1), que os pesos são iguais para o período analisado.

Dois indicativos que contribuem para a análise técnica de compra e venda de ativos são o MACD e o Sinal. O MACD, desenvolvido por Appel (1985), representa a diferença entre

uma média móvel exponencial (MME) de curta e uma de longa duração, como mostrado na Equação 2.1.

$$MACD = MME_{curta} - MME_{longa} \quad (2.1)$$

Segundo Appel (1985) as durações usualmente utilizadas para MME_{curta} e MME_{longa} são 12 e 26, respectivamente.

Já o *Sinal* pode representar os valores da MME de 9 períodos.

Ambos indicadores são apresentados na Figura 2.6. A linha azul corresponde ao indicador *MACD* e linha laranja representa o *Sinal*. Quando a linha de sinal cruza de baixo pra cima a de *MACD* indica um sinal de venda, enquanto ela cruza de cima para baixo indica um sinal de compra.



Figura 2.6 – MACD, Sinal e Histograma MACD

No ano de 1985 foi implementado o Histograma MACD para melhor visualização das relações entre as linhas MACD e o Sinal. Esse histograma pode ser observado nas barras verdes e vermelhas sobre o eixo X. Quanto maiores positivamente, as barras, indicam um fluxo maior de alta do mercado e o contrário é aplicado para um movimento de baixa, auxiliando a leitura da tendência pelo cruzamento das linhas.

Para a construção do *Histograma_MACD* é realizada a diferença entre o *MACD* e o *Sinal*, como pode é representado na Equação 2.2

$$Histograma_MACD = MACD - Sinal \quad (2.2)$$

2.4.4 Stop And Reversal (SAR)

O SAR foi desenvolvido por Welles Wilder, sendo um indicador baseado em preço e tempo: segue o preço à medida que a tendência se estende ao longo do tempo. O indicador está abaixo dos preços à medida que eles estão subindo e acima dos preços à medida que estão caindo, mostrando a tendência do mercado, como observado na Figura 2.7.

O Cálculo do SAR é dividido em duas partes: O primeiro cálculo cobre o aumento da SAR e o segundo cobre a queda da SAR.



Figura 2.7 – SAR em BTCUSDT entre JAN/2019 a JUN/2019

2.4.5 Índice de Força Relativa (RSI)

Segundo Sachetm (2006), o índice de Força Relativa (do inglês *Relative Strength Indice* - RSI) desenha uma linha que mede a força de movimentação do ativo em um gráfico de tempo por uma escala de 0 a 100 pontos, realizando a média dos fechamentos de alta e baixa dos preços em relação há N dias analisados. Sendo a área acima de 70 pontos um mercado sobre-comprado⁴ e abaixo de 30 um mercado sub-vendido⁵.

O RSI pode ser calculado segundo a equação 2.3.

$$RSI = 100 - 100 / (1 + ValorizacaoMedia / DesvalorizacaoMedia) \quad (2.3)$$

A variável *ValorizacaoMedia* corresponde à média dos dias em que o ativo reportou valorização e a *DesvalorizacaoMedia* representa a média dos dias que o ativo reportou desvalorização. Por exemplo, assumindo um período de 10 dias, se o ativo reportou resultados positivos em 5 dias, e a média de valorização desses dias foi de 1%. Neste caso o adotado pela *ValorizacaoMedia* é de 1%/10. Em contrapartida, os outros 5 dias restante o ativo reportou resultados negativos, sendo a média desses resultados igual a 0.5%. Neste caso o adotado pela *DesvalorizacaoMedia* é de 0.5%/10. A desvalorização é calculada utilizando o seu valor absoluto.

⁴ Movimento de valorização intenso

⁵ Movimento de desvalorização intenso

Como podem ser vistos na Figura 2.8, os sinais de compra e venda são dados pela entrada ou saída das regiões entre 30 e 70. A compra é sinalizada pelo cruzamento da linha para acima da região de 30 e a venda pelo cruzamento para baixo da região de 70.



Figura 2.8 – RSI em BTCUSDT entre JAN/2019 a JUN/2019

2.4.6 Biblioteca Ta-Lib

Segundo o site oficial [Ta-Lib](http://ta-lib.org/)⁶, é uma ferramenta multiplataforma para análise de mercado criada em 1999 por Mario Fortier, que possui mais de 200 indicadores técnicos e bibliotecas de código aberto para a utilização deles.

2.5 Redes Neurais Artificiais

As Redes Neurais Artificiais (RNAs), de acordo com OSÓRIO e BITTENCOURT (2000) são ferramentas de Inteligência Artificial que tem a capacidade de adaptação e aprendizagem para realizar uma tarefa ou comportamento, partindo de um conjunto de exemplos dados. De acordo com Osório e OSÓRIO e BITTENCOURT (2000), também são denominadas métodos conexionistas e foram inspiradas em estudos sobre a organização e funcionamento do cérebro humano. A abordagem de redes neurais artificiais, como abordado em Beale e Jackson (1990), vem da captura dos princípios básicos de manipulação de informação do cérebro humano e aplicação desse conhecimento na resolução de problemas que exigem aprendizado a partir da experiência.

Hecht-Nielsen (1988) define o modelo conexionista como uma estrutura de processamento de informações distribuída e paralela, composta por unidades de processamento denominadas nós, neurônios ou células, interconectadas por arcos unidirecionais, chamados de ligações, conexões ou sinapses. Os nós possuem memória local e conseguem realizar operações de processamento de informação localizada. Cada célula tem única saída (axônio), por onde consegue se ramificar em muitas ligações colaterais. Todo processamento que é realizado em cada unidade deve ser local, dependendo somente dos valores correntes dos sinais de entrada que chegam dos neurônios pelas das conexões.

⁶ <http://ta-lib.org/>

De acordo com [Mueller et al. \(1996\)](#), as redes neurais artificiais apresentam como características marcantes abstração, generalização e aprendizado. A abstração é a característica de retirar a essência do conjunto de dados apresentado para a rede, o que permite reconhecimento e classificação de padrões incompletos. Generalização é a capacidade de adaptação da rede a novas situações, sendo sensíveis a variações, como ruído e distorção, sendo muito importante para a aplicabilidade da rede neural. [Carbonell, Michalski e Mitchell \(1989\)](#) definem aprendizado como capacidade de fazer tarefas novas que não poderiam ser antes, ou, como resultado desse processo, aprimorar a execução de tarefas antigas: é a característica das redes neurais artificiais mais interessante. [Faber \(2016\)](#) mostra que o processo de aprendizagem de redes neurais artificiais pode ser feito com dados durante a operação, online, ou com dados previamente coletados.

De acordo com [Roque et al. \(2018\)](#), os neurônios artificiais das Redes Neurais Artificiais produzem saídas contínuas não-lineares a partir de dados submetidos a eles como entrada, sendo cada sinal de entrada ponderado por valores (pesos sinápticos). A união linear dos sinais e seus respectivos pesos é colocada em função de ativação, que irá sair ou responder ao neurônio.

2.5.1 Aprendizagem em profundidade (Deep Learning)

Como colocam [Goodfellow, Bengio e Courville \(2016\)](#), aprendizagem em profundidade é uma abordagem de inteligência artificial que permite a própria rede aprender com a experiência e entender o mundo a partir de uma hierarquia de conceitos, relacionando cada dado ao conceito mais simples. Concedendo o entendimento de tarefas formais e abstratas diretamente para a máquina, podendo ser mais fácil do que para humanos. Diferindo-se das redes com aprendizagem "rasas" ou "superficiais", que utilizam diretamente de uma função estática para a obtenção e cálculo dos resultados desejados, como explicam [Ponti e Costa \(2018\)](#). O sucesso das técnicas de aprendizado de máquina para a previsão do mercado de ações, de acordo com [Alessandretti et al. \(2018\)](#) nos faz pensar que esses métodos podem ser eficazes também na previsão de valores de criptomoedas.

Existem vários tipos de arquiteturas e topologias de redes neurais que são amplamente utilizadas em muitas aplicações do dia a dia. Como por exemplo detecção de rostos feitas em plataformas do Google com algoritmos de redes neurais convolucionais como ocorrem com a FaceNet ([SCHROFF; KALENICHENKO; PHILBIN, 2015](#)). Outro exemplo é na tradução de idiomas com as redes neurais recorrentes, que são muito utilizadas também para predição de séries temporais, com isso investigamos-a para a utilização neste trabalho.

2.5.2 Redes neurais recorrentes

Redes neurais recorrentes são um tipo de rede neural artificial projetada para reconhecer padrões em sequências de dados. Segundo [Vieira, Lemos e Lee \(2003\)](#), tais redes evoluem utilizando equações não-lineares. Desta forma ela tem a capacidade de modelar sistemas dinâmicos,

sendo muito utilizada para predições de séries temporais, devido ao fato de extrair e aprender com dados relevantes do passado (ver Figura 2.9).

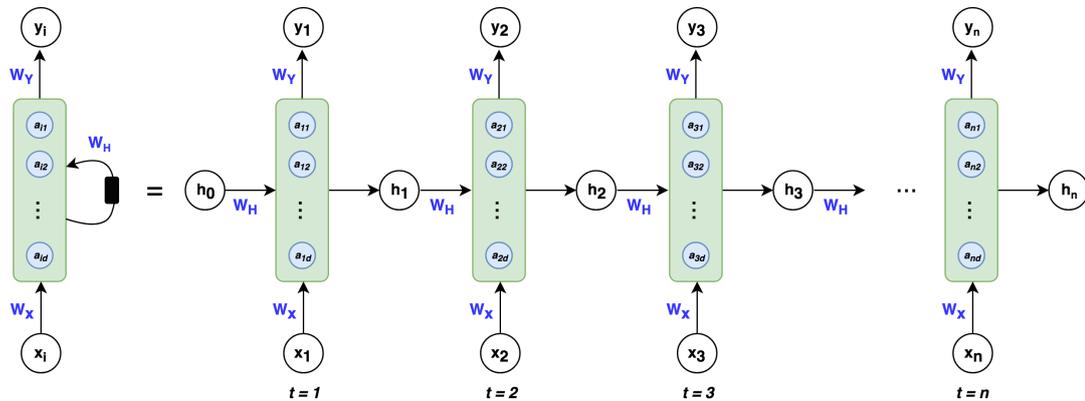


Figura 2.9 – Entrada/Saída de uma rede neural recorrente⁷.

As RNNs possuem algumas limitações em relação a capacidade de "lembrar" de grandes quantidades de dados ao longo do processo, para tal, surgiu em 1997 por Hochreiter e Schmidhuber (1997) uma variação da rede com uma arquitetura conhecida como *Long Short-Term Memory* (LSTM) que solucionou essa limitação (Figura 2.10). Várias aplicações utilizam a LSTM para sua solução como processamento de linguagem natural e predições em séries temporais. Como são eficientes dimensões temporais, utilizaremos tal arquitetura para reconhecer os padrões das cotações diárias e prever padrões futuros de preços para o Bitcoin.

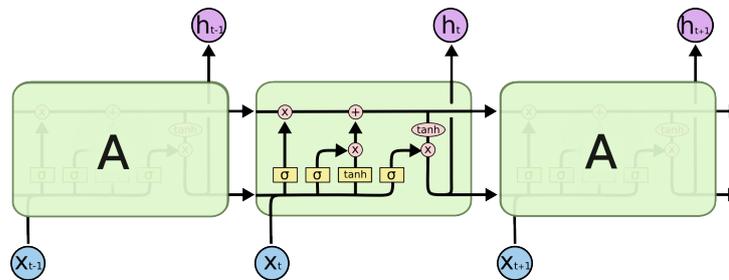


Figura 2.10 – Representação da estrutura da LSTM⁸.

2.6 Raiz Quadrada do Erro Quadrático Médio - RMSE

Com o objetivo de analisar a qualidade do modelo gerado, é necessário realizar uma comparação com o resultado obtido com o resultado esperado. Neste sentido, a Raiz Quadrada do Erro Quadrático Médio (do Inglês *Root-Mean-Squared Error* - RMSE) é uma medida frequentemente utilizada para calcular o erro entre os valores previstos por um modelo e os valores observados (GOOIJER; HYNDMAN, 2006).

⁷ Disponível em: <https://bit.ly/2r54DAo>. Acessado em: 16/12/2019

⁸ Disponível em: <https://bit.ly/36Tmn0L>. Acessado em: 16/12/2019

A RMSE é representada na Equação 2.4.

$$RMSE = \sqrt{\sum_{i=1}^n (x_i - y_i)^2 / n} \quad (2.4)$$

A equação calcula a raiz quadrada do somatório da diferença entre os valores que foram previstos pelo modelo (representado pela variável x), e os valores observados (representado pelo variável y). A variável n corresponde ao número total de observações, enquanto a i representa a observação atual.

3 Trabalhos Relacionados

Apesar de ser um tema atual, nos anos 90 já existia registros de trabalhos nacionais envolvendo redes neurais auxiliando na previsão de mercados. Segundo [Mueller et al. \(1996\)](#), o modelo conexionista como ferramenta alternativa para previsão e manipulação de séries de cotações com resultados muito próximos aos valores observados, inclusive muito melhores que alguns métodos convencionais, deixando inclusive observações a serem pesquisadas no futuro.

Em 2013, [Dong, Fataliyev e Wang \(2013\)](#) desenvolvem um método de Redes Neurais de Propagação para prever um ciclo à frente no mercado de ações, e verificam que a qualidade dos dados de treinamento é o mais importante para uma previsão bem sucedida, deixando brechas no futuro para novos estudos com variáveis de melhor qualidade, prevendo melhor o mercado de ações.

No trabalho proposto em [Faber \(2016\)](#) utiliza-se duas diferentes redes neurais para prever valores de ações futuros da PETR4: uma rede perceptron multicamada e uma rede neural convolucional profunda, sendo ambas entradas em banco de dados de interesse por tempo dos usuários da Google sobre temas selecionados e o histórico dos valores de mercado das ação selecionada (Google Trends). O resultado da rede perceptron multicamada é melhor, prevendo 68,22%, ao passo que a rede neural convolucional prevê 59,81%, sendo ambas melhores que um classificador ingênuo, que estima uma continuidade no padrão do dia anterior, com taxa de acerto de 50,72%.

Mais especificamente na área de previsão de criptomoedas, em 2016, [Kim et al. \(2016\)](#) propõe um modelo de previsão baseado nos comentários e respostas postados em comunidades on-line relevantes para criptomoedas, especificamente em fóruns de Bitcoin, Ethereum e Ripple, usando a hipótese de que comentários de usuários em certas comunidades on-line de criptomoeda pode afetar flutuações em seu preço e volume de negociação. Por meio de um algoritmo denominado VADER ([HUTTO; GILBERT, 2014](#)), os comentários são filtrados e analisados estatisticamente pelo sentimento que transmitem, sendo os extremos positivos e negativos excluídos. O resultado é positivo para a hipótese trabalhada, sendo a previsão mais consistente no sistema do Bitcoin, mostrando que a opinião dos usuários pode ser usada para ajudar a prever flutuações no mercado. Porém, os próprios autores sugerem que devem ser testados futuramente critérios mais qualitativos para a previsão.

[Radityo, Munajat e Budi \(2017\)](#) faz uma comparação de previsão de câmbio de Bitcoin para dólar americano utilizando quatro métodos de rede neural artificial: rede neural de retropropagação, algoritmo genético da rede neural, algoritmo genético rede neural de retropropagação e neuroevolução de topologias aumentadas, sendo o método mais preciso de algoritmo genético rede neural de retropropagação e o menos preciso rede neural do algoritmo genético, porém

como o primeiro precisa de muito treinamento e há pouca diferença de precisão entre os dois melhores, concluem que seria mais viável utilizar a rede neural de retropropagação em Bitcoin.

[Alessandretti et al. \(2018\)](#), avaliam o desempenho de três modelos na previsão do preço diário de 1.681 criptomoedas entre novembro de 2015 e abril 2018. O primeiro e o segundo modelo trabalham com árvores de regressão construídas pelo algoritmo XGBoost, considerando preço, capitalização de mercado, participação no mercado, classificação, volume e ROI. O primeiro método utiliza um único modelo de regressão para descrever a mudança de preço de todas as moedas, enquanto no segundo modelo o algoritmo é usado para construir uma regressão diferente para cada moeda. O terceiro método é baseado em redes de memória de longo prazo, um tipo especial de redes neurais recorrentes, capazes de aprender dependências de longo prazo. Como modelo-base é utilizada estratégia de médias móveis simples (SMA). Os três métodos testados funcionam melhor que o método base, sendo os dois primeiros melhores para uma previsão de 5-10 dias, e o segundo melhor em previsão que o primeiro. Por fim, os autores sugerem que a prever simultaneamente a tendência geral de mercado de criptomoedas junto a moedas individuais é mais desafiador do que a previsão de moedas individuais isoladas.

No mesmo ano, [Velankar, Valecha e Maji \(2018\)](#) propõem dois métodos para predição de Bitcoin utilizando as bases de dados Quandl e CoinMarketCap, após filtragem de dados: Regressão Bayesiana e Modelo Linear Generalizado/Floresta Aleatória (Random Forest).

Utilizando a Regressão Bayesiana em séries temporais de Bitcoin, Jang ([JANG; LEE, 2017](#)) mostram bom desempenho do método na previsão de preço e explicação de alta volatilidade do preço recente do Bitcoin.

Em relação à Redes Neurais Recorrentes, [McNally \(2016\)](#) compara a Rede Neural Bayesiana Otimizada (RNN) e *Long Short Term Memory* (LSTM) ao tradicional modelo ARIMA para previsão de séries temporais, e encontra-o pior do que os modelos de redes neurais, sendo que o LSTM supera o RNN, mas sem diferença significativa. Além disso, o LSTM demora muito mais tempo de treinamento que RNN e ARIMA. Após, treinou o LSTM em GPU e CPU, encontrando o treinamento em GPU 70,7% melhor em desempenho.

Atualmente [Duarte e Lima \(2019\)](#) demonstram um modelo de predição temporal para o Ether comparando duas redes neurais: *Multilayer Perceptrons* (MLP) e *Bidirectional Long Short Term Memory Units* (bi-LSTM), e conseguem como resultado o bi-LSTM com desempenho um pouco melhor que a MLP.

[Huisu et al. \(2018\)](#) utiliza o LSTM para realizar uma análise temporal de preços de Bitcoin com os seguintes parâmetros: preços, log do preço do Bitcoin e log da volatilidade do preço do Bitcoin. Mais especificamente, eles usam uma camada oculta com 10 neurônios e as seguintes características de entrada: informações de negociação, variáveis macroeconômicas, índices de moeda global e informações sobre blockchain. A escolha de incluir as informações da blockchain foi baseada no impacto que isso tem sobre a popularidade da moeda. Eles utilizam a

raiz quadrada do erro quadrático médio (RMSE) para avaliar a qualidade do método proposto. Os autores relatam que o melhor resultado obtido foi 0,01 para o RSME, com os valores de duração da sequência e duração do treinamento igual a 200 e 150 respectivamente.

4 Desenvolvimento

Para o desenvolvimento do projeto foram utilizadas algumas bibliotecas e repositórios de código aberto para a extração, modelagem e análise dos dados.

4.1 Base de Dados

A base dados é extraída com o auxílio da plataforma open-source [CryptoDataDownload](https://www.cryptodatadownload.com/)¹ que disponibiliza dados do mercado de diversas criptomoedas contidas em variadas casas de câmbio (exchanges). A exchange escolhida foi a [Bitstamp](https://www.bitstamp.net/)², sendo, segundo o [CoinMarketCap](https://coinmarketcap.com/)³, a casa de câmbio mais antiga do mercado de criptomoedas em vigência.

Os dados são disponibilizados no seguinte formato para todos valores diários:

- Data: Dia analisado
- Símbolo: Combinação da moeda negociada em sua paridade, no caso do trabalho, bitcoin para dólar (BTCUSD)
- Abertura: Valor inicial
- Máxima: Valor máximo atingido
- Mínima: Valor mínimo atingido
- Fechamento: Último valor atingido
- Volume BTC: Quantidade total negociada em Bitcoin
- Volume USD: Quantidade total negociada em dólar

Aproximadamente temos 1800 pontos de movimentação do gráfico do Bitcoin (ver Tabela 4.1) com valor de fechamento de cada dia sendo um ponto, chamamos tais pontos de "Curva", totalizando de 365 pontos por ano. Os dados obtidos a partir do [CryptoDataDownload](https://www.cryptodatadownload.com/) são desde 2014 até dezembro de 2019. Com os dados em mãos, a biblioteca [Ta-lib](https://github.com/mrjbjq7/ta-lib)⁴ trata-os com a aplicação dos indicadores gráficos apresentados na Seção 2.4, preparando os dados para um vetor de características que serão utilizados posteriormente com os modelos de Redes Neurais Recorrentes.

¹ <https://www.cryptodatadownload.com/data/northamerican/>

² <https://www.bitstamp.net/>

³ <https://coinmarketcap.com/>

⁴ <https://github.com/mrjbjq7/ta-lib>

Tabela 4.1 – Amostra de dados do dia 28/01/2019 ao dia 01/02/2019

Data	Símbolo	Abertura	Máxima	Mínima	Fechamento	Volume BTC	Volume USD
2019-02-01	BTCUSD	3413.11	3460	3364.53	3434.83	6659.85	22735654.44
2019-01-31	BTCUSD	3437.35	3474.2	3392.6	3413.11	5951.82	20359058.48
2019-01-30	BTCUSD	3390.5	3465.05	3372.34	3437.35	5704.02	19556298.64
2019-01-29	BTCUSD	3429.5	3438.76	3322.19	3390.5	7284.39	24704685.92
2019-01-28	BTCUSD	3533.23	3536.77	3357.3	3429.5	10345.1	35519461.33

4.2 Pré-Processamento

Uma fase muito importante é a de pré-processamento dos dados. Nesta etapa são feitos os tratamentos necessários no vetor de características que antecedem a entrada no treinamento. Dividida nos seguintes passos:

1. Ordenação dos dados ascendentemente pelas datas. Essa primeira fase é necessária para que todas as datas estejam da mais antiga para a mais recente, à fim de organizar os dados para o aprendizado do passado até os dados mais recentes:

```
1 data = data.sort_values(by=['Data'], ascending=True)
```

Algoritmo 4.1 – Ordenação do banco de dados

2. Somente a coluna de fechamento (dados da curva) são copiados para o novo vetor de características, denominado "values". Sendo as colunas de abertura, máxima, mínima e os volumes do Bitcoin e Dólar desnecessárias para o treinamento do modelo:

```
1 values = data['Fechamento'].values.reshape(-1,1)
2 values = values.astype('float32')
```

Algoritmo 4.2 – Cópia do Fechamento para vetor de características

3. Vetores referentes a cada indicador são calculado com a biblioteca Ta-Lib:

```
1 indic_sar = (talib.SAR(data['High'], data['Low']))
2 indic_sar = indic_sar.values.reshape(-1,1)
3 indic_sar = indic_sar.astype('float32')
4
5 indic_sma = (talib.SMA(np_float_data, 5))
6 indic_sma = indic_sma.reshape(-1,1)
7 indic_sma = indic_sma.astype('float32')
8
9 indic_rsi = (talib.RSI(np_float_data, 14))
10 indic_rsi = indic_rsi.reshape(-1,1)
11 indic_rsi = indic_rsi.astype('float32')
```

Algoritmo 4.3 – Biblioteca Ta-Lib em Python

4. Vetores calculados no passo anterior são concatenados ao novo vetor de características:

```
1 values = tf.concat(axis=1, values=[values, indic_rsi])
2 values = tf.concat(axis=1, values=[values, indic_sma])
3 values = tf.concat(axis=1, values=[values, indic_sar])
```

Algoritmo 4.4 – Concatenação de indicadores

5. Remoção de dados inválidos ou nulos do vetor de características gerado:

```
1 dataset = pd.DataFrame({'Curva': values[:, 0],
2                         'RSI': values[:, 1],
3                         'SMA': values[:, 2],
4                         'SAR': values[:, 3]
5 })
6 values = dataset.dropna().values
```

Algoritmo 4.5 – Remoção de valores nulos

Após a realização dos passos anteriores é gerado o vetor de características no formato da Tabela 4.2:

Tabela 4.2 – Amostra do dia 25/11/19 à 29/11/19 do vetor de características

Curva	RSI	SMA	SAR
6908.359863	22.332123	7442.910156	8509.305664
7122.140137	28.428631	7249.649902	8267.903320
7159.220215	29.462856	7159.191895	7987.438477
7527.839844	38.913166	7207.589844	7751.848145
7600.970215	40.613068	7263.706055	7676.270020

No entanto, para a conversão do modelo, os dados são normalizados para uma faixa de valores entre 0 e 1 com a função *MinMaxScaler*:

```
1 scaler = MinMaxScaler(feature_range=(0, 1))
2 scaled = scaler.fit_transform(values)
```

Algoritmo 4.6 – Normalização do vetor de características

4.3 Modelagem

Para a modelagem dos dados, temos a entrada com o vetor de características das últimas duas semanas do Bitcoin juntamente com os valores dos indicadores, como explicado na Seção 4.1. A partir disso, o pré-processamento é realizado e submetido a métodos de redes recorrentes em profundidade, a fim de otimizar os lucros e proporcionar maior segurança para o investidor. A saída das redes deve informar o melhor posicionamento para ordens de compra/venda no

dia seguinte. Para tal, o modelo é composto por uma arquitetura rasa com uma camada de LSTM (Seção 2.5.2) e uma camada fortemente conexa, popularmente denominada "Densa"(ver Figura 4.1).

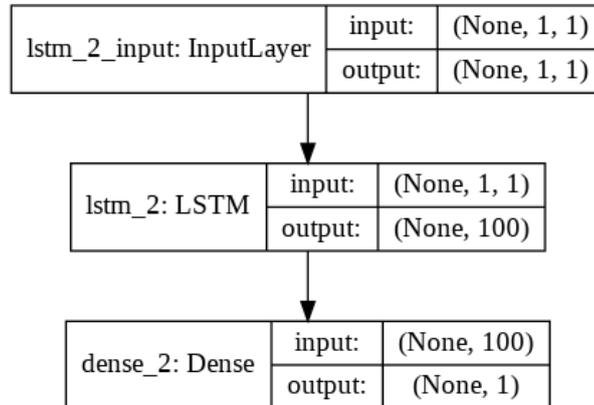


Figura 4.1 – Visualização gerada pelo TensorFlow do modelo.

Utilizamos o otimizador ADAM (KINGMA; BA, 2014) para os pesos e juntamente o método de erro médio absoluto (MAE) para avaliação da perda do modelo, conhecido como *loss*.

```

1 model = Sequential()
2 model.add(LSTM(100, input_shape=(trainX.shape[1], trainX.shape[2])))
3 model.add(Dense(1))
4 model.compile(loss='mae', optimizer='adam')
5 history = model.fit(trainX, trainY, epochs=100,
6                     batch_size=100, validation_data=(testX, testY),
7                     verbose=1, shuffle=False)

```

Algoritmo 4.7 – Modelo proposto

5 Experimentos e Resultados

Todos experimentos utilizam máquinas gratuitas disponibilizadas pelo ambiente do [Google Colab](#)¹ com as seguintes especificações:

- GPU: 1xTesla K80 3.7, 2496 CUDA cores, 12GB GDDR5 VRAM
- CPU: 1xXeon Processors @2.3Ghz (1 core, 2 threads)
- RAM: aproximadamente 12.6 GB Disponíveis
- Disco: aproximadamente 33 GB Disponíveis

Com todos passos realizados no Capítulo 4, o vetor de características resultante é dividido em 70% dos dados para treino e os outros 30% para testes e está pronto para realizar as experimentações:

```
1 train_size = int(len(scaled) * 0.7)
2 test_size = len(scaled) - train_size
3 train, test = scaled[0:train_size,:], scaled[train_size:len(scaled),:]
```

Algoritmo 5.1 – Divisão de dados de treinamento e teste

Os experimentos foram realizados com todas combinações dos 3 indicadores (RSI, SMA, SAR) com a curva do gráfico, totalizando 8 experimentos para cada um dos três seguintes períodos:

I - 28/11/2014 à 29/11/2019

II - 01/01/2017 à 31/12/2017

III - 01/01/2018 à 31/12/2018

Todos experimentos acima foram realizados utilizando totalmente ou partes do gráfico da Figura 5.1 que possuem ao seu total 1802 pontos.

¹ <https://colab.research.google.com/>

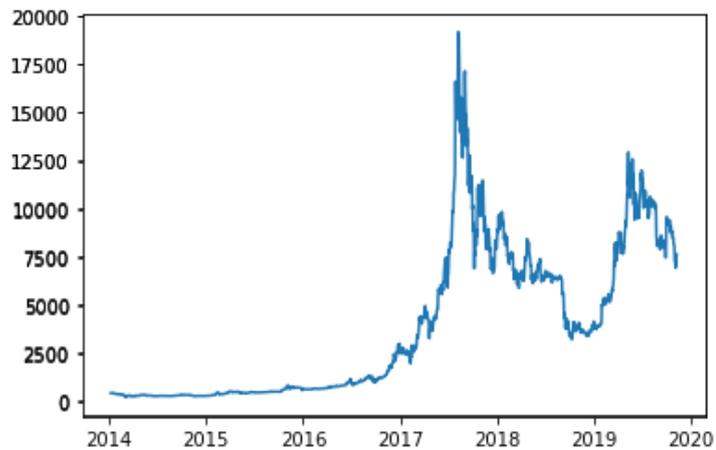


Figura 5.1 – Curva real da base de dados de 28/11/2014 até 29/11/2019.

Com tais dados, temos a Figura 5.2 demonstrando o experimento do período I com 2 casos extremos: o primeiro com somente a Curva do gráfico e outro com a Curva e os demais indicadores como observado respectivamente nos itens (a) e (b). Obtemos a seguinte predição:

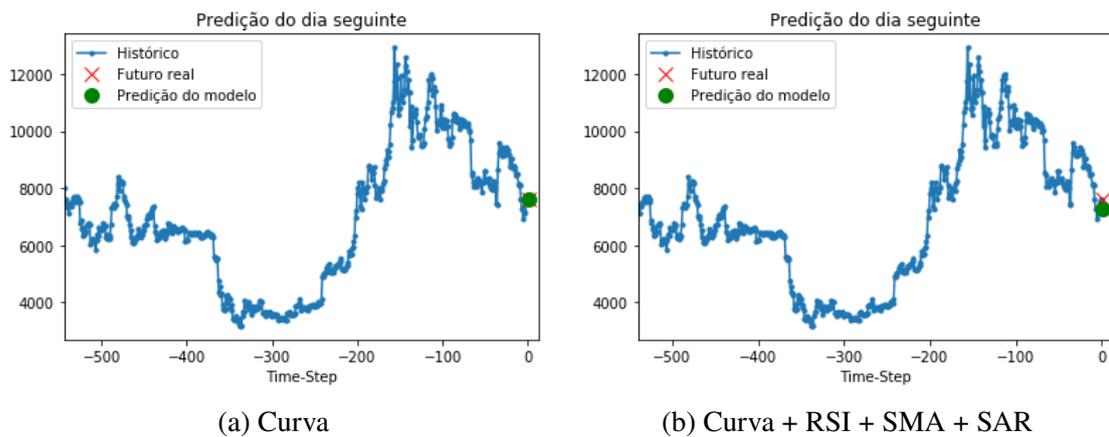


Figura 5.2 – Experimentos do período I de 2014 à 2019

Nas Figuras 5.3(a) e 5.4(a) temos o período II de dados de setembro a dezembro (30% utilizados para treino) com o mercado positivo e otimista. Já o período III está presente nas figuras 5.3(b) e 5.4(b), com um mercado negativo e pessimista.

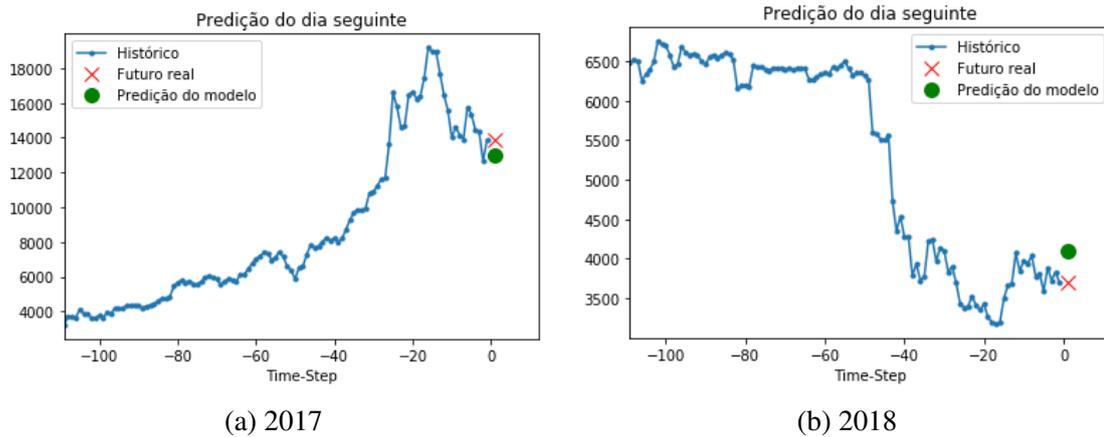


Figura 5.3 – Experimentos com dados da Curva dos teste.

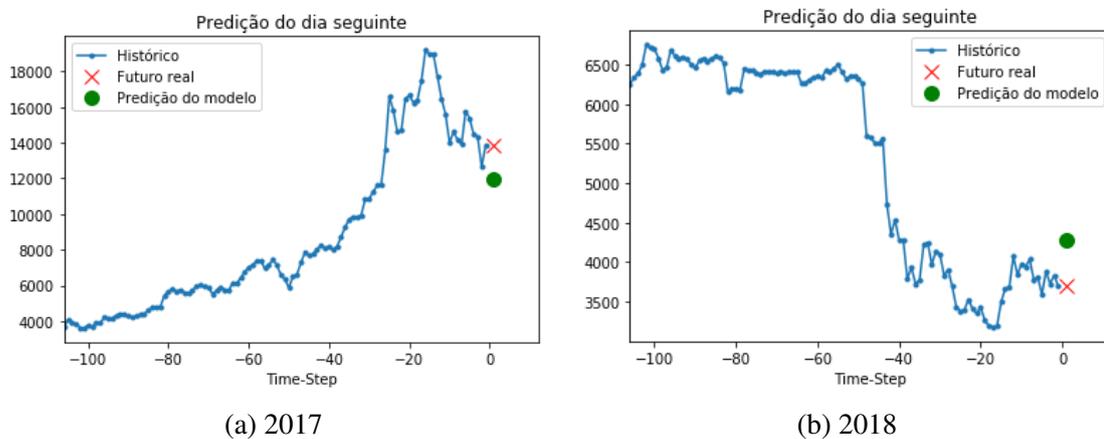


Figura 5.4 – Experimentos com dados da Curva + RSI + SMA + SAR

Visto os gráficos gerados nos experimentos acima, temos que nosso modelo proposto realiza uma predição mais ineficiente em momentos de grande volatilidade, o que ocorre nas figuras 5.3 e 5.4 em comparação ao ocorrido na Figura 5.2.

Em relação a análise isolada de 2017 e 2018, temos nos experimentos um resultado oposto. Em 2017 o modelo realizou a predição mais pessimista que o mercado, já em 2018 o modelo é mais otimista. Devido ao fato que o modelo realiza sua fase de treinamento em períodos que há uma tendência linear de alta para as Figuras 5.3(a) e 5.4(a) e de baixa nas Figuras 5.3(b) e 5.4(b). Porém, ao realizar os testes com tal aprendizado, o oposto ocorre e a predição ocorre da forma que observamos em tais figuras.

5.1 Discussão dos Resultados

Após a permutação das experimentações realizadas, obtemos a Tabela 5.1 com seus respectivos indicadores utilizados (ver Seção 2.4) pelos valores de RMSE (ver Seção 2.6) dos 3

períodos avaliados: de 2014 à 2019, ano completo de 2017 e ano completo de 2018, resultando em 24 valores:

Tabela 5.1 – Comparativo do RMSE da permutações da Curva + Indicadores

Experimentos	2014 - 2019	2017	2018
Curva	304.020	696.822	260.137
Curva + RSI	313.099	661.605	296.591
Curva + SMA	351.840	726.792	286.223
Curva + SAR	427.505	652.646	300.844
Curva + RSI + SMA	309.483	868.329	333.294
Curva + RSI + SAR	361.006	645.998	297.060
Curva + SAR + SMA	360.713	853.971	302.930
Curva + RSI + SMA + SAR	334.261	956.755	334.000

Analisando os dados acima, podemos perceber que tivemos o melhor resultado do RMSE para somente o valor da Curva em 2018 com o valor igual a **260.137** e o pior resultado foi referente a 2017 com a utilização da Curva e os indicadores RSI, SMA e SAR com valor igual a **956.755**.

Os resultados para o período I e período III foram bem semelhantes como observado na tabela acima. Já o período II pode-se observar que tivemos valores muito maiores que a média devido ao fato da grande instabilidade.

6 Conclusão

Com base na revisão de literatura, podemos observar que *machine learning*, ou mais precisamente, redes neurais recorrentes, podem ser uma ferramenta promissora para a resolução do problema aqui proposto, isto é, definir o momento e operação a ser realizada no câmbio do Bitcoin. Muitos autores já investigaram a aplicação de redes profundas para prever esse tipo de série temporal em outros contextos, inclusive.

Todavia, acreditamos que o Bitcoin tem uma volatilidade muito maior que os ativos convencionais por sofrer radicalmente várias influências externas no valor da criptomoeda, como por exemplo, especulações em redes sociais e notícias de cunho econômico mundial. Assim, acreditamos que tais métodos de previsão necessitam de mais informações de entrada além de dados observados nos gráficos.

O período de 2017 e 2018 foram nitidamente muito atípicos. Esse trabalho visa investigar o comportamento dos métodos nesse contexto de grande volatilidade, e se é possível operá-lo com lucro em momentos de grande euforia sendo em mercado otimista ou pessimista. No entanto o modelo não se comportou eficientemente para tais períodos como para o período completo do Bitcoin.

Para os parâmetros do nosso trabalho, quanto menor o RMSE melhor. Como observado na Tabela 5.1, o melhor resultado de RMSE foi o experimento somente com dados da curva de 2018, porém não é possível uma comparação em valores reais (dólares), pois o RMSE é calculado a partir de todo o conjunto de dados selecionados para teste.

Como é um tema novo em pesquisa, sugerimos que poderiam ser utilizadas mais ferramentas, isoladas ou em conjunto, para treinamento do modelo, podendo resultar em uma melhor previsão do Bitcoin. Nosso trabalho seria o início de novos experimentos, buscando um conjunto de parâmetros de avaliação para a previsão do Bitcoin.

6.1 Trabalhos Futuros

Concluimos no Capítulo 6 que para realizarmos uma melhor previsão do preço do Bitcoin necessitamos de mais variáveis além de dados gráficos, alguns trabalhos futuros que podem contribuir para tal melhoria, seriam:

- Realizar comparações de modelos clássicos de econometria financeira de previsão de modelagem de ativos, como por exemplo: Autorregressivos medias moveis (ARMA) e Autorregressivos de heterocedasticidade na volatilidade (GARCH);

- Utilizar entradas na rede com sentimentos de notícias e informações das redes sociais sobre o período analisado;
- Utilizar log-retornos em dados de entrada do modelo para o tornar mais estável, técnica muito utilizadas na literatura de finanças.

Referências

- ALESSANDRETTI, L. et al. Anticipating cryptocurrency prices using machine learning. *Complexity*, Hindawi, v. 2018, 2018.
- ANTONOPOULOS, A. M. *Mastering Bitcoin: unlocking digital cryptocurrencies*. [S.l.]: "O'Reilly Media, Inc.", 2014.
- APPEL, G. *The moving average convergence-divergence trading method: advanced version*. [S.l.]: Scientific Investment Systems, 1985.
- ARAGÃO, D. C. Bitcoin: Uma análise sobre a evolução das taxas de transação. Universidade Federal de Pernambuco, 2016.
- BARBOSA, P. C. L. Bitcoin e moedas fiat: um estudo de volatilidade comparada. *Fundação Instituto de Pesquisas Econômicas—FIPE, São Paulo*, p. 75, 2016.
- BEALE, R.; JACKSON, T. *Neural Computing-an introduction*. [S.l.]: CRC Press, 1990.
- BOLLINGER, J. *Bollinger on Bollinger bands*. [S.l.]: McGraw-Hill New York, 2002.
- BUKOVINA, J.; MARTIČEK, M. et al. *Sentiment and bitcoin volatility*. [S.l.], 2016.
- CARBONELL, J. G.; MICHALSKI, R. S.; MITCHELL, T. M. Machine learning: a historical and methodological analysis. 1989.
- CATANIA, L.; GRASSI, S.; RAVAZZOLO, F. Predicting the volatility of cryptocurrency time-series. In: *Mathematical and Statistical Methods for Actuarial Sciences and Finance*. [S.l.]: Springer, 2018. p. 203–207.
- CROSBY, M. et al. Blockchain technology: Beyond bitcoin. *Applied Innovation*, v. 2, n. 6-10, p. 71, 2016.
- DONG, G.; FATALIYEV, K.; WANG, L. One-step and multi-step ahead stock prediction using backpropagation neural networks. In: *IEEE. 2013 9th International Conference on Information, Communications & Signal Processing*. [S.l.], 2013. p. 1–5.
- DOWNES, J.; GOODMAN, J. E. *Dicionário de termos financeiros e de investimento*. [S.l.]: NBL Editora, 1993.
- DUARTE, F. L. C.; LIMA, N. C. de A. Redes neurais aplicadas na predição do preço do ether: Mlp vs bi-lstm. *Anais do Encontro de Computação do Oeste Potiguar ECOP/UFERSA (ISSN 2526-7574)*, n. 3, 2019.
- FABER, P. H. H. *PREVISÃO DE VALORES DE AÇÕES UTILIZANDO DEEP LEARNING*. Tese (Doutorado) — Dissertação (Trabalho de Graduação em Engenharia de Controle e Automação), 2016.
- FREITAS, E. A. de. Moeda, câmbio e conversões monetárias. 2008.
- GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. *Deep learning*. [S.l.]: MIT press, 2016.

- GOOIJER, J. G. D.; HYNDMAN, R. J. 25 years of time series forecasting. *International journal of forecasting*, Elsevier, v. 22, n. 3, p. 443–473, 2006.
- GUO, T.; ANTULOV-FANTULIN, N. Predicting short-term bitcoin price fluctuations from buy and sell orders. *arXiv preprint arXiv:1802.04065*, 2018.
- HECHT-NIELSEN, R. Applications of counterpropagation networks. *Neural networks*, Elsevier, v. 1, n. 2, p. 131–139, 1988.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural computation*, MIT Press, v. 9, n. 8, p. 1735–1780, 1997.
- HUISU, J. et al. Predicting bitcoin prices by using rolling window lstm model. In: *2018 Data Science in FinTech (DSF)*. [S.l.: s.n.], 2018.
- HUTTO, C. J.; GILBERT, E. Vader: A parsimonious rule-based model for sentiment analysis of social media text. In: *Eighth international AAAI conference on weblogs and social media*. [S.l.: s.n.], 2014.
- IGNÁCIO, L. V. R. et al. *O uso de inteligência artificial para a previsão do preço do petróleo*. [S.l.]: Revista Espacios, 2016.
- JANG, H.; LEE, J. An empirical study on modeling and prediction of bitcoin prices with bayesian neural networks based on blockchain information. *Ieee Access*, IEEE, v. 6, p. 5427–5437, 2017.
- KIM, Y. B. et al. Predicting fluctuations in cryptocurrency transactions based on user comments and replies. *PloS one*, Public Library of Science, v. 11, n. 8, p. e0161197, 2016.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014.
- MCNALLY, S. *Predicting the price of Bitcoin using Machine Learning*. Tese (Doutorado) — Dublin, National College of Ireland, 2016.
- MEDEIROS, D. D.; FRANCHINI, A. A. A taxa de câmbio e seus efeitos na balança comercial. Instituto Viana Júnior, 2007.
- MOHNOT, R. Forecasting forex volatility in turbulent times. *Global Journal of Business Research*, v. 5, n. 1, p. 27–38, 2011.
- MUELLER, A. et al. Uma aplicação de redes neurais artificiais na previsão do mercado acionário. Universidade Federal de Santa Catarina, 1996.
- NAKAMOTO, S. Bitcoin: A peer-to-peer electronic cash system. Manubot, 2009.
- NEVES, R. H. d. *Precificação do bitcoin: impacto de variáveis de atratividade*. Tese (Doutorado) — FUNDAÇÃO GETULIO VARGAS, 2018.
- OSÓRIO, F. S.; BITTENCOURT, J. R. Sistemas inteligentes baseados em redes neurais artificiais aplicados ao processamento de imagens. In: *I WORKSHOP DE INTELIGÊNCIA ARTIFICIAL UNISC—Universidade de Santa Cruz do Sul Departamento de Informática-Junho*. [S.l.: s.n.], 2000.
- PARINO, F.; BEIRÓ, M. G.; GAUVIN, L. Analysis of the bitcoin blockchain: socio-economic factors behind the adoption. *EPJ Data Science*, SpringerOpen, v. 7, n. 1, p. 38, 2018.

- PONTI, M. A.; COSTA, G. B. P. da. Como funciona o deep learning. *arXiv preprint arXiv:1806.07908*, 2018.
- RADITYO, A.; MUNAJAT, Q.; BUDI, I. Prediction of bitcoin exchange rate to american dollar using artificial neural network methods. In: IEEE. *2017 International Conference on Advanced Computer Science and Information Systems (ICACSIS)*. [S.l.], 2017. p. 433–438.
- RODRIGUES, C. K. da S. Sistema bitcoin: uma análise da segurança das transações. *Revista Brasileira de Sistemas de informação*, v. 10, p. 97, 2017.
- ROQUE, L. et al. Análise de estilo de programação com rede neural recorrente para aprovação automática de pull request. Intelligence for Software RESEARCH GROUP, 2018.
- SACHETIM, H. M. Análise técnica: estudo da confiabilidade dos principais indicadores de análise técnica, aplicados as ações mais negociadas na bovespa no período de 1995 a 2005. 2006.
- SANDRONI, P. Novíssimo dicionário de economia, 13. *São Paulo: Editora Best Seller*, 2004.
- SCHROFF, F.; KALENICHENKO, D.; PHILBIN, J. Facenet: A unified embedding for face recognition and clustering. In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. [S.l.: s.n.], 2015. p. 815–823.
- SILVA, R. M. P. A evolução da moeda e a bitcoin: um estudo da validade da bitcoin como moeda. *Revista da Graduação*, v. 9, n. 2, 2016.
- STEVENSON, J. *Getting started with Litecoins (after Bitcoin)*. [S.l.]: John Stevenson, 2013.
- TRESS, E. H. H. *UMA REVISÃO DA LITERATURA SOBRE O COMPORTAMENTO DOS PREÇOS DO BITCOIN: TRATA-SE DE UMA BOLHA ESPECULATIVA?* Tese (Doutorado) — Universidade Federal do Rio de Janeiro, 2017.
- ULRICH, F. Bitcoin. *A moeda na era digital*, p. 18, 2014.
- VELANKAR, S.; VALECHA, S.; MAJI, S. Bitcoin price prediction using machine learning. In: IEEE. *2018 20th International Conference on Advanced Communication Technology (ICACT)*. [S.l.], 2018. p. 144–147.
- VICENTE, R. J. A criptomoeda como método alternativo para realizar transações financeiras. *Maiêutica-Tecnologias da Informação*, v. 2, n. 01, 2017.
- VIDOTTO, R. S. et al. O moving average convergence-divergence como ferramenta para a decisão de investimentos no mercado de ações. *Revista de Administração Contemporânea*, Associação Nacional dos Programas de Pós-graduação em Administração, 2009.
- VIEIRA, F. H. T.; LEMOS, R. P.; LEE, L. L. Alocação dinâmica de taxa de transmissão em redes de pacotes utilizando redes neurais recorrentes treinadas com algoritmos em tempo real. *IEEE Latin America*, v. 1, n. 1, 2003.