



UFOP

Universidade Federal
de Ouro Preto

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

Séries Temporais para Predição de Finanças no contexto de Criptomoedas

Vinícius de Souza Fialho Garcia

TRABALHO DE CONCLUSÃO DE CURSO

ORIENTAÇÃO:
Fernando Bernardes de Oliveira

**Abril, 2021
João Monlevade–MG**

Vinícius de Souza Fialho Garcia

**Séries Temporais para Predição de Finanças no
contexto de Criptomoedas**

Orientador: Fernando Bernardes de Oliveira

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

Universidade Federal de Ouro Preto

João Monlevade

Abril de 2021

SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

G216s Garcia, Vinicius de Souza Fialho .
Séries temporais para predição de finanças no contexto de
criptomoedas. [manuscrito] / Vinicius de Souza Fialho Garcia. - 2021.
58 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Fernando Bernardes de Oliveira.
Monografia (Bacharelado). Universidade Federal de Ouro Preto.
Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia de
Computação .

1. Análise de séries temporais. 2. Bitcoin. 3. Inteligência
computacional. 4. Mercado financeiro - Previsão. 5. Redes neurais
(Computação). 6. Transferência eletrônica de fundos. I. Oliveira,
Fernando Bernardes de. II. Universidade Federal de Ouro Preto. III. Título.

CDU 519.2:336.74/.76

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



FOLHA DE APROVAÇÃO

Vinícius de Souza Fialho Garcia

Séries Temporais para Predição de Finanças no contexto de Criptomoedas

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

Aprovada em 29 de abril de 2021

Membros da banca

Doutor - Fernando Bernardes de Oliveira - Orientador(a) (Universidade Federal de Ouro Preto)
Doutor - Gilda Aparecida de Assis - (Universidade Federal de Ouro Preto)
Doutor - Bruno Pereira dos Santos - (Universidade Federal de Ouro Preto)
Doutor - Luiz Carlos Bambirra Torres - (Universidade Federal de Ouro Preto)

Fernando Bernardes de Oliveira, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 14/06/2021



Documento assinado eletronicamente por **Fernando Bernardes de Oliveira, PROFESSOR DE MAGISTERIO SUPERIOR**, em 14/06/2021, às 21:55, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0, informando o código verificador **0181834** e o código CRC **1698659E**.

Este trabalho é dedicado a todos, todos que me ajudaram, todos que passaram por mim, e aqueles que não puderam também, dedico este trabalho a vida e a ciência.

Agradecimentos

Nesta seção gostaria de relatar meus profundos agradecimentos às pessoas que deram suporte e contribuíram de alguma maneira para que eu conseguisse concluir este trabalho.

Em primeiro lugar gostaria de agradecer minha família, apesar de distantes e com convicções completamente diferentes, abdicaram do que acreditam e depositaram fé na minha capacidade e vontade de evoluir. Desde de o início da minha caminhada independentemente da situação sempre estiveram do meu lado.

Gostaria também de agradecer a todos meus amigos que tanto em situações de alegria quanto em situações de tristeza e dúvidas me abraçaram e deram a base que eu precisava para ficar bem, sem eles a minha caminhada seria completamente diferente. Saber que passei por todos os desafios com um time ao meu redor, para de cobrar me incentivar, e as vezes também me desanimar fez com que tudo fosse mais brando e alegre.

Não posso deixar de citar, todas republicas que de alguma maneira me abrigaram quando eu precisei e solidificaram as amizades que fiz: República Back Jack, republica Kalango, República Anomalia, República Vuco Vuco, República Monastério, dentre diversas outras. Em especial, quero deixar meus carinhos e agradecimentos a republica puro malte, por todo suporte prestado, aqui criei uma família, todos fazem de parte de alguma forma do que sou e do que fiz. Obrigado!

Por fim, mas não menos importante, quero deixar meus agradecimentos a UFOP, e a todos colaboradores que fazem essa instituição ser o que é, por incrível que parece aqui também fiz amigos. Ressaltar também a importância de todos profissionais que fazem parte dela, os faxineiros, os professores, as famosas “tias da cantina”, bibliotecários, recepcionistas, coordenadores, todos vocês têm um papel fundamental na formação de cada pessoa que passa por essa universidade, sem vocês não existiriam graduandos pela UFOP em João Monlevade. Em especial, quero agradecer meu orientador Fernando, apesar das adversidades do tema, dos tempos difíceis e do aluno indisciplinado, sempre me deu suporte e conselhos e contribuiu veementemente para que o trabalho fosse concluído com clareza e perfeição. Obrigado!

*“Nothing in life is to be feared, it is only to be understood.
Now is the time to understand more, so that we may fear less.”*

— Marie Curie (1867 – 1934)

Resumo

A recente aparição das criptomoedas tem atraído a atenção mundial, principalmente pelo seu crescente valor de mercado, sendo o *Bitcoin* o principal personagem nesse cenário. Nesse contexto, este projeto tem como objetivo estudar o comportamento do *Bitcoin* e utilizar mecanismo já estudados na literatura para realizar predições e comparações entre eles. A partir disso, foram utilizadas técnicas de inteligência computacional para a predição do mercado financeiro em relação às criptomoedas. Após o estudo de algumas técnicas, foram obtidos resultados satisfatórios utilizando a técnica do modelo ARIMA, a técnica de Redes Neurais do tipo *Long Short Term Memory* (LSTM) e o método de vetores de suporte (SVR). Foram realizados experimentos em diversos cenários a fim de analisar o comportamento dos métodos preditivos, sendo utilizados conjuntos de dados com mais de 6 anos de registros diários envolvendo características da moeda. Com o auxílio de métricas, como, por exemplo, o *Root Mean Square Error* (RMSE), foram aperfeiçoados os algoritmos e produzidos resultados na predição do valor de fechamento diário do *Bitcoin*. Ao final, os resultados sugerem a capacidade de previsão e modelagem da série para cada método utilizado. Foi possível verificar o rendimento de cada um deles, levando em consideração erros obtidos e períodos de tempo avaliados. Considerando o contexto experimental estabelecido, os resultados sugerem que o LSTM que obteve resultados ligeiramente superiores que os demais. Por fim, foram reconhecidos as limitações e erros das análises realizadas e pontuadas futuras mudanças que podem aperfeiçoar os resultados.

Palavras Chave : Séries Temporais. Inteligência Computacional. Redes Neurais. Predição. Criptomoedas. *Bitcoin*.

Abstract

The recent appearance of cryptocurrencies has attracted the attention around the world, mainly to its increasing market value, with Bitcoin being the main character in this scenario. In this context, this project aims to study the behavior of Bitcoin and use the mechanism already studied in the literature to perform predictions and comparisons between them. From that, computational intelligence techniques were used to predict the financial market in relation to cryptocurrencies. After studying some techniques, satisfactory results were obtained using the ARIMA model technique, the Long Short Term Memory (LSTM) Neural Networks technique and the support vector method. Experiments were performed in various scenarios to analyze the predictive methods behavior, using data sets with more than 6 years of daily records involving currency characteristics. With the aid of metrics, such as the Root Mean Square Error (RMSE), the algorithms were improved and results were achieved to predict the daily closing value of Bitcoin. In the end, the performed studies identified the capacity of each method used. Through the evaluation of the results it was possible to verify the performance of each one of them, taking into account the obtained errors and evaluated periods of time. Considering the established experimental context, the results suggest that the LSTM that obtained slightly higher results than the others. Finally, the limitations and errors of the analyzes performed were accepted and future changes that may improve the results were punctuated.

Key Words : Cryptocurrency, Bitcoin, neural networks, time series, computational intelligence, machine learning.

Lista de ilustrações

| | |
|--|----|
| Figura 1 – Preço da moeda por tempo | 15 |
| Figura 2 – Neurônio biológico | 23 |
| Figura 3 – Neurônio artificial | 23 |
| Figura 4 – Classificação binaria linearmente separável no espaço original | 26 |
| Figura 5 – Classificação binaria não linearmente separável | 27 |
| Figura 6 – Ilustração gráfica da transformação de um problema de regressão em classificação binaria | 27 |
| Figura 7 – Decomposição da série: tendência | 32 |
| Figura 8 – Decomposição da série: Sazonalidade | 32 |
| Figura 9 – Decomposição da série: Resíduo | 33 |
| Figura 10 – Gráfico <i>Boxplot</i> dos registros de cotação do Bitcoin | 33 |
| Figura 11 – Gráfico <i>Candlestick</i> dos registros de cotação do Bitcoin | 34 |
| Figura 12 – Agrupamento da média anual do valor de fechamento do BTC | 35 |
| Figura 13 – Agrupamento da média mensal do valor de fechamento do BTC | 35 |
| Figura 14 – Agrupamento da média diária do valor de fechamento do BTC | 36 |
| Figura 15 – Agrupamento da média semanal do valor de fechamento do BTC | 36 |
| Figura 16 – Divisão inicial dos dados entre treino e teste | 38 |
| Figura 17 – Comparação entre quantidade de valores do passado | 38 |
| Figura 18 – Comparação entre otimizadores | 39 |
| Figura 19 – Comparação entre quantidade de neurônios | 40 |
| Figura 20 – Escopo da rede neural finalizada | 40 |
| Figura 21 – Teste de predição 2: LSTM – Treino: 2.500 valores iniciais. Teste: 100 próximos valores. | 41 |
| Figura 22 – Teste de predição 3: LSTM | 42 |
| Figura 23 – Teste de predição 4: LSTM | 42 |
| Figura 24 – Dados redimensionados por mês | 43 |
| Figura 25 – Teste de predição 1: ARIMA | 44 |
| Figura 26 – Teste de predição 2: ARIMA | 45 |
| Figura 27 – Teste de predição 3, ARIMA | 46 |
| Figura 28 – Teste de predição 2: SVR | 47 |
| Figura 29 – Teste de predição 3: SVR | 47 |
| Figura 30 – Teste de predição 4: SVR | 48 |
| Figura 31 – Teste de predição 5, SVR | 49 |
| Figura 32 – Vetores de suporte gerados durante treinamento. Previsão de valores de teste – Modelo SVR | 49 |

Lista de tabelas

| | |
|---|----|
| Tabela 1 – Comparação de desempenho para períodos de baixa volatilidade | 51 |
| Tabela 2 – Comparação de desempenho para períodos de alta volatilidade | 51 |

Lista de abreviaturas e siglas

ARIMA *Autoregressive Integrated Moving Average*

BTC *BitCoin*

MAE *Mean Absolute Error*

MAPE *Mean Absolute Percent Error*

RMSE *Root Mean Square Error*

RNN *Recurrent Neural Networks*

SARIMAX *Seasonal Autoregressive Integrated Moving Average*

SVM *Support Vector Machine*

SVR *Support Vector Regressor*

Sumário

| | | |
|----------|--|-----------|
| 1 | INTRODUÇÃO | 14 |
| 1.1 | Justificativa | 15 |
| 1.2 | Objetivos | 15 |
| 1.3 | Metodologia | 16 |
| 1.4 | Organização | 17 |
| 2 | REVISÃO BIBLIOGRÁFICA | 18 |
| 2.1 | Criptomoedas | 19 |
| 2.2 | BitCoin | 20 |
| 2.3 | Séries temporais | 20 |
| 2.3.1 | Dickey-Fuller Test | 21 |
| 2.4 | Objetivos da análise de séries temporais | 22 |
| 2.5 | Redes neurais | 22 |
| 2.5.1 | Redes LSTM | 24 |
| 2.5.2 | Otimizadores | 24 |
| 2.6 | ARIMA | 25 |
| 2.7 | Vetores de suporte a regressão | 26 |
| 2.8 | Métricas Adotadas | 28 |
| 2.8.1 | RMSE | 28 |
| 2.8.2 | MAE | 28 |
| 2.8.2.1 | MAPE | 29 |
| 2.8.3 | U de Theil | 29 |
| 2.9 | Considerações finais | 29 |
| 3 | DESENVOLVIMENTO | 30 |
| 3.1 | Coleção de dados | 30 |
| 3.2 | Análise exploratória | 31 |
| 3.3 | Considerações finais | 36 |
| 4 | RESULTADOS | 37 |
| 4.1 | Modelagem | 37 |
| 4.1.1 | Rede LSTM | 37 |
| 4.2 | Modelo ARIMA | 42 |
| 4.3 | SVR | 46 |
| 4.4 | Discussão | 50 |

| | | |
|------------|------------------------------------|-----------|
| 5 | CONCLUSÃO | 53 |
| 5.1 | Trabalhos futuros | 54 |
| | REFERÊNCIAS | 55 |

1 Introdução

Diante a evolução do mercado financeiro, as criptomoedas adquirem cada vez mais espaço devido os mecanismos de segurança empregados na efetivação da troca de valores. A segurança se deve a utilização do *Blockchain*, uma tecnologia de registros associados, seguros e protegidos por criptografia. Diversas especulações e dúvidas circundam essas moedas, pelo fato de não existir uma instituição controladora da moeda ou lastro. Devido a isso, as flutuações dessas moedas são, a princípio, baseadas em oferta e demanda. A partir desse contexto, o estudo do comportamento e das características das criptomoedas, principalmente o *Bitcoin*, se torna promissor. Alguns estudos podem ser observados em [Li e Wang \(2017\)](#), os quais apresentam a quantidade de detalhes inerentes a moeda e possíveis abordagens para investigá-la. Desta maneira, o primeiro passo para investigar a moeda é obter seu histórico de dados, utilizando sua cotação temporal (diariamente, por exemplo). Porém, diferente das moedas fiduciárias, o valor final das criptomoedas é determinado, entre outros, pela quantidade de transações que são feitas, ou em termos financeiros sua capitalização de mercado. Este trabalho procura explorar a relação que existe entre os dados temporais do Bitcoin, com o intuito de prever seus valores utilizando técnicas de aprendizagem de máquina e inteligência computacional. Além disso, apresentar comparações entre modelos comumente utilizados pela literatura.

O processo de cotação de uma moeda, seja ela virtual ou não, envolve valores de abertura, fechamento, máximos e mínimos, além da cotação de mercado. Por exemplo, moedas não virtuais, como o real, sofrem influência no seu valor final ou no seu valor de comercialização. Isso pode ocorrer por diversos outros fatores, como taxa de juros, balança comercial, preço de commodities, dentre outros. Além disso, elas enfrentam interferências externas, como da política, por exemplo, dificultando em partes a realização de previsão de seu valor futuro. Já a cotação de moedas virtuais, como o Bitcoin, ainda está sendo descoberto pelo mercado, e existem mistérios em sua evolução, conforme observado no trabalho de [Jeffrey \(2015\)](#). O fato de não ter ligação direta com uma instituição ou país e não sofrer taxaçoão direta em seu valor, abre espaço para que a especulação das criptomoedas seja mais sensível, tornado-a volátil e suscetível aos mais diversos tipos de influência, desde um comentário em uma rede social, a uma crise global. Tais situações podem culminar em um acréscimo ou decréscimo acentuado em seu valor. Desta maneira, entender e estudar como a série temporal de uma criptomoeda funciona é o passo inicial para um longo processo de conhecimento e descobertas.

1.1 Justificativa

Apesar de as criptomoedas serem palco de grandes movimentações no mercado digital, seus valores de cotação e sua evolução temporal ainda não são conhecidos explicitamente. Como pode-se observar na Figura 1, o valor de troca do *BitCoin* (BTC), a principal Criptomoeda comercializada, sofreu duas ascensões altíssimas, se comparadas a qualquer outro período desde sua criação, uma delas entre 2017 e 2018 e a segunda em 2021. Além disso, o gráfico sugere a alta volatilidade da moeda em pouco tempo de existência. Sendo assim, identificar as situações que levam à sua variação (de baixa ou de alta) pode ser complexo. Com a cotação diária do BTC, é possível estudar a variação da moeda durante o tempo, de maneira a capturar suas características, fazendo utilização de séries temporais e utilizando procedimentos de exploração de dados. Ademais, com o auxílio de técnicas de inteligência computacional, é possível identificar tendências, realizar previsões, além de principalmente, compreender o comportamento da moeda. Desta maneira, verifica-se a necessidade de estudar e entender mais a fundo o funcionamento e evolução das criptomoedas.

Figura 1 – Preço da moeda por tempo



Fonte: elaborado pelo autor

1.2 Objetivos

Este projeto pretende estudar do comportamento de criptomoedas por séries temporais. O estudo utiliza técnicas de inteligência computacional e aprendizagem de máquina para fazer previsões do mercado financeiro considerando diferentes períodos e modelagens.

De modo geral, este trabalho possui os seguintes objetivos específicos:

1. Modelar e implementar mecanismos de séries temporais para as criptomoedas.

2. Estudar e aplicar mecanismos de inteligência computacional para a predição do comportamento de criptomoedas.
3. Validar os modelos propostos por experimentos computacionais utilizando instâncias de teste e coleção de dados.

1.3 Metodologia

A metodologia para a execução do projeto consiste em uma pesquisa bibliográfica, para a revisão acerca dos temas envolvidos, bem como uma pesquisa experimental, na qual é avaliada os modelos proposto por meio de instâncias de teste. As atividades deste projeto podem ser descritas como segue:

1. Revisão da literatura: pesquisar e examinar a literatura sobre os seguintes tópicos principais: séries temporais, criptomoedas, inteligência computacional, aprendizado de máquina, dentre outros.
2. Coleção de dados: pesquisar ou construir uma coleção de dados para as criptomoedas de interesse.
3. Modelagem da série temporal: definir um modelo de série temporal a partir de uma coleção de dados de interesse.
4. Definição das técnicas de inteligência computacional: definir técnicas para a predição do comportamento das criptomoedas.
5. Implementação: implementar técnicas de inteligência computacional para o contexto estudado.
6. Planejamento e execução do experimento: Planejar o experimento a ser realizado no contexto das criptomoedas, bem como realizar todos os testes necessários para validação da abordagem proposta.
7. Análise e discussão: avaliar os resultados obtidos, por meio de técnicas estatísticas apropriadas, com as devidas considerações e ponderações.

Mediante a análise da evolução temporal da moeda, espera-se entender melhor seu funcionamento e como agentes externos podem influenciar no seu valor, além de comparar diferentes formas de avaliação e modelagens da série temporal referente ao *BitCoin* (BTC). Desta maneira, pretende-se facilitar a avaliação de mercado e tentativas de predições.

1.4 Organização

Este trabalho está organizado como segue. O Capítulo 2 descreve a revisão bibliográfica, os trabalhos correlatos na literatura e as respectivas abordagens para o problema. No Capítulo 3 são descritas as estratégias a serem utilizadas e como a modelagem foi executada. Já no Capítulo 4 são apresentados e discutidos os resultados obtidos por meio dos métodos propostos. Por fim, no Capítulo 5, são apresentadas as conclusões para o trabalho elaborado, pontuando os principais detalhes e aprendizados obtidos.

A seguir, os principais trabalhos encontrados na literatura serão apresentados. Esses trabalhos foram utilizados como fonte e base de conhecimento para os desenvolvimentos propostos, destacando-se os resultados obtidos em cada um deles.

2 Revisão bibliográfica

Apesar de ser uma discussão relativamente nova e que tem ganhado grandes proporções nos últimos anos, os estudos em torno da análise e predição de séries temporais, utilizando redes neurais, é utilizado há anos. [Lapedes e Farber \(1987\)](#), um dos trabalhos pioneiros da área, sugeriu como redes neurais apresentem resultados extremamente satisfatórios para processar sinais não lineares. Em [Groot e Würtz \(1991\)](#), foi apresentado como uma rede neural simples poderia trazer resultados promissores na análise de séries não lineares. Dentre diversos outros, tais trabalhos foram inspiração e base para consolidar diversos estudos.

No trabalho proposto por [Khashei e Bijari \(2010\)](#) foi descrito como as redes neurais tradicionais, apesar de trabalharem bem acerca de diversas áreas do conhecimento, em casos específicos, como a predição de séries temporais, não trazem resultados tão satisfatórios. Desta maneira, é proposto por aqueles autores um modelo híbrido e comparativo, na tentativa de avaliar melhor situações particulares. Em [Gheyas e Smith \(2009\)](#), foi implementado um algoritmo diferente, nesse caso baseado em redes neurais recorrentes. Após modelagem e avaliação, o método avaliado apresentou resultados altamente superiores, se comparado aos convencionais. É possível observar com tais trabalhos, como a adaptação e generalização de modelos já existentes, não somente é viável, como essencial em alguns casos, além de promissor em situações recorrentes.

Especificamente em previsões de séries temporais financeiras, [Oancea e Ciucu \(2014\)](#) trazem um estudo sobre predição da taxa de câmbio entre diferentes moedas fiduciárias, como a Libra e Dólar. O trabalho citado, apresenta a dificuldade em realizar tal previsão, se comparada a séries temporais não financeiras. Algumas características monetárias como: taxa de câmbio, cotação, entre outras, geram na análise e estimativa dessas séries temporais algumas incertezas. Além disso, fatores como a especulação e interferências externas tornam seu valor extremamente volátil. Ainda assim, os resultados dos trabalhos sugerem que a utilização de redes neurais recorrentes se mostra superior a modelos tradicionais.

Associando os estudos anteriormente citados ao contexto de criptomoedas, em particular o BTC, [Adcock e Gradojevic \(2019\)](#) apresentam um panorama sobre a análise e predição da moeda. No trabalho foram comparados 6 diferentes modelos, baseados em redes neurais, com o objetivo de prever seus valores futuros. Além disso, o período em dias da série é alterado entre as análises. Como conclusão temos que com regras simples é possível avaliar e realizar previsões satisfatórias do BTC utilizando RNA (Redes neurais artificiais). Entretanto, modelos paramétricos concorrentes e modelos não paramétricos são variações que podem trazer resultados melhores. Segundo os autores, há, no entanto,

variabilidade no desempenho preditivo das RNA ao longo do tempo, possivelmente devido à natureza volátil do Bitcoin. Pode-se observar que a dinâmica dos retornos diários do BTC, apresentam episódios das tendências locais que surgem potencialmente da natureza especulativa do comércio de criptomoedas (ADCOCK; GRADOJEVIC, 2019).

No trabalho de Yenidoğan et al. (2018) foram avaliados dois métodos diferentes, *Autoregressive Integrated Moving Average* (ARIMA) e Prophet, também para previsão do BTC. Foram adicionadas também variáveis ao modelo, sendo estas baseadas em moedas fiduciárias, no caso o Real brasileiro, o Iene japonês e a Libra. A partir das modelagens executadas foram avaliados os resultados utilizando 5 modelos diferentes. Apesar de o ARIMA ter uma relevância superior na literatura, segundo os autores, os resultados obtidos pelo modelo Prophet foram superiores, tanto para avaliação de acurácia, quanto para avaliação dos erros médios de previsão. Além disso, um ponto de destaque foi o incremento de variáveis baseadas na matriz de correlação das moedas anteriormente citadas, que tiveram resultados positivos para uma previsão de até 90 dias.

Trabalhos como Atsalakis et al. (2019) e Yang e Kim (2015) sugerem como a utilização de diferentes métodos, e adaptações dos já existentes, são, não só promissores, como necessários para diferentes avaliações do BTC, especificamente. Além disso, é importante ressaltar que a quantidade de trabalhos referentes a esse tema é crescente. Apesar de tratarem de áreas relativamente novas, criptomoedas e redes neurais, tais discussões são fundamentais para fomentar o debate e acrescentar novas ideias. Principalmente pela dificuldade de avaliação e a alta volatilidade das moedas virtuais, as novas possibilidades que o avanço computacional traz para o processamento de redes neurais é promissor e surpreendente.

2.1 Criptomoedas

Segundo Castello (2019), as moedas digitais ou criptomoedas são uma forma de transferir recursos entre pessoas. Diferente das tradicionais, as criptomoedas não tem taxaço de impostos nem vínculos governamentais e suas transações são validadas por uma tecnologia chamada *Blockchain*, que foi criada pelo pseudônimo “*Satoshi Nakamoto*”. Por meio dela é possível realizar transações virtuais, parte a parte de maneira segura, como pode ser observado em Nakamoto (2019), trabalho que propiciou o surgimento dessas moedas. Segundo Rodrigues (2017), o *Blockchain* é um livro razão que contém os registros distribuídos, ou a razão de todos os eventos digitais compartilhados entre os pares participantes, garantido a segurança das trocas por meio de um histórico.

Assim, como descrito em Catania, Grassi e Ravazzolo (2018), surgiram diversas criptomoedas desde 2008, como *Ethereum*, *Litecoin*, entre outros. O BTC foi a primeira classificada em capitalização de mercado.

Existem estratégias para tentar regulamentar o BTC como uma moeda oficial, os quais podem ser observadas em [Hughes \(2017\)](#). Porém, existem dificuldades em proteger os envolvidos na transação. Além disso, o conceito de moeda virtual e definições de possíveis taxas sobre as moedas são inconclusivos e não generalistas como também pode ser verificado em [Castello \(2019\)](#).

2.2 BitCoin

O BTC nada mais é que uma espécie no gênero das criptomoedas. A sua definição e ideia foram iniciadas pelo trabalho [Nakamoto \(2019\)](#) escrito pelo pseudônimo "Satoshi Nakamoto". Ainda hoje não se sabe sua identidade. Por meio desse trabalho foi definido um modelo de transações entre usuários que funciona mediante um sistema par a par, no qual os nós na rede são responsáveis por validar as transações da moeda.

A validação funciona devido a *Blockchain*. [Silva \(2016\)](#) apresenta que o *blockchain* contém todos os registros envolvendo o Bitcoin. De acordo com aqueles autores, toda transação da moeda é aceite a partir de um consenso da maioria dos nós participantes do sistema.

Apesar de difundida e conhecida são poucos os usos práticos que se encontra para a moeda. Devido a sua volatilidade e especulação são poucas as instituições ou industriais que a aceitam. Seu valor de mercado, ainda misterioso, é sustentado principalmente pelas transações e trocas de investimentos.

2.3 Séries temporais

Uma série temporal é uma cadeia de observações feitas de maneira sequencial em um período, estas podem ser de forma contínua temporalmente, ou por um conjunto discreto de pontos. Cada uma dessas observações é representada por um valor em determinados instantes, suas aplicações são amplas e essenciais em diversos campos de estudo ([HANNAN, 2009](#)).

O conjunto de dados que representam uma informação é a base que possibilita o entendimento de determinados cenários. Analisando um estudo meteorológico, por exemplo, é importante sugerir numericamente (recorrendo a uma série temporal) a temperatura do local durante um intervalo qualquer, para entender a origem e evolução da situação. Já em uma temática de ativos financeiros, segundo [Morettin \(2017\)](#) é interessante destacar os valores de abertura, fechamento, máximo e mínimos diários da moeda avaliada, tais informações permitem reconhecer tendências, influências e outros atributos essenciais para analisar e entender os dados. Porém, ainda se tratando do campo monetário, como fica claro em [Morettin \(2017\)](#), as séries temporais financeiras se diferenciam das demais por

possuírem uma alta volatilidade e sofrerem por diversas influências externas, exigindo métodos e modelagens específicas.

Uma série temporal é definida por suas características, tais definições impactam diretamente em sua análise e modelagem. Dentre elas, a estacionariedade de uma série é medida pela utilização da média e variância, caso elas sejam iguais ou próximas durante todo tempo observado, a série é estacionária. Já a sazonalidade, identifica uma repetição de comportamento. Um exemplo simples seria de um vendedor de sorvete, que tem um acréscimo na quantidade de sorvetes vendidos a cada verão, em teoria os clientes consomem mais durante esse período. Avaliar as características, é essencial para um entendimento adequado do problema. Em alguns casos faz-se necessário a utilização de testes matemáticos para identificar tais características, como o que segue.

2.3.1 Dickey-Fuller Test

De acordo com [Agiakloglou e Newbold \(1992\)](#), nos últimos anos houve um considerável interesse no desenvolvimento e aplicação de testes para raízes auto regressivas unitárias no processo de geração de uma série temporal. As implicações desses resultados de teste são particularmente importantes na compreensão de dados econômicos e na construção de modelos para séries de tempo econômicas. Dentre suas utilidades, uma das mais comuns é para testar a hipótese nula de um ARIMA, ainda conforme [Agiakloglou e Newbold \(1992\)](#).

O teste *Dickey-Fuller* é um teste de significância estatística. Sendo assim há um teste de hipótese envolvido com uma hipótese nula e alternativa, como resultado é calculado o valor da variável de resposta p . A partir deste, pode ser feita uma inferência se uma determinada série é estacionária ou não.

A raiz unitária é uma característica de uma série temporal que a torna não estacionária. Diz-se que uma raiz unitária existe em uma série de tempo do valor de alfa = 1 na equação abaixo.

$$Y_t = \alpha * Y_{t-1} + \beta * X_e + E \quad (2.1)$$

Sendo que: Y_t é o valor da série temporal no tempo ' t ' e X_e é uma variável exógena (explicativa). A presença de uma raiz unitária significa que a série temporal não é estacionária. Além disso, o número de raízes unitárias contidas corresponde ao número de operações de diferenciação necessárias para tornar a série estacionária.

Desta maneira, para valores de $p \leq 0,05$ pode-se inferir que uma determinada série é estacionária.

2.4 Objetivos da análise de séries temporais

A análise de séries temporais consiste em procurar alguma relação de dependência temporal entre os dados, identificando o mecanismo gerador da série com o objetivo de extrair periodicidades relevantes nas observações; descrever o seu comportamento e fazer previsões (BAYER, 2010).

De acordo com Castro et al. (2001), a análise de uma série temporal visa a modelagem do fenômeno em questão, a obtenção de conclusões em termos estatísticos e a avaliação da adequação do modelo em termos de previsão. Desta maneira, selecionar um modelo que represente os dados de maneira fiel e satisfatória é essencial. A partir da escolha de um modelo, torna-se possível estimar os parâmetros e checar pela clareza, o entendimento do mecanismo de geração dos dados da série (BROCKWELL et al., 2016). Dado o desenvolvimento do modelo é possível utilizá-lo de diversas maneiras dependendo do campo de aplicação.

2.5 Redes neurais

A primeira aparição ou modelo que utilizou neurônios como componentes conceituais em circuitos para realizar tarefas computacionais foi McCulloch e Pitts (1943). Porém, em pouco tempo, os recursos foram redirecionados e os estudos na área não puderam prosseguir. Em Kröse et al. (1993), é possível observar que o interesse nas redes neurais ressurgiu apenas depois que alguns resultados teóricos importantes foram alcançados décadas após sua aparição, ressaltando a demanda de processamento necessário para o funcionamento satisfatório das redes.

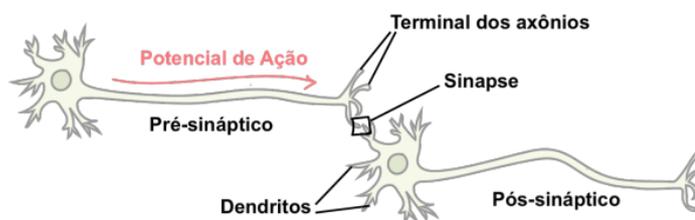
De acordo com Rauber (2005), uma rede neural artificial tem duas facetas elementares: a arquitetura e o algoritmo de aprendizagem. Essa divisão surge naturalmente pelo paradigma como a rede é treinada. Ao contrário de um computador com arquitetura de Von Neumann que é programado, a rede é treinada, por exemplo, de treino.

Uma rede é composta basicamente por neurônios que são responsáveis pelo processamento da informação. A resposta de um neurônio inicial com uma função de ativação alimenta os próximos e assim sucessivamente até o último nó, cada conjunto de neurônios representa uma camada e o conjunto delas formam a rede.

A Figura 2 representa a interação entre dois neurônios. O pequeno espaço entre os dendrito e terminais dos axiomas é conhecido como sinapse, com papel fundamental de memorizar a informação. Segundo Haykin (2007), as sinapses são estruturas elementares e unidades funcionais que medem a interação entre os neurônios. As sinapses mais comuns são as sinapses químicas, que operam da seguinte forma: o processo de sinapse converte um sinal elétrico pré-sináptico em um sinal químico e volta para um sinal elétrico pós-sináptico.

Como resultado dessa reação química, o sinal elétrico, pós sináptico pode aumentar ou diminuir o potencial elétrico do corpo celular assim excitando ou inibindo o neurônio receptor.

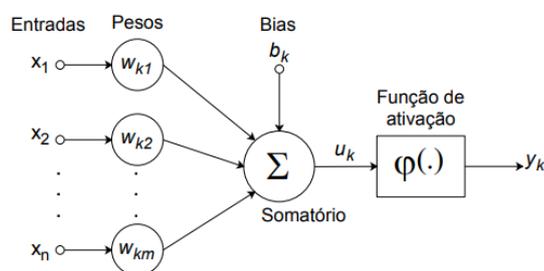
Figura 2 – Neurônio biológico



Fonte: Adaptado de Haykin (2007)

As redes neurais mais comuns são do tipo *feedforward* (Feedforward Neural Network), nessas redes a informação percorre sempre a mesma direção, até a última camada. Existem diversas maneiras de se conectar os neurônios e modelar uma rede, dentre elas na *Recurrent Neural Networks* (RNN), as informações podem percorrer diferentes direções, desta maneira, um neurônio além de alimentar o próximo, consegue se realimentar produzindo uma categoria de memória a curto prazo. Em decorrência destas características, as RNNs podem criar modelos mais complexos e extensíveis a um grupo maior de problema (CAVAIONI, 2014). A Figura 3 ilustra a operação de um neurônio artificial. Os sinais elétricos enviados pelos axiomas de outros neurônios são recebidos pelas entradas. O resultado dessa soma de sinais faz com que exista ou não energia suficiente para o neurônio ser ativado e emitir um sinal de saída pelo seu axônio. A função de ativação modela a forma como o neurônio responde ao nível de excitação, limitando e definindo a saída da rede neural (HAYKIN, 2007).

Figura 3 – Neurônio artificial



Fonte: Adaptado de Haykin (2007)

Devido ao recente avanço tecnológico, a utilização de redes neurais para o processamento de dados é cada vez maior. Especificamente para a predição de series temporais, como citado anteriormente, os resultados são promissores. Em especial as redes neurais

LSTM apresentam um erro de predição para series financeiras reduzido, se comparada a outros modelos.

2.5.1 Redes LSTM

As LSTM foram introduzidas por Hochreiter e Schmidhuber (1997) e utilizam o mesmo conceito das RNN com um aperfeiçoamento relacionado a memória. Especificamente no que se refere a dependência entre elementos distantes na rede, as RNNs tradicionais não são eficientes em capturar essa conexão mais afastada.

Projetadas para evitar o problema da dependência de longo prazo, as LSTMs possuem um módulo de repetição especial. Nas RNNs padrões o módulo de repetição possui uma única camada de rede neural, já nas LSTMs o mesmo possui 4 camadas de redes neurais, as quais interagem de uma maneira particular (GREFF et al., 2017).

O ponto principal do funcionamento da LSTM é o estado da célula, que atravessa toda a estrutura da rede, podendo sofrer alterações gerenciadas pelos chamados portões (*gates*). Estes portões são compostos de uma camada de rede neural com função de ativação sigmoide e uma operação de multiplicação, o que controlará a quantidade que passará de cada componente, gerando assim, a capacidade de remover ou adicionar informações ao estado da célula LSTM (CHEN, 2017).

2.5.2 Otimizadores

Do ponto de vista prático, para possibilitar a atualização dos pesos em uma rede neural, pode ser utilizada um método de otimização. Esse método será responsável por calcular a função de erro durante o período de treinamento do modelo. Em Sutskever et al. (2013), é possível observar como a definição do otimizador pode impactar diretamente nos resultados de treinamento de um modelo. A biblioteca *Keras* utilizada durante o trabalho disponibiliza alguns otimizadores para realizar estes cálculos, destes, quatro serão empregados na etapa de testes. O primeiro deles chamados *Adam* (KINGMA; BA, 2014), utiliza um algoritmo baseado em gradiente de primeira ordem para realizar este cálculo. *Rmsprop* (HINTON; SRIVASTAVA; SWERSKY, 2012), outro otimizador, usa a média de execução e magnitude da função gradiente, para calcular a função de erro durante o treinamento. O terceiro otimizador testado é o *SGD* (SUTSKEVER et al., 2013), o qual utiliza a descida gradiente estocástica como base para os cálculos de erro, como pode ser verificado em. E, por fim, o otimizador *Nadam* (DOZAT, 2016), utiliza um algoritmo adaptativo baseado no Adam.

Para melhor definição e entendimento dos métodos de otimização seria necessário um estudo mais específico, devido a sua complexidade e robustez. Tal estudo fugiria do escopo inicial do trabalho. Desta maneira, foi feita uma revisão menos abrangente dos

métodos utilizados.

2.6 ARIMA

Introduzido por [Box et al. \(2015\)](#), o modelo ARIMA (modelo de média móvel integrado auto regressivo) tem uma abordagem matemática prática com impacto fundamental em análise de séries temporais e aplicações de previsão. Segundo [Bayer \(2010\)](#), a classe de modelos tradicionalmente mais utilizada em análise de séries temporais é a dos modelos auto regressivos integrados e de médias móveis (ARIMA). A ideia é que a série temporal em estudo seja gerada por um processo estocástico, cuja natureza pode ser representada a partir de um modelo matemático, o modelo ainda pode ser generalizado para presença de sazonalidade.

De acordo com [Zhang \(2003\)](#), em um modelo ARIMA, o valor futuro de uma variável é considerado uma função linear de várias observações anteriores e erros aleatórios, desta maneira, o processo que gera a série temporal, tem a forma:

$$Y_t = \sigma_0 + \phi_1 Y_{t-1} + \phi_2 Y_{t-2} + \dots + \phi_p Y_{t-p} + e_t - \sigma_1 e_{t-1} - \sigma_2 e_{t-2} - \dots - \sigma_q e_{t-q} \quad (2.2)$$

Sendo que: y_t e e_t são o valor real e o erro aleatório no período t , respectivamente, sendo ϕ_i ($i = 1, 2, \dots, p$) e σ_j ($j = 0, 1, 2, \dots, q$) são parâmetros do modelo. P e q são inteiros e muitas vezes referido como ordens do modelo. Erros aleatórios, t , são assumidos como independentemente e identicamente distribuídos com uma média de zero e uma variância constante de 2. Equação (1) envolve vários casos especiais importantes da família de modelos ARIMA. Se $q = 0$, então (1) torna-se um modelo AR de ordem p . Quando $p = 0$, o modelo reduz a um MA de ordem q . Uma tarefa central da construção do modelo ARIMA é determinar a ordem de modelo apropriada (p, q) ([ZHANG, 2003](#)).

A metodologia de aplicação do modelo ARIMA, envolve 3 etapas interativas. A estacionariedade da série é um requisito auxiliar para utilização do modelo, portanto na parte de identificação é necessário realizar tal verificação e adaptação, caso necessário. Em sequência a definição de parâmetros é essencial para adaptação da série ao modelo. A etapa final é verificar a adequação do modelo, averiguando se os erros utilizados são satisfatórios.

Existem ainda variações para o ARIMA, onde são adicionadas variáveis sazonais como parâmetros. Um destes o *Seasonal Autoregressive Integrated Moving Average* ([SARIMAX](#)), inclui os efeitos de interação das variáveis exógenas ao modelo e pode melhorar potencialmente o desempenho de previsão ([ELAMIN; FUKUSHIGE, 2018](#)).

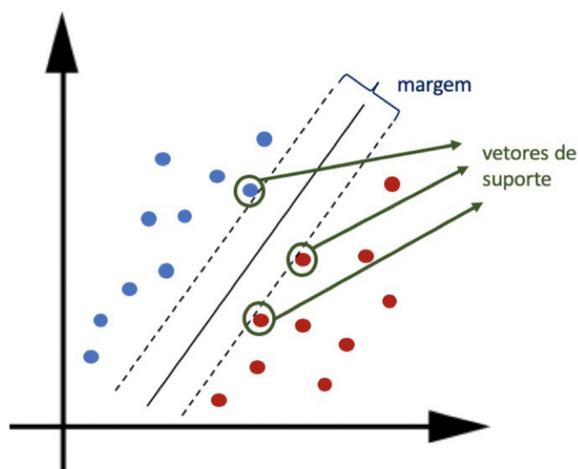
2.7 Vetores de suporte a regressão

Elaborado principalmente por [Vapnik et al. \(1997\)](#), o vetor de suporte à regressão foi desenvolvido originalmente para solucionar problemas de classificação binária (máquina de vetor suporte). Posteriormente, a técnica foi ampliada para tratar problemas de regressão, (máquina de vetor suporte). Situações onde existem rótulos de dados bem definidos e discretos, podem ser modelados como problemas de classificação e cabe a utilização do SVM, como, por exemplo, um problema de categorização de imagens. Já em situações nas quais os rótulos dos dados são relacionados com valores reais e contínuos, como, por exemplo, a predição do valor de uma moeda, é adequado o uso de uma regressão.

Como pode ser observado em [Lima et al. \(2004\)](#), as definições e terminologias para *Support Vector Machine (SVM)* e *Support Vector Regressor (SVR)* na literatura são complexos. Ambos são métodos de aprendizagem de máquina que utilizam vetores no espaço como suporte para realizar classificação ou regressão de dados, buscando maximizar a capacidade de generalização do modelo.

A Figura 4 ilustra um exemplo de classificação binária usando suportes de vetores. Nesse caso, como pode ser observado, os dados são linearmente separáveis. Desta maneira, um único hiperplano é suficiente para separar corretamente as classes de dados.

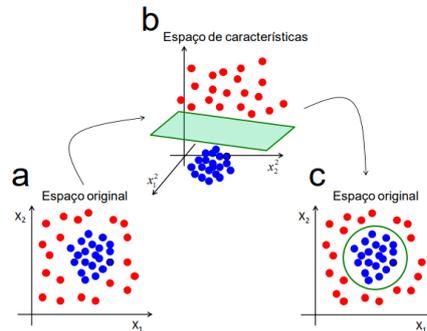
Figura 4 – Classificação binária linearmente separável no espaço original



Fonte: Retirado de [Escovedo \(2020\)](#)

Situações em que os dados não são linearmente separáveis, exigem a adoção de estratégias para os tornar separáveis por meio da utilização de uma função de ativação *Kernel*, sendo algumas: linear, polinomial, sigmoide, dentre outras. De acordo com [Filgueiras et al. \(2014\)](#), a aplicação de uma função *kernel* não linear (ϕ) possibilita mapear as variáveis de entrada em um espaço de alta dimensão, de maneira a se tornarem separáveis, como pode ser observado na Figura. 5.

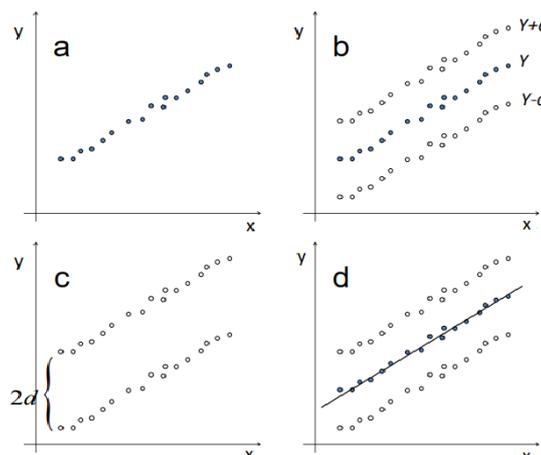
Figura 5 – Classificação binária não linearmente separável



Classificação binária não linearmente separável no espaço original (a). Projeção das amostras de entrada no espaço de alta dimensão (b). Representação ilustrativa de uma função não linear de classificação no espaço original(c). Fonte: Retirado de [Filgueiras et al. \(2014\)](#)

Originalmente o suporte de vetores foram desenvolvidos para resolver problemas de classificação. Porém, podem ser utilizados para tratar problemas de regressão, basta realizar o procedimento: para cada amostra X_i da regressão na Figura 5, um número positivo d é adicionado e subtraído do correspondente valor de interesse y_i , formando assim duas classes ([FILGUEIRAS et al., 2014](#)). A Figura 6 exemplifica o processo.

Figura 6 – Ilustração gráfica da transformação de um problema de regressão em classificação binária



Problema de regressão (a). Adição e subtração aos dados de entrada (b). Transformação do problema de regressão inicial em um problema de classificação binária (c). Hiperplano que define a função de regressão (d). Fonte: Retirado de [Filgueiras et al. \(2014\)](#)

A aplicabilidade do método SVR para predição de criptomoedas não é muito difundida na literatura, porém é possível encontrar alguns trabalhos promissores como [Cao](#)

e Tay (2003). Entender e estudar tais modelos, a priori pouco investigados, pode trazer diferentes perspectivas para o estado da arte.

2.8 Métricas Adotadas

Em um sistema de modelagem e previsão de dados é essencial o uso de métricas que permitem avaliar e entender os resultados obtidos, por meio delas é possível sugerir quantitativamente a adequação da metodologia e processos ao problema. Para avaliação, *Mean Absolute Error* (MAE) e *Root Mean Square Error* (RMSE) são amplamente adotados em diversas áreas do conhecimento para medir desempenho Chai e Draxler (2014), sendo utilizados desde estudos climáticos, esportivos e principalmente para estimar a qualidade de um modelo de previsão. De acordo com Zhang e Qi (2005), o uso destas medidas representa ângulos diferentes para avaliar modelos de previsão, os dois primeiros são absolutos medidas de desempenho, enquanto a segunda é uma medida relativa. Diferente dos anteriores, o MAPE, traz uma perspectiva percentual de erro do método avaliado. Por último, o coeficiente *U de Theil* realiza uma comparação entre os resultados obtidos por métodos diferentes, mudando a perspectiva de análise da eficiência do modelo avaliado. Criado pelo ecônomo Henri Theil, a métrica avalia a capacidade de o modelo em prever múltiplos passos a frente. Como observado em Blimel (1973), a versão ainda mais simples do coeficiente de Theil, usada no trabalho, dá informações mais significativas sobre a precisão dos métodos de previsão. Como pode ser observado em Aznarte et al. (2012) e Affonso, Dias e Pinto (2021) a utilização de métricas que consideram os erros encontrados entre predição e valor real, como forma de avaliação para predição de series temporais, é efetiva, além de facilitar a identificação de características e realização comparativos.

2.8.1 RMSE

RMSE é a raiz do erro médio quadrático da diferença entre a predição e o valor real. Análoga ao desvio padrão, interpreta-se seu valor como uma medida do desvio médio entre observado e predito. Sendo x_i o valor real e x'_i o valor predito, tem-se:

$$RMSE = \sqrt{\frac{\sum_{i=1}^N (x_i - x'_i)^2}{N}} \quad (2.3)$$

2.8.2 MAE

Erro médio absoluto ou MAE, basicamente, consiste na média de erros que o modelo obteve. Diferente do RMSE, ele penaliza menos os grandes erros do modelo. Sendo x_i o valor real e x'_i o valor predito, tem-se:

$$MAE = \sum_{i=1}^N \frac{(x_i - x'_i)^2}{N} \quad (2.4)$$

2.8.2.1 MAPE

O *Mean Absolute Percent Error* (**MAPE**) diferente das métricas anteriormente citadas, e mede o erro em porcentagem. O mesmo é calculado como a média do erro percentual. Expressa a acurácia do erro em porcentagem. Desta maneira, um MAPE de 10% mostra que o erro médio do estimador é de 10%, e quanto menor o MAPE melhor é o ajuste.

$$MAPE = \frac{1}{n} \sum_{i=1}^N \frac{(x_i - x'_i)}{x_i} * 100 \quad (2.5)$$

2.8.3 U de Theil

O coeficiente *U de Theil* avalia o desempenho da previsão em relação à previsão pelo método Naïve. Essa estimativa mostra que o valor futuro é igual ao valor predito. A estatística U mede o quanto a previsão é melhor que o método Naïve. Com $U = 1$ significa que ambos os métodos são iguais; $U > 1$ que o método proposto é pior que Naïve; e $U < 1$ que ele é melhor.

$$U = \sqrt{\frac{\sum_{i=1}^{N-1} \left(\frac{x'_{i+1} - x_i - 1}{x_i}\right)^2}{\sum_{i=1}^{N-1} \left(\frac{x_{i+1} - x_i - 1}{x_i}\right)^2}} \quad (2.6)$$

2.9 Considerações finais

A partir dos conceitos abordados e descritos, no próximo capítulo será iniciada a fase de resultados. Serão implementados os métodos e modelos anteriormente citados, considerando uma adaptação para a base de dados escolhida, conforme a metodologia proposta. Desta forma, o 3 irá introduzir melhor o problema para implementações e análises futuras.

3 Desenvolvimento

Este capítulo apresentará uma contextualização sobre os dados, as técnicas utilizadas e objetivos, além disso será inicializado o estudo e avaliação da serie temporal do BTC e realizadas ponderações importantes para os capítulos que seguem.

A análise realizada, desde coleção dos dados à realização de modelagem e teste, foi feita utilizando a linguagem *Python*, versão 3.7.10, por meio de máquinas gratuitas disponibilizadas pelo ambiente do *Google Colaboratory*¹. Foram utilizadas as bibliotecas *Matplotlib* (HUNTER, 2007) para plotagem dos gráficos e imagens, *scipy* (VIRTANEN et al., 2020) e *statsmodels* (SEABOLD; PERKTOLD, 2010) para criação do Modelo ARIMA e realização de testes, e a biblioteca *keras* (CHOLLET et al., 2015), para instancias do modelo de rede neural LSTM. Além disso, aa biblioteca *scikit-learn* (PEDREGOSA et al., 2011) foi utilizada para instâncias do modelo SVR.

3.1 Coleção de dados

O conjunto de dados utilizados foi obtido na *CoinMarketCap*². Os dados selecionados são do período de 28 abril de 2013 até 12 de março de 2021, com, cerca de, 2.876 amostras. Esse conjunto é composto por registros diários contendo as seguintes informações:

- *Date* - Data do registro
- *Open* - Valor de abertura em US\$
- *High* - Valor de máxima em US\$
- *Low* - Valor de mínima em US\$
- *Close* - Valor de fechamento em US\$
- *Volume* - Quantidade total negociada em BTC
- *Market Cap* Valor total em US\$ da oferta de Bitcoin em circulação.

Toda análise realizada neste trabalho foi feita a partir da base de dados coletada, sofrendo alteração apenas no período avaliado. Seguindo a metodologia proposta o valor de fechamento da moeda ou *Close* será utilizado para realização de testes e os demais serão descartados. Desta maneira o estudo será focado na série temporal do BTC. Inicialmente

¹ <https://colab.research.google.com>

² <https://coinmarketcap.com/>

foram observadas as características estatísticas dos dados para um melhor entendimento do problema e foram fundamentais para definir alguns parâmetros da modelagem. A Figura 1, inserida na Seção 1.1, apresenta a série temporal do preço do Bitcoin para o conjunto de dados. É importante observar que, em 24/03/2017, um Bitcoin equivalia à US\$ 937,52. Já em 16/12/2017, o Bitcoin equivalia à US\$ 19.497,40. Isso representa a enorme variação em seus preços de mercado e pode ser percebido novamente no início do ano de 2021. Também é possível observar graficamente como o valor da moeda sofre fortes variações no decorrer do tempo.

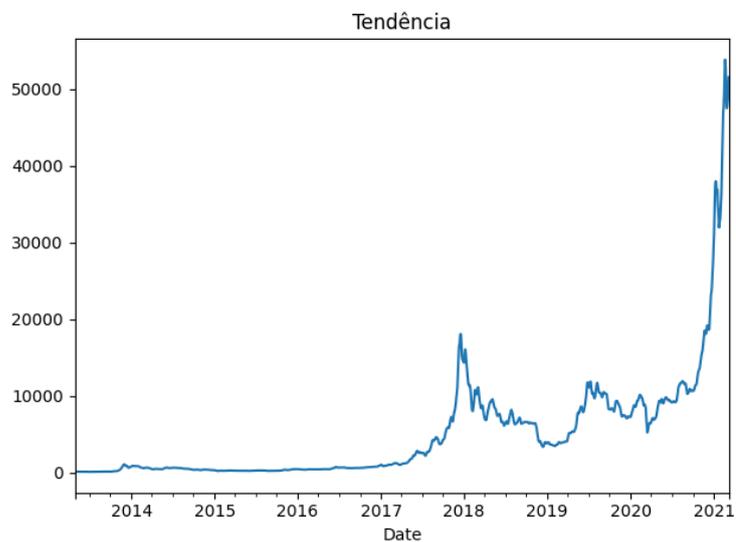
Apesar de conter diversas informações na base retirada, somente parte dela será efetivamente utilizada. Com base na metodologia proposta e com objetivo de entender seu funcionamento isolado, a variável de interesse para análise é o valor de fechamento ou *Close* da moeda.

3.2 Análise exploratória

Essa etapa é essencial para o andamento do trabalho. Nela serão identificadas características da série e adaptação dos dados com o objetivo de otimizar e facilitar a análise. Inicialmente, para adaptação dos dados, foi verificada a existência de algum valor nulo, e os mesmos retirados. Em seguida, a série foi decomposta em 3 componentes. A primeira é a sazonal, a qual indica eventos que acontecem repetidas vezes durante o tempo de observação além do período em que ocorrem. A segunda é a tendência que indica, basicamente, a predisposição dos dados durante tempo. E, por fim, a componente residual que é basicamente o que sobra da série ao se retirar a sazonalidade e a tendência. De maneira geral, ela representa fatores desconhecidos ou que não são mensuráveis. O método de decomposição utilizado foi o multiplicativo. As Figuras 7, 8 e 9 representam o resultado da decomposição.

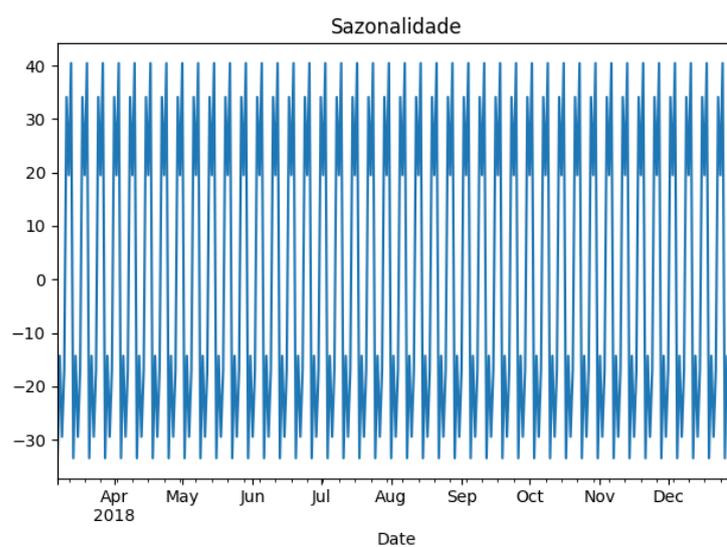
O gráfico *Boxplot* apresenta informações sobre os valores da série durante o tempo, tais como menor e maior, media e mediana, entre outros. Porém, para análise em questão, uma observação que chama a atenção é a quantidade de pontos que o gráfico sinaliza como sendo *outliers*. Ou seja, para o período analisado, tais pontos, em teoria, distorcem ou fogem do padrão da série. Para verificar se esses pontos são realmente *outliers* seria necessária uma análise mais aprofundada. Ainda assim, para o trabalho em questão, a análise simplificada é válida, pois sugere a separação que existe entre valores mínimos, máximos e quartis dos dados. O que, mais uma vez, sugere a volatilidade da série e a grande diferença que existe entre alguns pontos dela. Sendo assim, apesar de bem correlacionado, as análises sugerem como os dados não têm um padrão temporal. Apesar de inicialmente identificados os *outliers* presentes não foram retirados ou tratados para realização de testes. Devido à alta volatilidade a qual a série está sujeita, é essencial manter todos os

Figura 7 – Decomposição da série: tendência



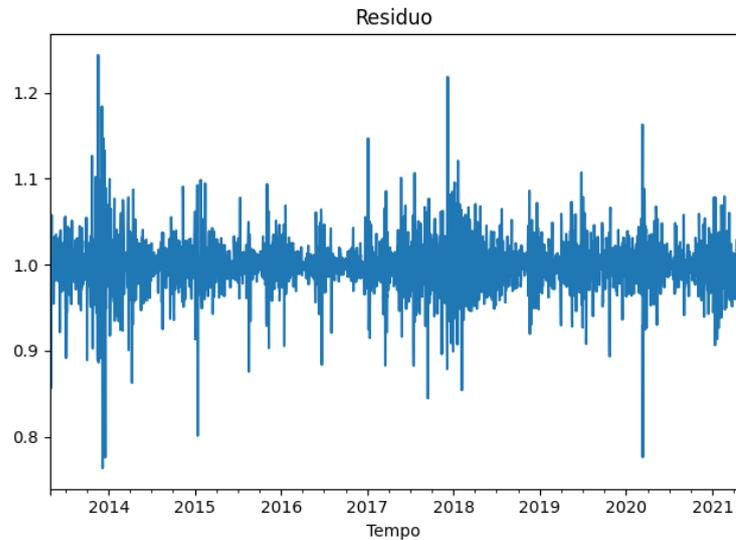
Fonte: elaborado pelo autor

Figura 8 – Decomposição da série: Sazonalidade



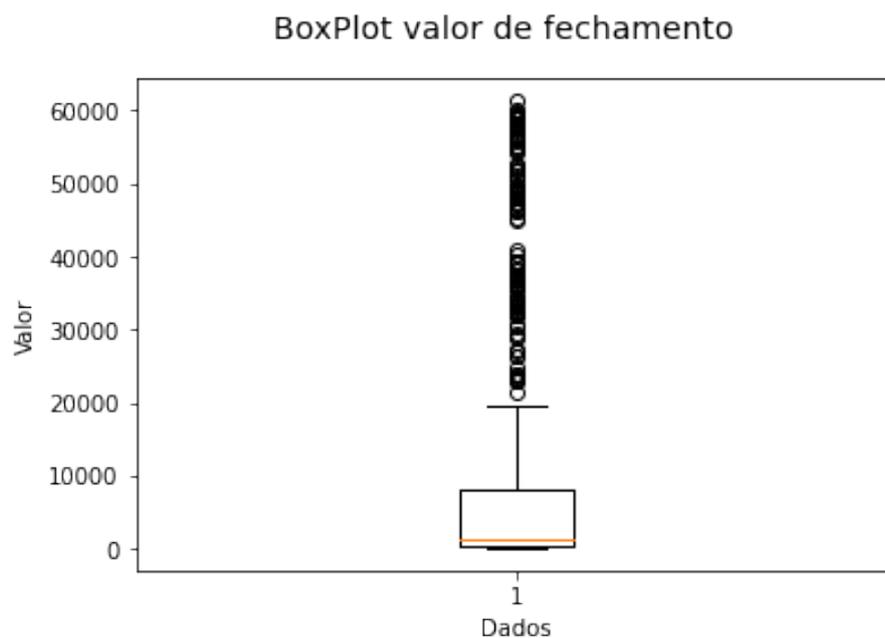
Fonte: elaborado pelo autor

Figura 9 – Decomposição da série: Resíduo



Fonte: elaborado pelo autor

dados, para que os modelos preditivos identifiquem tais características. A Figura 10, criada utilizando pontos diários desde janeiro de 2013 até março de 2021 do valor de fechamento do Bitcoin, representa a avaliação proposta. No gráfico, os pontos circulares indicam os *outliers* identificados pelo gráfico

Figura 10 – Gráfico *Boxplot* dos registros de cotação do Bitcoin

Abril de 2014 até março de 2021. Fonte: elaborado pelo autor

Bastante utilizado por investidores, o gráfico *Candlestick*, em português castiçal ou

gráfico de velas, traz informações de queda e alta para os valores diários do BTC. Para cada dia avaliado é criada um retângulo no gráfico, as hastes desses objetos representam os valores de máximo e mínimo diário, caso o valor de fechamento seja maior que do dia anterior o retângulo é verde, caso contrário vermelho. Por meio da Figura 11 é possível realizar análises de tendência e auxilia na visualização de perda ou ganho do valor da moeda.

Figura 11 – Gráfico *Candlestick* dos registros de cotação do Bitcoin



Início Abril de 2014 até março de 2021. Fonte: elaborado pelo autor

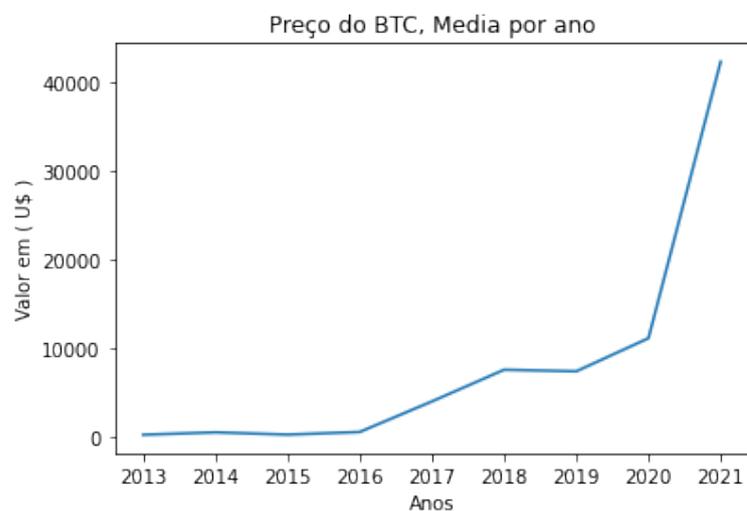
Agrupar os dados por períodos de tempos diferentes é uma estratégia interessante do ponto de vista analítico. É possível observar ou sugerir, por meio dessa avaliação, características temporais da série que são determinadas ou influenciadas por intervalos específicos no tempo. Desta maneira, os dados analisados foram redimensionados de diferentes formas com o objetivo de verificar a existência de tais situações. Inicialmente, o valor do BTC no período avaliado foi agrupado por ano e calculada uma média de seus valores anuais, como pode ser observado na Figura 12. Por meio deste gráfico, é possível verificar como durante os anos avaliados o valor da moeda segue sua tendência temporal.

A Figura 13 apresenta os dados agrupados por mês. Seguindo o primeiro passo, foi calculada a média para cada mês, utilizando o período de avaliação. Mediante ela, é evidente como o valor do BTC sofre uma ascensão no início e final dos anos avaliados, divergindo das demais épocas do ano.

Continuando a análise, os dados foram agrupados pela média diária de duas maneiras diferentes. No primeiro caso foram agrupados por dias da semana e no segundo caso por dias do ano. O resultado pode ser observado na Figura 14. Nesta etapa foi possível identificar uma pequena elevação do valor da moeda no meio da semana, porém pouco expressivo, e novamente a ascensão de seu valor no início e finais do ano.

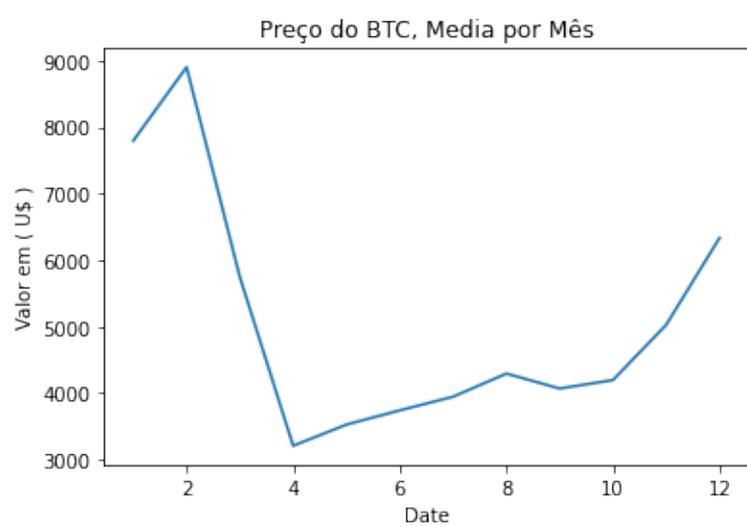
Por último, foi realizado um agrupamento semanal, no período anual, da média do valor do BTC, com um destaque para a diferenciação entre dias úteis e finais de semana. A Figura 15 ilustra a representação. Inicialmente não foi constatado uma diferença significativa

Figura 12 – Agrupamento da média anual do valor de fechamento do BTC



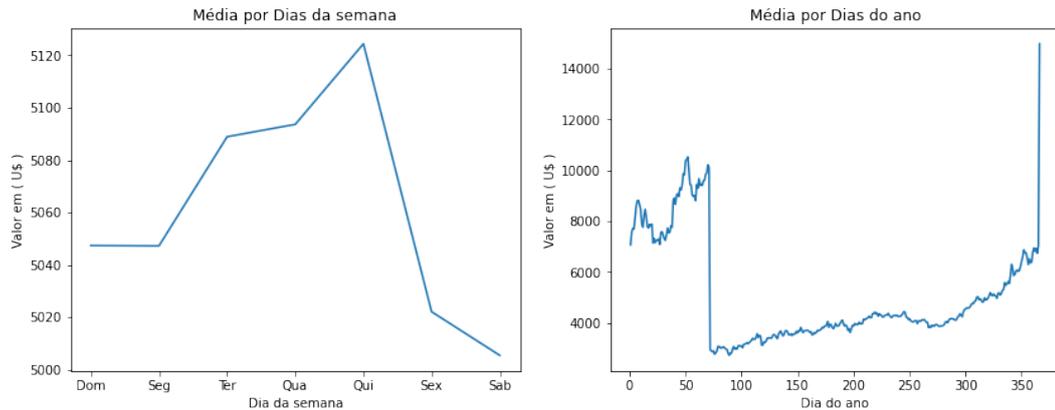
Fonte: elaborado pelo autor

Figura 13 – Agrupamento da média mensal do valor de fechamento do BTC



Fonte: elaborado pelo autor

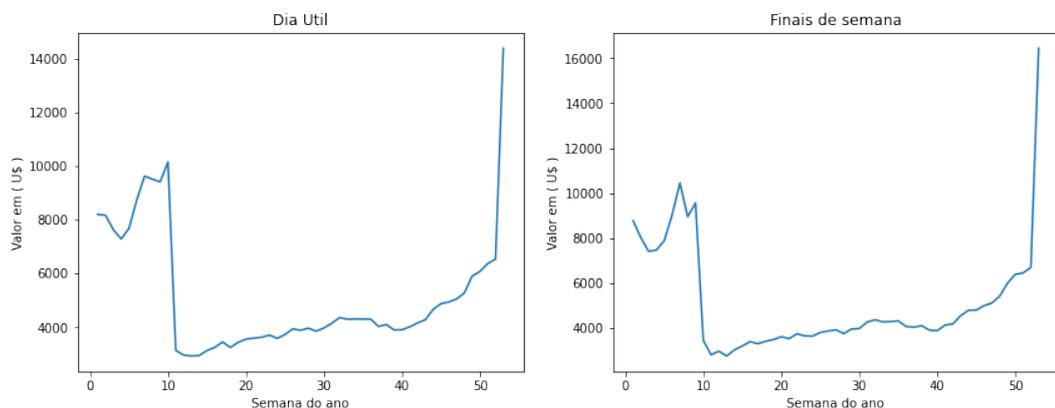
Figura 14 – Agrupamento da média diária do valor de fechamento do BTC



Fonte: elaborado pelo autor

entre os valores comercializados da moeda durante dias úteis e finais de semana. Porém, novamente, a ascensão de seu valor no início e final do ano é encontrada, indicando um possível comportamento a ser estudado futuramente.

Figura 15 – Agrupamento da média semanal do valor de fechamento do BTC



Fonte: elaborado pelo autor

3.3 Considerações finais

A partir das verificações iniciais feitas, foi possível identificar algumas características dos dados que serão utilizadas para futuras análises. Com o reconhecimento e coleção dos dados finalizados, no capítulo seguinte os modelos serão preparados, baseados na metodologia proposta, a série temporal adaptada para cada caso de teste e por fim os testes serão realizados.

4 Resultados

A partir da coleção de dados e análise exploratória concluída, neste capítulo serão apresentadas as implementações. Esta etapa descreve os testes propostos, considerando a metodologia enunciada, o referencial teórico, assim como as considerações do Capítulo 3. Por fim considerações, os resultados obtidos conforme o contexto experimental estabelecido serão discutidos.

4.1 Modelagem

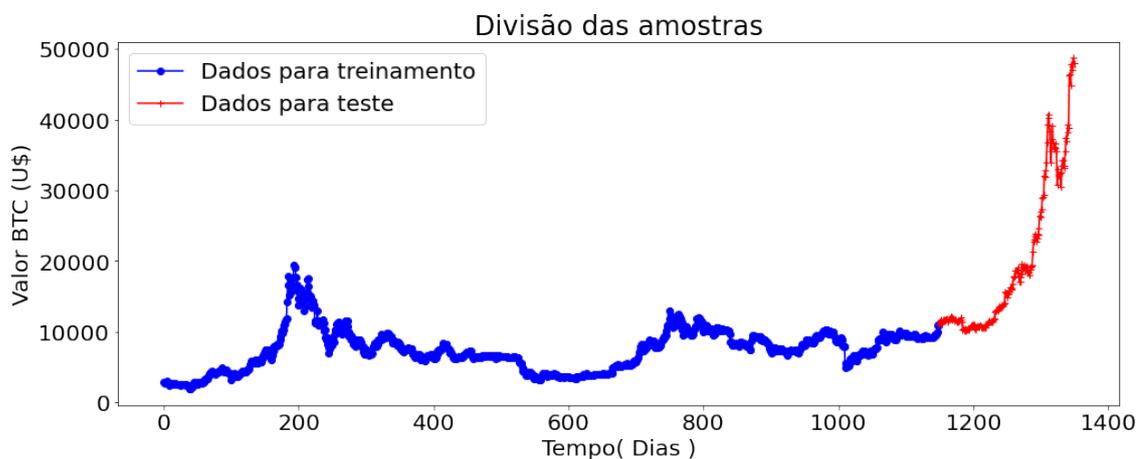
Pode-se observar, mediante as análises anteriores, que a sazonalidade referente a série sofre grande oscilação devido à volatilidade de seus valores, em complemento os agrupamentos temporais sugerem indícios da existência de sazonalidade no início dos anos. Porém, devido ao curto período de avaliação tais variações podem ser resultado de influências específicas e não tem relação explícita com algum intervalo de tempo.

Além disso, dada as observações realizadas, foi possível verificar como o período escolhido para análise pode ter impacto direto nos resultados, devido a sua grande variabilidade. Desta maneira, além de diversificar os modelos de predição e os métodos de análise de resultados, o intervalo avaliado será variado durante os testes com o objetivo de identificar suas especificidades.

4.1.1 Rede LSTM

Antes de realizar a entrada dos dados para o modelo, eles foram normalizados em uma escala de 0 a 1, e divididos entre treino e teste. Existem diversas maneiras para se dividir uma base de dados. Neste caso, a divisão foi feita de forma variada. Considerando que os modelos utilizados usam os próprios valores da série para aprendizado, o intervalo selecionado para treinamento pode trazer impactos nos resultados. Desta maneira, incorporar ou retirar picos de valor do BTC, durante a execução dos modelos, pode alterar diretamente os valores de predição. Um histórico de erro foi registrado durante as épocas de treinamento para identificar o aprendizado da rede. A Figura 16 ilustra a divisão inicial dos dados.

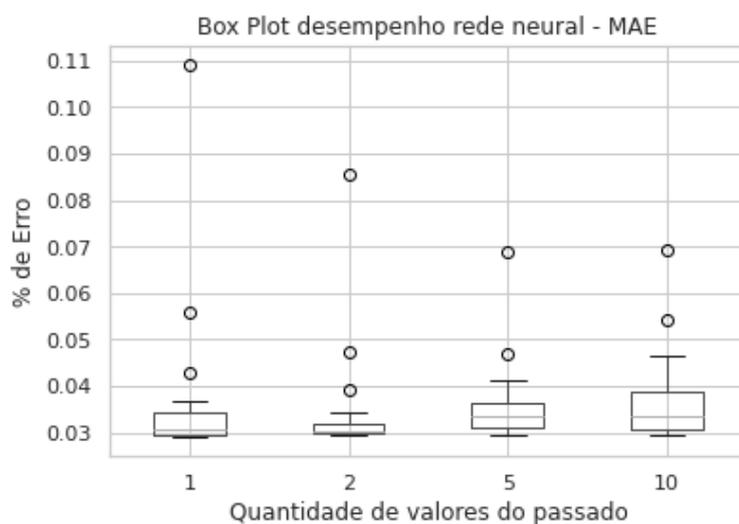
Figura 16 – Divisão inicial dos dados entre treino e teste



Fonte: elaborado pelo autor

Para definição de parâmetros foram realizados testes com o objetivo de identificar os que apresentassem melhores resultados. Durante o treinamento da rede foram armazenados os valores de erro médio absoluto percentual (MAPE) para cada época de treinamento. Esses valores foram utilizados como comparação de desempenho. O primeiro teste realizado foi da quantidade de valores do passado utilizados como entrada. A Figura 17 apresenta a comparação de desempenho para a rede, considerando o erro durante o treinamento e a quantidade de valores passados utilizados em cada um deles. Os resultados sugerem que a utilização de 2 valores do passado proporcionam um erro menor.

Figura 17 – Comparação entre quantidade de valores do passado

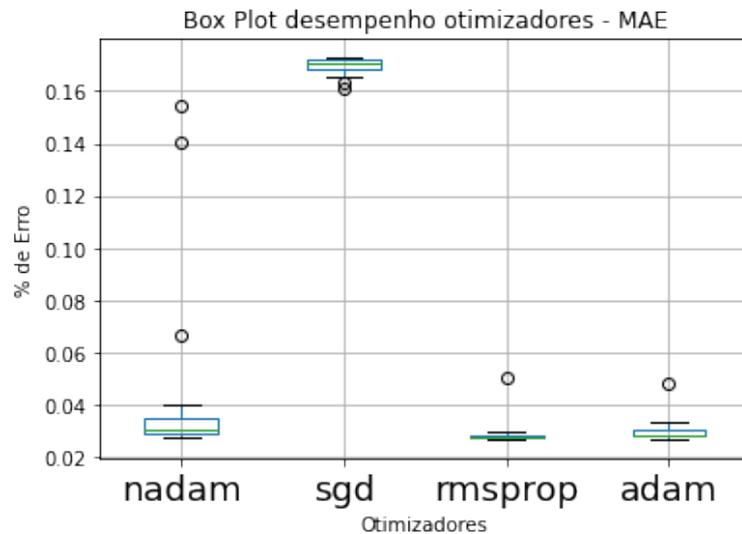


Fonte: elaborado pelo autor

O segundo teste realizado foi para definição do otimizador da rede neural mais eficiente. Esse otimizadores estão descritos na Seção 2.5.2.

Dentre o experimento, considerando o contexto estabelecido, os resultados sugerem que o *rmsprop* teve desempenho satisfatório, pois o percentual de erros é aparentemente menor. A Figura 18 apresenta a comparação entre eles baseada no erro durante treinamento.

Figura 18 – Comparação entre otimizadores

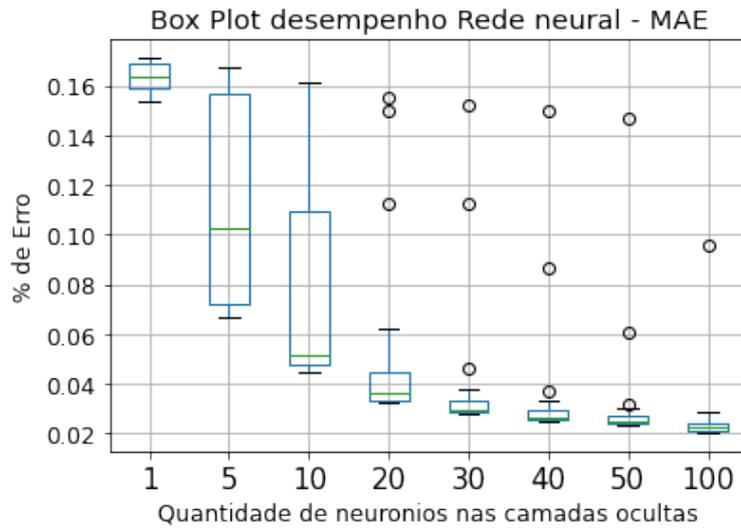


Fonte: elaborado pelo autor

O terceiro e último teste identificou a quantidade de neurônios nas camadas ocultas da rede, que reduzissem ao máximo o erro durante as épocas de treinamento. A Figura 19 sugere a quantidade mais adequada baseada no histórico de erros, sendo indicada como 100 neurônios na camada oculta. Além disso, o histórico de erro durante o treinamento foi avaliado para verificar a capacidade de generalização do modelo. A quantidade de neurônios selecionada considera o erro obtido durante treinamento assim como a capacidade de predição da rede. Importante destacar como existem resultados favoráveis e contras durante a definição de parâmetros para uma rede neural.

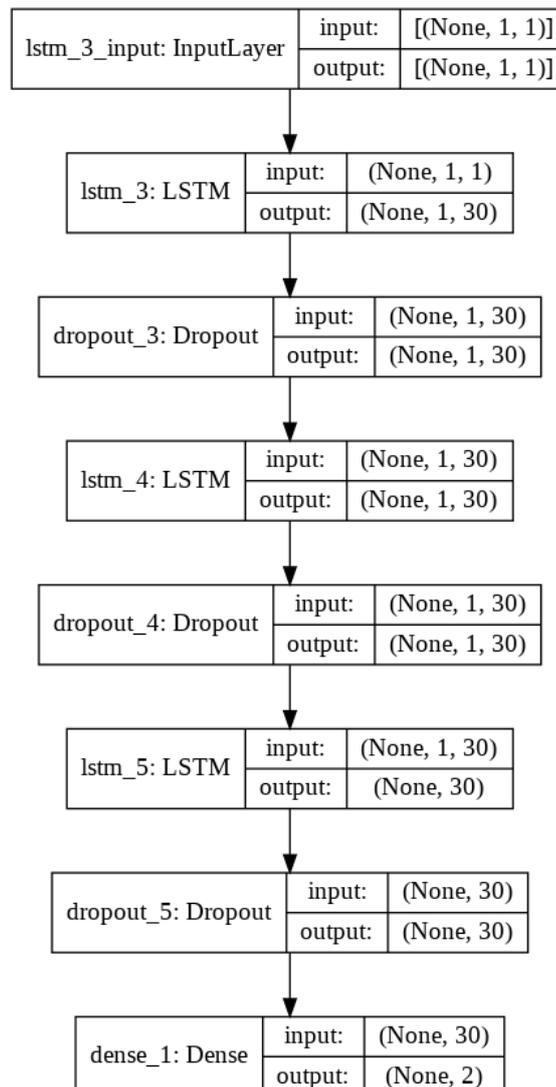
Existem ainda testes que poderiam ser realizados para definir a quantidade de camadas ocultas, tamanho de lote de treinamento, métricas de avaliação, dentre outros. Dada a metodologia proposta, os testes foram finalizados. Para definição e identificação de outros parâmetros seria necessário um estudo específico de adequação para o modelo. Desta maneira, a rede foi criada. A Figura 20 ilustra o escopo. A utilização de 3 camadas ocultas foi definida baseada na revisão da literatura.

Figura 19 – Comparação entre quantidade de neurônios



Fonte: elaborado pelo autor

Figura 20 – Escopo da rede neural finalizada



Fonte: elaborado pelo autor

Uma primeira tentativa de predição foi realizada alterando tanto a quantidade de valores a serem preditos, como o período avaliado. Os dados foram divididos e como entrada do modelo foram inseridos os 2.500 valores iniciais da série, intervalo de tempo onde a série se mostrou menos volátil. Para teste, foram utilizados os 100 próximos valores. A Figura 21 apresenta os valores originais e preditos.

Figura 21 – Teste de predição 2: LSTM – Treino: 2.500 valores iniciais. Teste: 100 próximos valores.

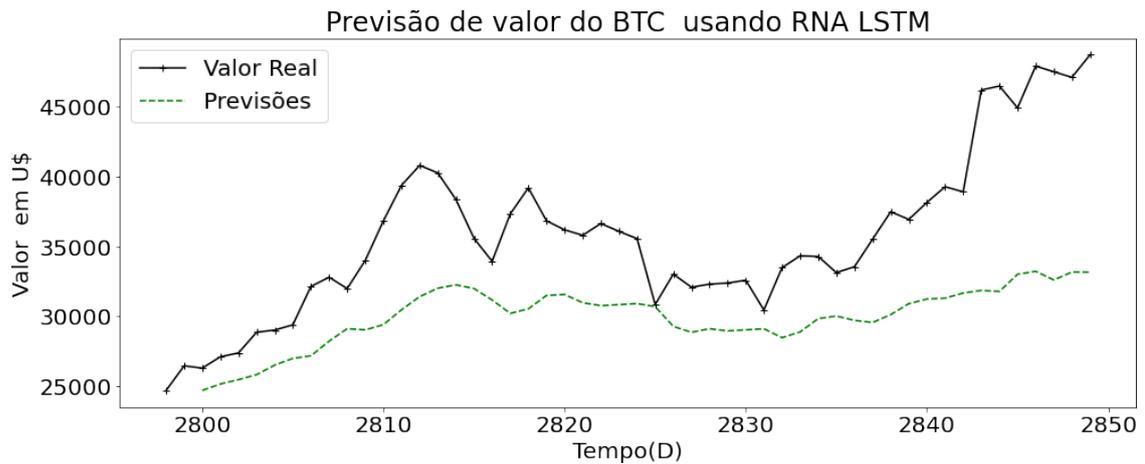


Fonte: elaborado pelo autor

Durante o treinamento, os resultados sugerem que a rede apresentou um percentual de erro médio de 3,6%, com o RMSE de 430 e o índice *U de Theil* de 1,82. De maneira geral, o RMSE penaliza grandes erros de previsão. Considerando os dados analisados, com um intervalo alto, esse valor sugere um desempenho satisfatório do modelo. Além disso, o índice de *U de Theil* quanto mais próximo de 1 (um), mais próxima é a predição em relação ao modelo Naïve.

A terceira alteração de período foi aplicada apenas na base de teste. Sendo os primeiros 2.800 valores, considerados como entrada para o modelo e os próximos 50 para teste. A Figura 22 apresenta os valores originais e previstos pelo modelo proposto. Durante o treinamento, os resultados sugerem um percentual de erro médio de 18,8%, com RMSE de 7.900 e o índice *U de Theil* de 4,0.

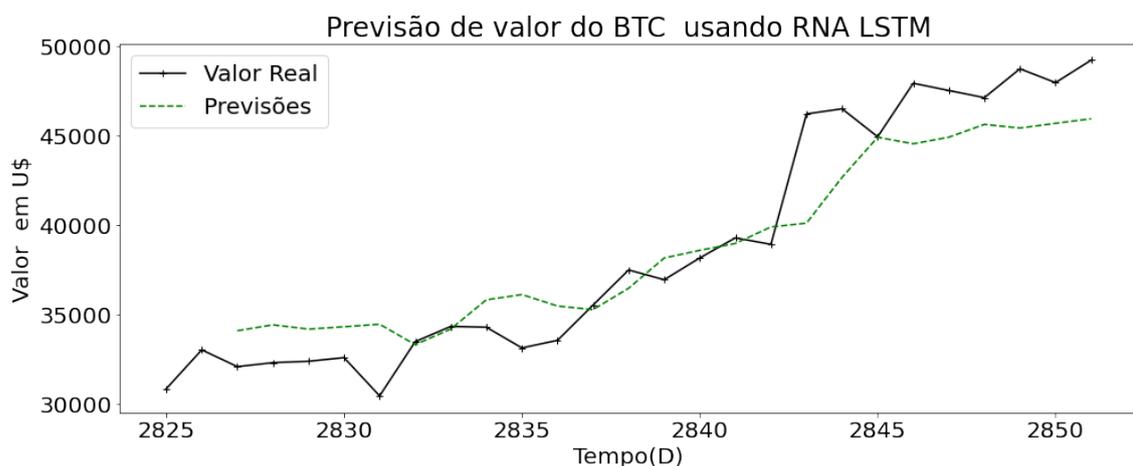
Figura 22 – Teste de predição 3: LSTM



Fonte: elaborado pelo autor

A quarta e última alteração de período para realização de teste foi feita apenas na base de teste. Os primeiros 2.825 valores foram utilizados como entrada para o modelo e os próximos 25 para teste. Os resultados são apresentados pela Figura 23, indicados os valores reais e previstos pelo modelo. Durante o treinamento, os resultados sugerem um percentual de erro médio de 5,2%, com RMSE de 2.432 e o índice *U de Theil* ficou em 1,11.

Figura 23 – Teste de predição 4: LSTM



Fonte: elaborado pelo autor

4.2 Modelo ARIMA

Na previsão de série temporal utilizando o modelo ARIMA, a primeira etapa é verificar a estacionariedade da série. É interessante, neste caso, que a série avaliada

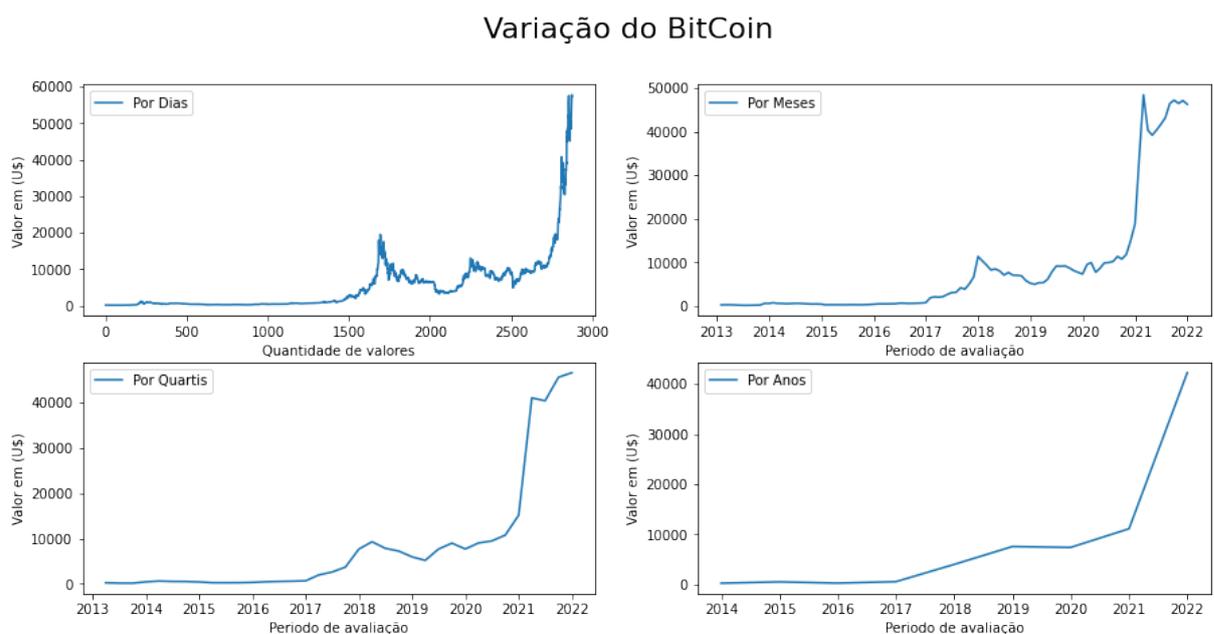
seja estacionária, considerando que o modelo utiliza médias móveis durante o processo de treinamento. Assim, inicialmente foi realizado o *Dickey-Fuller Test*. Sendo a série identificada como não estacionária, deve ser aplicada uma transformação nos dados para adaptação. Ao realizar o teste na base de dados original foi identificado um valor de $p = 1.00$. Esse resultado sugere a não estacionariedade da série.

Com o objetivo de torná-la estacionária foi aplicado uma diferenciação das séries de seus valores do passado. Cada observação dos dados é subtraída de seu respectivo valor anterior, considerando o intervalo da série. Esta prática é comum ao se utilizar o modelo ARIMA. Realizar tal diferenciação até a série se tornar estacionária é necessário para que o modelo apresente resultados satisfatórios.

Desta maneira, ao se aplicar a primeira diferenciação com os valores originais da série, obteve-se $p = 0.00$. Isso sugere que a transformação resultou numa série estacionária. Entretanto, isso não é interessante para o trabalho proposto, pois, desta maneira, a variância e média são completamente constantes com o tempo, tornando a previsão de valores conhecidos pelo modelo trivial, e a previsão de valores desconhecidos tendenciosa.

Sendo assim, com o objetivo de adaptar os dados para o modelo foi realizado um redimensionamento. A Figura 24 ilustra como os dados ficaram após 3 tentativas diferentes de transformação. Foram aplicados redimensionamentos nos dados por quartis, por anos e por meses.

Figura 24 – Dados redimensionados por mês



Fonte: elaborado pelo autor

A proposta inicial foi utilizar o redimensionamento semanal da série. Porém, foram

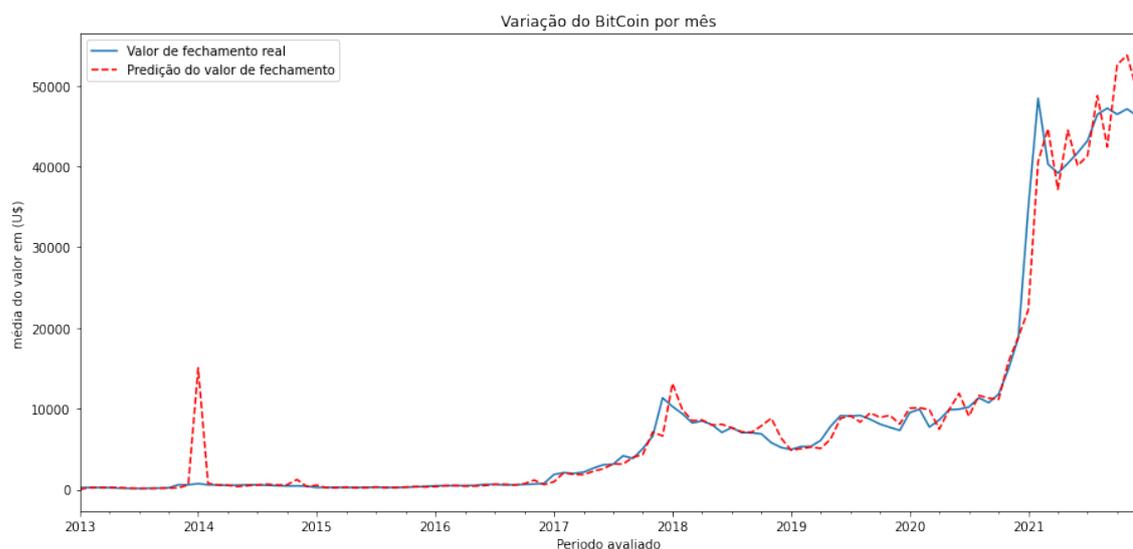
gerados diversos valores vazios durante a redistribuição aplicada, tendo em vista que o período avaliado não tem uma divisão semanal exata. Desta maneira, a redimensão que mais se aproxima da distribuição real foi a mensal, a qual foi selecionado para realização dos testes. Foram definidos 108 meses (valores da série), contendo cada um, a média mensal respectiva do valor de fechamento da moeda.

Novamente, os dados foram condicionados ao *Dickey-Fuller Test*, e obteve-se $p = 0.997890$, o que sugere a não estacionariedade da série. Aplicando-se a primeira diferenciação, o resultado foi $p = 0.111722$. Empregando pela segunda vez, obteve-se $p = 0.000276$. Assim, o resultado sugere que a série é parcialmente estacionária.

O modelo ARIMA é instanciado por meio da definição de 4 parâmetros. Com a intenção de identificar o melhor cenário, foram realizados teste com os parâmetros de entrada, variados entre 0 e 3. O treinamento do modelo foi feito utilizando essa variação, e os resultados do modelo foram comparados. Os parâmetros melhor qualificados, ou que obtiveram menores erros durante o treinamento foram selecionados.

A primeira predição realizada foi referente aos valores originais da série, para identificarmos a capacidade de regressão do modelo. Para realizar a verificação dos resultados, foi aplicado uma função para reverter a diferenciação anteriormente aplicada. A Figura 25, traz os dados originais da série redimensionados por mês, assim como a tentativa de previsão realizada.

Figura 25 – Teste de predição 1: ARIMA

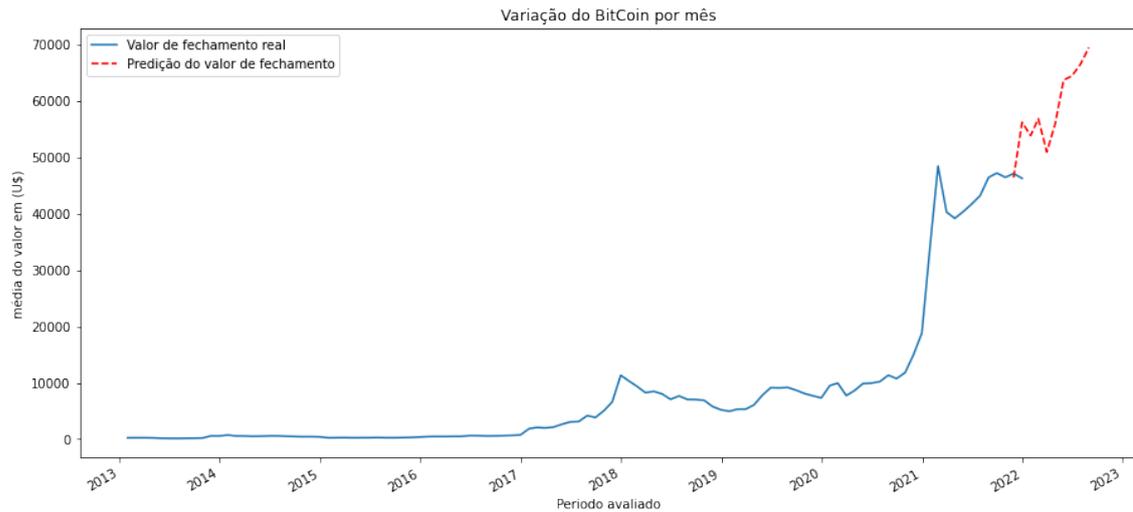


Fonte: elaborado pelo autor

Para validação, foram utilizados os mesmos índices de avaliação anteriormente usados, com o objetivo de futuras comparações. Os resultados sugerem um erro médio percentual de 34,8%, com RMSE foi de 2.470,21, e o índice *U de Thail* de 1.031.

Um segundo teste foi realizado para verificar a capacidade do modelo de realizar previsões futuras, de períodos ainda desconhecidos (não utilizados no treinamento). Devido à pequena quantidade de valores presentes nos dados redimensionados, eles não foram separados em treino e teste. A Figura 26 apresenta a série original e os valores previstos pelo modelo.

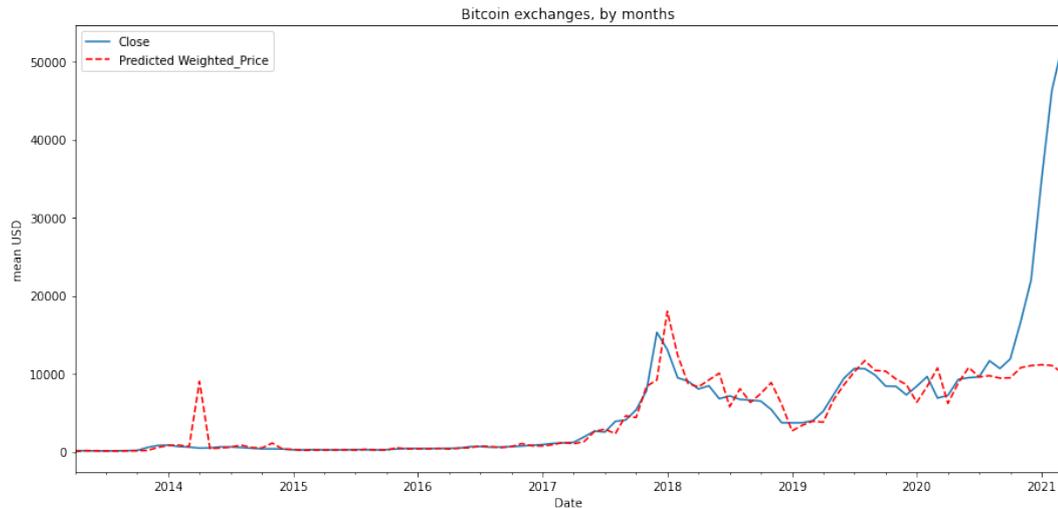
Figura 26 – Teste de predição 2: ARIMA



Fonte: elaborado pelo autor

A Figura 27 apresenta o último teste realizado, com o objetivo de mostrar a capacidade do modelo e realizar previsão dos dados em períodos de grande volatilidade da moeda. Fica evidente ao observar o gráfico como os valores preditos não acompanham a grande ascensão sofrida pelo BTC, destacando a deficiência do modelo quando sujeito a períodos de alta variação.

Figura 27 – Teste de predição 3, ARIMA



Fonte: elaborado pelo autor.

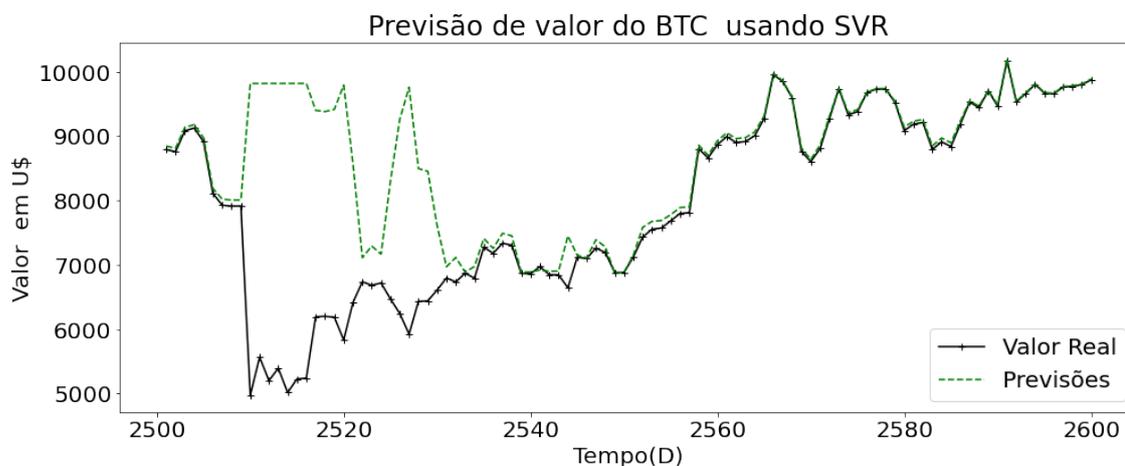
4.3 SVR

Para aplicação do modelo foram propostas duas abordagens diferentes para os dados de entrada ao modelo. Inicialmente, foi utilizado os valores passados da série, assim como nas etapas anteriores. Em uma segunda abordagem foram utilizados valores sequenciais na tentativa de representar a evolução temporal. Em ambos casos, os valores reais de fechamento da moeda foram utilizados como resposta.

Na primeira situação, as entradas do modelo são o valor de fechamento do dia anterior para cada dia avaliado. Para preparação do modelo foram realizados testes para verificar os melhores parâmetros para o modelo. Porém, ao se realizar ajustes finos, os resultados sugerem que parâmetros definidos como padrão pela linguagem apresentaram melhor desempenho.

Em seguida, foi realizada uma variação entre dados de treino e teste, sendo definidos 100 valores para teste, considerando um período de menor volatilidade da série. Como entrada do modelo, foram inseridos os 2.500 valores iniciais da série, intervalo de tempo no qual a série se mostrou menos volátil. Para teste, foram utilizados os 100 próximos valores. Assim, foram realizadas tentativas de previsão dos valores separados para teste. A Figura 28 apresenta os valores originais e as tentativas de previsão realizadas.

Figura 28 – Teste de predição 2: SVR

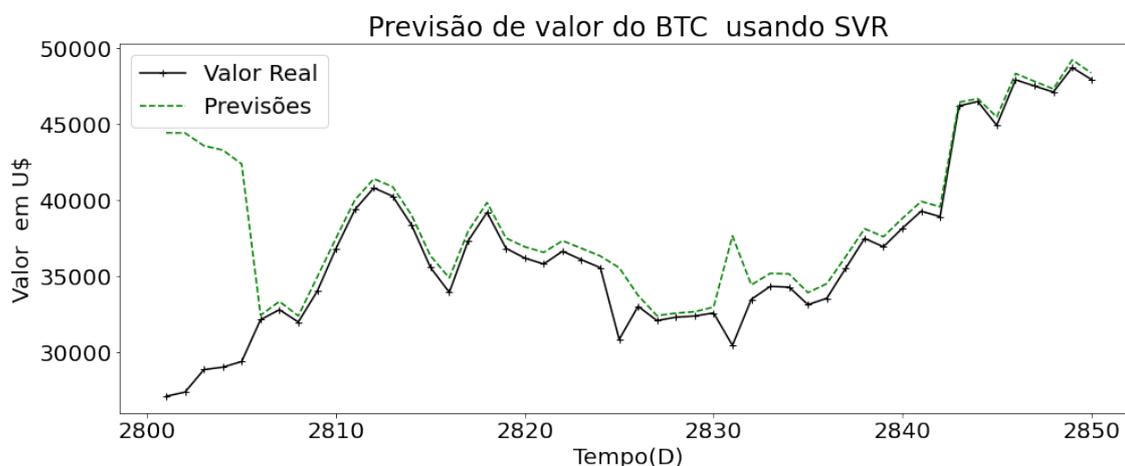


Fonte: elaborado pelo autor

Para avaliação foram utilizadas as mesmas métricas anteriores. Os resultados sugerem um percentual de erro médio de 12,22%, com RMSE de 1.555,38 e o índice *U de Theil* ficou em 1,16.

Foram também realizados testes para predição em um período mais volátil da série. Foram selecionados os primeiros 2.800 valores, considerados como entrada para o modelo e os próximos 50 para teste com o objetivo de futuras comparações. Os resultados são apresentados pela Figura 29, considerando os valores originais e preditos, além do intervalo considerado. As métricas sugerem um percentual de erro médio de 5,473%, com RMSE de 5.369,25 e o índice *U de Theil* ficou em 2,275.

Figura 29 – Teste de predição 3: SVR

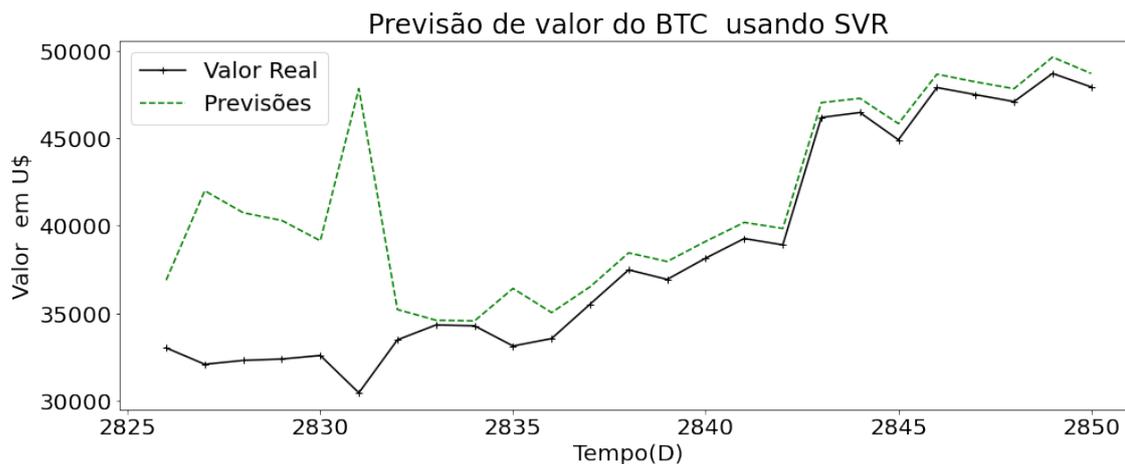


Fonte: elaborado pelo autor

Finalizando a primeira etapa, foram realizados testes para predição em um período

menor da série. Foram selecionados os primeiros 2.825 valores, considerados como entrada para o modelo, e os próximos 25 para teste com o objetivo de futuras comparações. Os resultados são apresentados pela Figura 30, considerando os valores originais e preditos, além do intervalo considerado. As métricas sugerem um percentual de erro médio de 7,473%, com RMSE de 5.069,25 e o índice *U de Theil* ficou em 1,33.

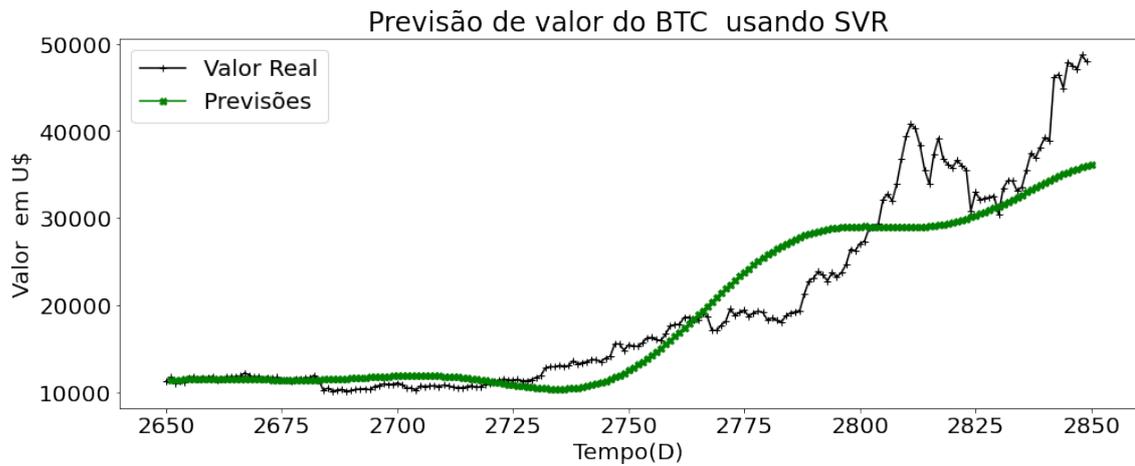
Figura 30 – Teste de predição 4: SVR



Fonte: elaborado pelo autor

Na segunda etapa, como entrada para o modelo foi passado uma sequência de valores, um para cada dia avaliado (1 a 2.860). Objetivo inicial foi vincular as datas de cotação com os valores de fechamento e desta maneira, identificar associação entre eles. Porém, os resultados obtidos não foram satisfatórios. Sendo assim, como entrada para o modelo foi passado um índice de cada valor respectivamente, começando de 1 até o último (2.860). Isso representa a evolução temporal dos dados de entrada. Após treinamento realizado, os dados de entrada para o modelo foram utilizados como teste para previsão. A Figura 31 apresenta a curva de predição para o modelo proposto.

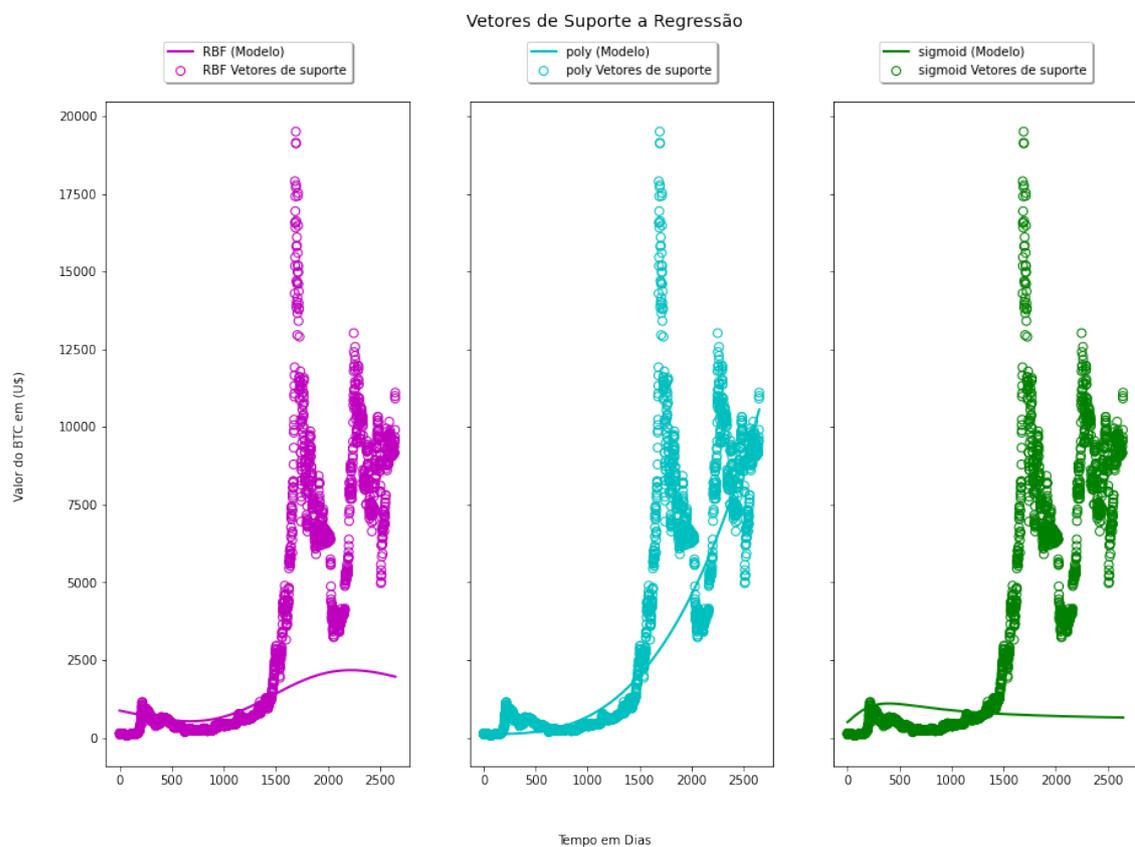
Figura 31 – Teste de predição 5, SVR



Fonte: elaborado pelo autor

Foram geradas também imagens do processo de treinamento da etapa anterior, com o objetivo de exemplificar o funcionamento do modelo. A Figura 32 ilustra os vetores de suporte criados, assim como as funções *kernel* que poderiam ser utilizadas para predição.

Figura 32 – Vetores de suporte gerados durante treinamento. Previsão de valores de teste – Modelo SVR



Fonte: Elaborado pelo autor.

4.4 Discussão

A primeira avaliação realizada foi referente a análise exploratória dos dados. Ao se observar os gráficos de agrupamento, os resultados sugerem a existência de um acréscimo do valor do BTC no início e final dos anos, seja esse agrupamento anual, semanal ou mensal. Tendo em vista a volatilidade da moeda e as influências externas que ela é sujeita, não é possível ainda vincular os picos de valor a um intervalo de tempo específico. Além disso, o período observado contém dois alavanches de valor, que ocorreram justamente no início e final dos anos de 2017/2018 e 2021. Esses saltos podem ter sido influenciados por diversos fatores externos. Esse é um ponto de atenção para estudos futuros, mas que carecem de mais análises.

Como indicado anteriormente e ilustrado pela Figura 10 e Figura 1, o gráfico *Boxplot* e o gráfico de valores reais sugerem a volatilidade da série. Os resultados possuem diversos *outliers* que divergem drasticamente dos valores de média e quartis da série, além dos picos de valores reais. Os valores da média e variância da série são instáveis ao decorrer do tempo.

Para entrada de dados aos modelos foram realizados diversos testes, os quais possibilitaram identificar a sensibilidade dos modelos referente aos picos de valores do BTC nos dados de treinamento. Desta maneira, a separação dos dados entre treino e teste foi feita priorizando o treinamento. Por isso, uma pequena parcela dos dados foi utilizada como teste.

Para cada modelo utilizado foram realizados testes com os respectivos parâmetros de entrada com o objetivo de selecionar os que apresentarem melhores resultados de cada um. No caso do modelo SVR, os testes de variação de parâmetros não apresentaram resultados satisfatórios. Sendo assim, foram utilizados parâmetros padrões para o modelo.

Devido à grande aparição do modelo ARIMA, para previsão e análise de séries temporais na literatura, esse método foi cotado como importante para análise realizada no trabalho. Devido à facilitação existente na estacionariedade da série para aplicação do ARIMA, foi necessário redimensionar os dados mensalmente. Apesar da diferenciação de períodos, esse método foi considerado na comparação entre os modelos. Antes do redimensionamento, foram realizados testes com os dados originais. Porém, o modelo não apresentou resultados satisfatórios.

As redes neurais LSTM foram selecionadas devido apresentarem resultados satisfatórios para previsão de séries temporais em diferentes trabalhos estudados da literatura. Não foram encontrados grandes problemas para entrada de dados ao modelo ou realização de testes e foi o modelo com maior diversidade de experiências realizadas, considerando o contexto estabelecido.

O modelo SVR, pouco encontrado na literatura para avaliação de séries temporais

financeiras, foi escolhido exatamente por este motivo. Se comparado aos modelos anteriores, o SVR é menos citado na literatura. Porém, a proposta inicial era utilizar como entrada para o modelo outros valores, que não fossem os do passado da série. As datas de cotação, por exemplo, seriam usadas como entrada para o modelo. Porém, não se obteve resultados satisfatórios. Sendo assim, foram realizados testes com os valores do passado da série como entrada para o modelo, semelhante à implementação da rede LSTM. Além disso, foi gerada uma sequência de valores, um para cada cotação da moeda, que serviu de entrada para um segundo teste realizado.

Os resultados dos índices de avaliação, utilizando o modelo ARIMA, SVR e as redes neurais LSTM, considerando espaços de tempo nos quais o BTC apresentou pouca volatilidade, são apresentados na Tabela 1.

Tabela 1 – Comparação de desempenho para períodos de baixa volatilidade

| Índices de Avaliação | | | |
|----------------------|-----------|--------|-------|
| Método | RMSE | MAPE | U |
| LSTM | 429,883 | 3,66 | 1,824 |
| ARIMA | 2.470,216 | 34,849 | 1,031 |
| SVR | 1.555.376 | 12,22 | 1,16 |

Fonte: Elaborado pelo autor.

A Tabela 2 foi feita com o objetivo de comparar o comportamento dos modelos diante da grande volatilidade da série. Nesse contexto, o ARIMA apresentou resultados bem distantes do ideal por isso, foi descartado.

Tabela 2 – Comparação de desempenho para períodos de alta volatilidade

| Índices de Avaliação | | | |
|----------------------|----------|-------|------|
| Método | RMSE | MAPE | U |
| LSTM | 7.892,22 | 18,29 | 4,01 |
| SVR | 5.369,25 | 9,47 | 2,53 |

Fonte: Elaborado pelo autor.

A escolha dos índices de avaliação tentou levar em consideração tanto o erro de predição do modelo quanto a adaptação do mesmo a série temporal, tendo em conta a penalização de erros em pequena e larga escala. A seleção dos índices de avaliação para a tabela de comparação final considerou os melhores resultados obtidos por cada modelo, contendo a mesma quantidade de dados para teste e treino, exceto para o modelo ARIMA. Apesar de considerar uma dimensão diferente dos dados para avaliação, o modelo ARIMA foi acrescentado a tabela de resultados a título de comparação.

É importante destacar a atribuição de pesos aleatórios que acontece durante o treinamento de uma rede neural, tornando sua implementação um pouco mais complexa. Além disso, foi necessário a realização de diversos testes utilizando os mesmos dados de entrada e parâmetros para ser possível obter uma média dos índices de avaliação.

Os resultados obtidos pelo modelo SVR utilizando dados sequenciais como entrada não foram considerados na tabela de comparação. Porém, esses resultados foram importantes para as considerações finais e conclusões.

A partir das tabelas de comparação, os resultados sugerem que o modelo de redes neurais LSTM apresentou desempenho mais satisfatórios considerando o erro de predição dos modelos, ou seja para os períodos testados o modelo apresentou o menor erro entre os valores preditos e os reais. Entretanto, o índice *U de theil* se mostrou promissor para o entendimento da série utilizando os outros modelos. Além disso, é possível observar como o comportamento do modelo SVR foi melhor se analisado um período mais volátil da série.

É importante destacar também que os valores referentes as previsões realizadas diferem entre o modelo SVR e as redes LSTM, pois os dados são submetidos a um redimensionamento para serem introduzidos no modelo SVR. Assim, o processo invertido é realizado para comparação dos resultados, tornando os dados ligeiramente diferentes.

Outro ponto importante é identificar como alguns períodos, ao se realizar a previsão pelo modelo SVR, tem o sentido oposto dos valores reais. Desta maneira, em algumas situações onde existe um acréscimo do valor, pode acontecer um decréscimo na previsão e vice-versa.

5 Conclusão

Por meio da revisão da literatura foi possível verificar como métodos de inteligência computacional, mais especificamente aprendizagem de máquina são eficazes para modelar e prever séries temporais de maneira geral. Entretanto, identificar valores ou tendências futuras de uma série não é uma tarefa simples, principalmente se tratando do contexto financeiro onde o contexto estudado sofre interferência de diversos fatores externos.

Em particular, as criptomoedas, diferente dos ativos convencionais, sofrem interferências não conhecidas em seu valor, fazendo com que sua evolução temporal seja extremamente volátil. Existem indícios e estudos de situações que podem ocasionar tais alterações. Porém, seu curto período de existência exige pesquisas mais aprofundadas sobre o tema. Os períodos de 2017, 2018 e 2021 foram atípicos, evidenciando o quão intensas podem ser as variações do valor de cotação do BTC, no caso.

Este trabalho visou investigar a eficiência da modelagem e entendimento da série temporal do BTC, com o intuito de realizar previsões de seu valor futuro. Foi possível a partir deste trabalho identificar prováveis tendências que a série tomou ao decorrer do tempo, comportamentos em períodos específicos de tempo. Além disso, foi possível avaliar como diferentes métodos identificam a evolução da série e preveem seus valores.

Os modelos de treinamento selecionados e as técnicas utilizadas para previsão, tiveram como objetivo diversificar os conteúdos já existentes sobre o tema, além de propor abordagens diferentes entre si. Inicialmente, as redes neurais LSTM apresentaram erros de previsão menores que as demais abordagens para períodos de baixa volatilidade. Entretanto, ao se propor períodos de alta volatilidade para previsão, os resultados sugerem que o modelo não se comportou tão bem, destacando uma deficiência para a categoria de análise proposta. Já o modelo ARIMA, apesar da necessidade de redimensionar a série, conseguiu por sua modelagem simples, acompanhar o desenvolvimento da mesma temporalmente e também prever futuras possibilidades para o valor da moeda. Da mesma maneira, o SVR, apesar de não obter resultados tão satisfatórios quanto a rede LSTM, se mostrou superior para períodos de alta volatilidade da moeda. Além disso, apesar de obterem um percentual de erro maior, o ARIMA e SVR se mostraram ligeiramente superiores à rede LSTM avaliando o índice *U de Theil*, sugerindo um potencial de modelagem promissor na realização de previsões múltiplos passos a frente, considerado o conjunto de dados e o contexto experimental estabelecido.

De maneira geral, avaliando os resultados obtidos, foi possível observar como os modelos propostos, dada a metodologia, foram capazes de realizar previsões de intervalos de tempos e valores desconhecidos do BTC de maneira eficiente, além de se comporta-

rem bem para diferentes abordagens. Entretanto, ao se considerar períodos nos quais o comportamento da moeda era instável ou mais volátil, os modelos não previram bem essa situação. Os grandes picos de valor sofridos pelo BTC, seja de alta ou baixa, são resultados de um conjunto de fatores. Estudá-los e entendê-los é essencial para se prosseguir com o trabalho.

Outra consideração que deve ser realizada é referente ao tempo de existência do BTC. A partir da análise exploratória, por exemplo, foi possível levantar e identificar possíveis características da série. Entretanto, seu pequeno período de existência não permite inferir padrões ainda. Além disso, as situações atípicas ao qual a série está sujeita dificultam seu entendimento, estudo e corroboram com as grandes variações e falta de padrão identificados. É importante destacar que, dada a metodologia proposta, foram utilizados diferentes métodos e modelagens preditivas com intuítos comparativos. Entretanto, é recomendado um estudo específico de cada modelo apresentado, com o objetivo de realizar um ajuste fino e adequação a cada situação.

5.1 Trabalhos futuros

Para trabalhos futuros sugere-se a avaliação de períodos de alta volatilidade da série, considerando análise de redes sociais, notícias, moedas fiduciárias, dentre outros. Essa avaliação pretende identificar e modelar as influências externas ao qual a moeda está sujeita.

Mediante uma análise consistente de situações que acarretam picos de alta e baixo do valor do BTC, seria possível propor valores futuros ou tendências para a moeda. Considerando o bom comportamento dos modelos avaliados para períodos conhecidos por treinamento, unir esses dois estudos pode ser um passo promissor para o entendimento da evolução temporal do BTC.

Ao se unir uma abordagem qualitativa de influências externas como, por exemplo, a análise de sentimento do *Twitter*, e uma abordagem quantitativa baseada nos próprios valores da série, pode ser a maneira mais adequada de conduzir a pesquisa. Além disso, essas avaliações podem ser um estudo promissor para a previsão da moeda.

Referências

ADCOCK, R.; GRADOJEVIC, N. Non-fundamental, non-parametric bitcoin forecasting. *Physica A: Statistical Mechanics and its Applications*, Elsevier, v. 531, p. 121727, 2019. Citado 2 vezes nas páginas 18 e 19.

AFFONSO, F.; DIAS, T. M. R.; PINTO, A. L. Financial times series forecasting of clustered stocks. *Mobile Networks and Applications*, Springer, v. 26, n. 1, p. 256–265, 2021. Citado na página 28.

AGIAKLOGLOU, C.; NEWBOLD, P. Empirical evidence on dickey-fuller-type tests. *Journal of Time Series Analysis*, Wiley Online Library, v. 13, n. 6, p. 471–483, 1992. Citado na página 21.

ATSALAKIS, G. S. et al. Bitcoin price forecasting with neuro-fuzzy techniques. *European Journal of Operational Research*, Elsevier, v. 276, n. 2, p. 770–780, 2019. Citado na página 19.

AZNARTE, J. L. et al. Financial time series forecasting with a bio-inspired fuzzy model. *Expert Systems with Applications*, Elsevier, v. 39, n. 16, p. 12302–12309, 2012. Citado na página 28.

BAYER, F. M. Wavelets e modelos tradicionais de previsão: um estudo comparativo. *Rev. Bras. Biom*, v. 28, n. 2, p. 40–61, 2010. Citado 2 vezes nas páginas 22 e 25.

BLIEMEL, F. *Theil's forecast accuracy coefficient: A clarification*. [S.l.]: SAGE Publications Sage CA: Los Angeles, CA, 1973. Citado na página 28.

BOX, G. E. et al. *Time series analysis: forecasting and control*. [S.l.]: John Wiley & Sons, 2015. Citado na página 25.

BROCKWELL, P. J. et al. *Introduction to time series and forecasting*. [S.l.]: Springer, 2016. Citado na página 22.

CAO, L.-J.; TAY, F. E. H. Support vector machine with adaptive parameters in financial time series forecasting. *IEEE Transactions on neural networks*, IEEE, v. 14, n. 6, p. 1506–1518, 2003. Citado na página 28.

CASTELLO, M. G. Bitcoin é moeda? classificação das criptomoedas para o direito tributário. *Revista Direito GV*, SciELO Brasil, v. 15, n. 3, 2019. Citado 2 vezes nas páginas 19 e 20.

CASTRO, M. C. F. d. et al. Predição não-linear de séries temporais usando redes neurais rbf por decomposição em componentes principais. [sn], 2001. Citado na página 22.

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. Citado na página 19.

- CAVAIONI, M. *DeepLearning series: Sequence Models*. 2014. Acessado em 05 jul 2020. Disponível em: <<https://medium.com/machine-learning-bites/deeplearning-series-sequence-models7855babe586>>. Citado na página 23.
- CHAI, T.; DRAXLER, R. R. Root mean square error (rmse) or mean absolute error (mae)?—arguments against avoiding rmse in the literature. *Geoscientific model development*, Copernicus GmbH, v. 7, n. 3, p. 1247–1250, 2014. Citado na página 28.
- CHEN, E. *Exploring LSTMs*. 2017. Acessado em 15 jun 2020. Disponível em: <<http://blog.echen.me/2017/05/30/exploring-lstms>>. Citado na página 24.
- CHOLLET, F. et al. *Keras*. 2015. <<https://keras.io>>. Citado na página 30.
- DOZAT, T. Incorporating nesterov momentum into adam. 2016. Citado na página 24.
- ELAMIN, N.; FUKUSHIGE, M. Modeling and forecasting hourly electricity demand by sarimax with interactions. *Energy*, Elsevier, v. 165, p. 257–268, 2018. Citado na página 25.
- ESCOVEDO, A. S. K. T. *Introdução a Data Science — Algoritmos de Machine Learning e métodos de análise*. [S.l.]: São Paulo, Ed. Casa do Código, 2020. Citado na página 26.
- FILGUEIRAS, P. R. et al. Regressão por vetores de suporte aplicado na determinação de propriedades físico-químicas de petróleo e biocombustíveis. [sn], 2014. Citado 2 vezes nas páginas 26 e 27.
- GHEYAS, I. A.; SMITH, L. S. A neural network approach to time series forecasting. In: CITESEER. *Proceedings of the World Congress on Engineering*. [S.l.], 2009. v. 2, p. 1–3. Citado na página 18.
- GREFF, K. et al. Lstm: A search space odyssey. *IEEE Transactions on Neural Networks and Learning Systems*, v. 28, n. 10, p. 2222–2232, 2017. Citado na página 24.
- GROOT, C. de; WÜRTZ, D. Analysis of univariate time series with connectionist nets: A case study of two classical examples. *Neurocomputing*, Elsevier, v. 3, n. 4, p. 177–192, 1991. Citado na página 18.
- HANNAN, E. J. *Multiple time series*. [S.l.]: John Wiley & Sons, 2009. v. 38. Citado na página 20.
- HAYKIN, S. *Redes neurais: princípios e prática*. [S.l.]: Bookman Editora, 2007. Citado 2 vezes nas páginas 22 e 23.
- HINTON, G.; SRIVASTAVA, N.; SWERSKY, K. Neural networks for machine learning lecture 6a overview of mini-batch gradient descent. *Cited on*, v. 14, n. 8, 2012. Citado na página 24.
- HOCHREITER, S.; SCHMIDHUBER, J. Long short-term memory. *Neural Comput.*, MIT Press, Cambridge, MA, USA, v. 9, n. 8, p. 1735–1780, nov. 1997. ISSN 0899-7667. Disponível em: <<https://doi.org/10.1162/neco.1997.9.8.1735>>. Citado na página 24.
- HUGHES, S. D. Cryptocurrency regulations and enforcement in the us. *W. St. UL Rev.*, HeinOnline, v. 45, p. 1, 2017. Citado na página 20.

- HUNTER, J. D. Matplotlib: A 2d graphics environment. *Computing in Science & Engineering*, IEEE COMPUTER SOC, v. 9, n. 3, p. 90–95, 2007. Citado na página 30.
- JEFFREY, N. S. C. *Statistical analysis of the exchange rate of bitcoin*. [S.l.]: Decision Support Systems, 2015. 49-60 p. Citado na página 14.
- KHASHEI, M.; BIJARI, M. An artificial neural network (p, d, q) model for timeseries forecasting. *Expert Systems with applications*, Elsevier, v. 37, n. 1, p. 479–489, 2010. Citado na página 18.
- KINGMA, D. P.; BA, J. Adam: A method for stochastic optimization. *arXiv preprint arXiv:1412.6980*, 2014. Citado na página 24.
- KRÖSE, B. et al. An introduction to neural networks. Citeseer, 1993. Citado na página 22.
- LAPEDES, A.; FARBER, R. *Nonlinear signal processing using neural networks: Prediction and system modelling*. [S.l.], 1987. Citado na página 18.
- LI, X.; WANG, C. A. The technology and economic determinants of cryptocurrency exchange rates: The case of bitcoin. *Decision Support Systems*, v. 95, p. 49 – 60, 2017. ISSN 0167-9236. Disponível em: <<http://www.sciencedirect.com/science/article/pii/S0167923616302111>>. Citado na página 14.
- LIMA, C. A. d. M. et al. Comitê de máquinas: uma abordagem unificada empregando máquinas de vetores-suporte. [sn], 2004. Citado na página 26.
- MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. *The bulletin of mathematical biophysics*, Springer, v. 5, n. 4, p. 115–133, 1943. Citado na página 22.
- MORETTIN, P. A. *Econometria financeira: um curso em séries temporais financeiras*. [S.l.]: Editora Blucher, 2017. 339-343 p. Citado na página 20.
- NAKAMOTO, S. *Bitcoin: A peer-to-peer electronic cash system*. [S.l.], 2019. Citado 2 vezes nas páginas 19 e 20.
- OANCEA, B.; CIUCU, Ș. C. Time series forecasting using neural networks. *arXiv preprint arXiv:1401.1333*, 2014. Citado na página 18.
- PEDREGOSA, F. et al. Scikit-learn: Machine learning in Python. *Journal of Machine Learning Research*, v. 12, p. 2825–2830, 2011. Citado na página 30.
- RAUBER, T. W. Redes neurais artificiais. *Universidade Federal do Espírito Santo*, p. 29, 2005. Citado na página 22.
- RODRIGUES, C. K. da S. Sistema bitcoin: uma análise da segurança das transações. *iSys-Brazilian Journal of Information Systems*, v. 10, n. 3, p. 5–23, 2017. Citado na página 19.
- SEABOLD, S.; PERKTOLD, J. statsmodels: Econometric and statistical modeling with python. In: *9th Python in Science Conference*. [S.l.: s.n.], 2010. Citado na página 30.
- 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. Citado na página 20.

- SUTSKEVER, I. et al. On the importance of initialization and momentum in deep learning. In: PMLR. *International conference on machine learning*. [S.l.], 2013. p. 1139–1147. Citado na página [24](#).
- VAPNIK, V. et al. Support vector method for function approximation, regression estimation, and signal processing. *Advances in neural information processing systems*, Morgan Kaufmann Publishers, p. 281–287, 1997. Citado na página [26](#).
- VIRTANEN, P. et al. SciPy 1.0: Fundamental Algorithms for Scientific Computing in Python. *Nature Methods*, v. 17, p. 261–272, 2020. Citado na página [30](#).
- YANG, S. Y.; KIM, J. Bitcoin market return and volatility forecasting using transaction network flow properties. In: IEEE. *2015 IEEE Symposium Series on Computational Intelligence*. [S.l.], 2015. p. 1778–1785. Citado na página [19](#).
- YENIDOĞAN, I. et al. Bitcoin forecasting using arima and prophet. In: IEEE. *2018 3rd International Conference on Computer Science and Engineering (UBMK)*. [S.l.], 2018. p. 621–624. Citado na página [19](#).
- ZHANG, G. P. Time series forecasting using a hybrid arima and neural network model. *Neurocomputing*, Elsevier, v. 50, p. 159–175, 2003. Citado na página [25](#).
- ZHANG, G. P.; QI, M. Neural network forecasting for seasonal and trend time series. *European journal of operational research*, Elsevier, v. 160, n. 2, p. 501–514, 2005. Citado na página [28](#).