

REDES NEURAIS ARTIFICIAIS NA PREVISÃO DO PREÇO DAS AÇÕES NA BOLSA DE VALORES POR MEIO DE NOTÍCIAS

Fabrcio Oliveira Bezerra, Andreza Sartori - Orientadora

Curso de Bacharel em Ci4ncia da Computa4o
Departamento de Sistemas e Computa4o
Universidade Regional de Blumenau (FURB) – Blumenau, SC – Brasil

fobezerra@furb.br, asartori@furb.br

Resumo: *Investir na bolsa de valores pode representar excelentes oportunidades financeiras, o que impulsiona pesquisadores e investidores a prever o mercado financeiro. Este trabalho apresenta um prot3tipo usando Redes Neurais Artificiais para sugerir a compra ou venda de ativos negociados na Bolsa de Valores brasileira, por meio de not3cias do mercado financeiro, a fim de auxiliar investidores nas suas transa4es no mercado de renda vari3vel. Para isso, 10.766 not3cias foram usadas como base de dados de aprendizagem do prot3tipo, advindas das empresas BBAS3, PRIO e VALE3, no per3odo 01/01/2018 e 20/05/2022. S3o abordados assuntos como Redes Neurais Artificiais Long Short-Term Memory (LSTM) para fazer as previs3es, Raspador Web (Web Scraper) para realizar a coleta das not3cias do mercado financeiro e a API Yahoo Finance para obter as cota4es das a4es. O percentual de acur3cia do prot3tipo alcan4ou 52% nos testes. Assim, o trabalho atingiu todos os objetivos propostos e facilita aos investidores ter uma vis3o sobre os testes realizados com dados hist3ricos.*

Palavras-chave: *Redes Neurais Artificiais. LSTM. Previs3o. Bolsa de valores. A4es. Not3cias.*

1 INTRODU4O

De acordo com Trisotto (2020), o ano de 2020 fechou com 3,2 milh3es de pessoas f3sicas cadastradas como investidoras na bolsa de valores brasileira, somando R\$ 424 bilh3es em a4es. Um dos motivos citados foi a democratiza4o no acesso 3 informa4o. Assim, parte dos novos investidores tomam suas decis3es de compra ou venda de a4es, por interm3dio da Internet, por meio de canais de influenciadores digitais, ou por conta pr3pria, a partir da an3lise de dados e informa4es de fontes distintas. A volatilidade, que se associava com o afastamento dos pequenos investidores, teve menor impacto a partir de 2020. Trisotto (2020) revela que o presidente da Bolsa de Valores (B3), Gilson Finkelsztain, ficou surpreso com o volume e a velocidade dos investimentos durante a crise.

A entrada desses novos investidores constitui tamb3m um desafio. Como assinalam Li *et al.* (2020), as situa4es que desencadeiam a volatilidade da alta ou baixa no pre4o das a4es s3o relacionadas ao movimento de oferta e demanda, 3 tend4ncia das empresas como lan4amento de algum produto inovador, eventos aleat3rios como desastres naturais ou morte de algum l3der pol3tico. 3 mencionado tamb3m o sentimento do mercado, em que informa4es relevantes 3 empresa tornam-se publicamente dispon3veis e segundo Pagolu, Challa e Panda (2016, p. 15), “existe uma forte correla4o entre subida e queda em pre4os de a4es de uma empresa em rela4o 3 opini3es ou emo4es p3blicas”.

Investir na bolsa de valores pode representar excelentes oportunidades financeiras, o que impulsiona pesquisadores e investidores a prever o mercado financeiro. Possui a capacidade de antecipar-se ao movimento de um mercado com tantas vari3veis pode representar vantagem em rela4o aos demais investidores e grande lucratividade (PAGOLU; CHALLA; PANDA, 2016). Estudos relacionados 3 intelig4ncia artificial t3m ganhado destaque nesse contexto. No entanto, cada mercado reflete um contexto social espec3fico, n3o somente devido 3 propriedades econ3micas de sua organiza4o, mas tamb3m em rela4o ao padr3o predominante de circula4o de informa4o. Machado (2017, p. 23) afirma que “acionistas e economistas financeiros se interessam profundamente na an3lise da rela4o entre o risco de um ativo financeiro e a seguran4a do seu retorno”. Tais agentes, sempre buscam estudos e opini3es fided3gnas que possam embasar suas decis3es sobre a venda, compra ou a renegocia4o de t3tulos de d3vidas do setor p3blico ou privado. Apesar da centralidade destes fatores, ainda n3o existe um dispositivo que esteja adaptado ao cen3rio nacional brasileiro.

No entanto, para avaliar essas vari3veis, que envolvem diferentes meios de comunica4o, aspectos psicol3gicos e subjetivos, unindo dados fundamentais das empresas e not3cias do mercado financeiro para previs3o do movimento das a4es, 3 necess3ria a utiliza4o de t3cnicas de Redes Neurais Artificiais no desenvolvimento de sistemas e no processamento de dados. Neste sentido, trabalhos recentes como os apresentados por Li *et al.* (2020), Li e Pan (2020) e Vargas *et al.* (2018) obtiveram bons resultados na resposta a estes desafios. A estrat3gia dos autores foi de utilizar t3cnicas de predi4o n3o lineares de Redes Neurais Artificiais (RNA) e de Processamento

de Linguagem Natural, também chamado de PLN e Natural Language Processing (NLP) (BRAGA; CARVALHO; LUDERMIR, 2007).

Nesse contexto, o objetivo geral deste trabalho é disponibilizar um protótipo usando Redes Neurais Artificiais para sugerir a compra ou venda de ativos negociados na Bolsa de Valores brasileira, por meio de notícias do mercado financeiro, a fim de auxiliar investidores nas suas transações no mercado de renda variável. Por conseguinte, o trabalho atende a três objetivos específicos: a) identificar os sentimentos relacionados às notícias de cada uma das empresas pesquisadas no período correspondente à 01/01/2018 e 20/05/2022 e que compuseram a base de dados de aprendizagem do protótipo; b) avaliar a eficácia das previsões do protótipo criado; c) disponibilizar um cadastro permitindo ao usuário acessar os sentimentos em relação às ações das empresas pesquisadas por meio de uma página *web*.

Elagamy, Stanier e Sharp (2018) ressaltam que o mercado financeiro representa um papel crucial no crescimento do comércio e da indústria. Por isso, encontrar formas eficientes de analisar e visualizar os dados deste setor é tarefa significativa para a economia moderna. Nesse contexto, o desenvolvimento deste estudo constitui uma oportunidade para preencher a lacuna existente neste setor e com isso, cria a possibilidade de acompanhamento das relações existentes entre investidores e o contexto financeiro e midiático brasileiro, o que justifica sua aplicação social e teórica.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo são apresentados os principais assuntos que fundamentam e constroem as propostas de modelos preditivos para auxiliar investidores em transações no mercado financeiro e os trabalhos correlatos que amparam as escolhas para a construção do protótipo deste estudo.

2.1 MERCADO FINANCEIRO E MODELOS PREDITIVOS DE APRENDIZADO DE MÁQUINA

Segundo Mueller e Massaron (2016), o acesso à informação, a complexidade e volatilidade do mercado financeiro têm levado investidores a buscar auxílio na Inteligência Artificial, explorando a capacidade dos computadores de aprender, se adaptar a novas circunstâncias, detectar padrões, criar novos comportamentos e tomar decisões a partir de um conjunto de dados. Para Santos *et al.* (2016) a busca de ferramentas que auxiliem a tomada de decisões tem utilizado modelos baseados em Redes Neurais Artificiais (RNA), que conseguem reter aprendizado e realizar procedimentos de controle, reconhecimento de padrões e classificação, contribuindo diretamente para avanços em relação ao desenvolvimento de técnicas que propiciam um melhor entendimento dos padrões presentes em dados financeiros e na construção de modelos preditivos.

As RNAs são sistemas de computação com nós interconectados que funcionam como os neurônios do cérebro humano. Usando algoritmos, elas podem reconhecer padrões escondidos e correlações em dados brutos, agrupá-los e classificá-los, e, com o tempo, aprender e melhorar continuamente esses processos. Conforme afirma Arbel (2018), devido a tais características, a utilização de RNA para a criação de modelos preditivos é adequada, pois simulam eventos cotidianos com a ajuda de algoritmos e de sistemas computacionais.

Embora aplicáveis em diversos contextos, os modelos preditivos têm alcançado espaço em um universo dinâmico e variável: a bolsa de valores. Giacomel (2016) explica que a bolsa de valores é de existência necessária a países que possuem diversas empresas de capital aberto, como um lugar em comum para a negociação das ações dessas empresas e das instituições participantes, devidamente credenciadas. Silva (2017) afirma que no Brasil a única bolsa de valores que realiza a negociação de valores mobiliários é a B3 (Brasil, Bolsa, Balcão – antiga BM&FBOVESPA), e que esse órgão é autorregulador e responsável por todos os registros de negociações de ativos do mercado brasileiro. Santos *et al.* (2016) salientam que muitos modelos preditivos são construídos utilizando modelos estatísticos, mas que os resultados têm causado frustração. Por isso, a aplicação de RNA tem sido uma alternativa aos tradicionais métodos empregados nas pesquisas científicas, já que imitam o cérebro humano ao reunir evidências empíricas e ao armazenar e permitir o uso de conhecimento experimental. Carvalho *et al.* (2018) apontam que as RNA, ao armazenar e disponibilizar informações, criam uma base de conhecimento reutilizável para uma gama de problemas complexos equivalentes, diminuindo o tempo e recursos de buscas por soluções.

2.1.1 Ferramentas para modelos preditivos

Para criar um modelo preditivo capaz de analisar os dados do mercado financeiro e auxiliar investidores nas suas transações no mercado de renda variável é preciso criar ferramentas capazes de coletar grandes quantidades de informações da *web*. Um dos *scripts* automatizados mais utilizados para isso é o “Web Scraper (Raspador Web), um programa que realiza a extração automática de dados específicos de uma página *web*” (MAZINI; SATO, 2020, p. 1-2). Depois de extrair os dados é possível transformá-los em informação estruturada,

criando um padrão e um formato necessários para a análise que se pretenda fazer. Em seguida, os dados são carregados no sistema onde serão cruzados, relacionados, tratados, analisados e visualizados.

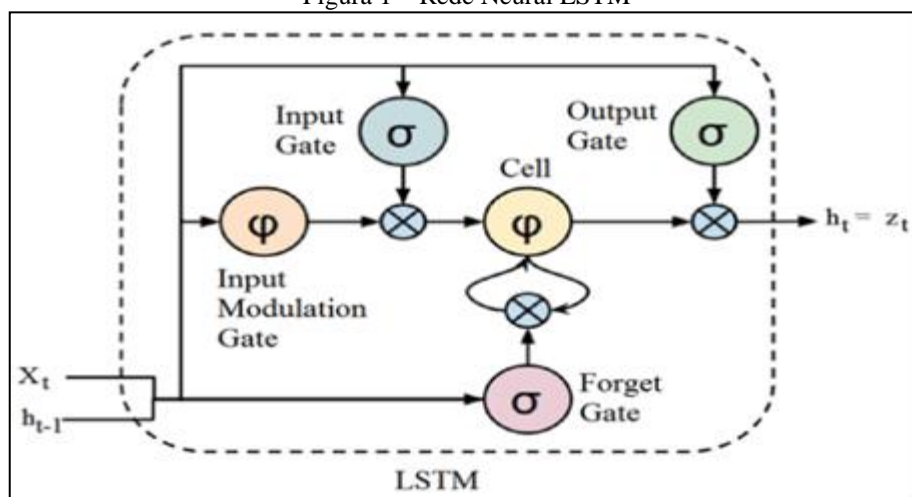
Para analisar grandes quantidades de dados complexos, podem ser utilizadas as técnicas que usam Redes Artificiais Neurais Profundas ou Deep Learning (DL). Para Hiransha *et al.* (2018), as técnicas de DL são ferramentas importantes para a análise de dados não categorizados, fazendo uso das redes neurais em processamento de imagens, reconhecimento de imagens, de áudio, reconhecimento facial, de caracteres, mineração de dados, classificação de doenças *etc.*

As Redes Neurais Artificiais Profundas são definidas por Luger (2013) como um modelo em camadas em que as novas informações são geradas ou informações existentes são adaptadas por meio de conexões entre as camadas. Assim, as camadas anteriores têm relação com as camadas posteriores, criando a mesma ideia de informações ancestrais apresentada na definição da predição estatística. São projetadas para reconhecer padrões em sequências de dados, como texto, genomas, caligrafia, palavra falada ou dados de séries numéricas que emanam de sensores, bolsas de valores e agências governamentais. Esses algoritmos consideram tempo e sequência, eles têm uma dimensão temporal. Entre as Redes Neurais Profundas destacam-se a Recurrent Neural Network (Rede Neural Recorrente – RNN), a Rede Neural Recorrente Long Short-Term Memory (LSTM) e a Convolutional Neural Network (Rede Neural Convolutacional – CNN).

As Redes Neurais Recorrentes (RNN) sofrem de memória de curto prazo. Elas têm dificuldade em transportar informações muito longas das etapas anteriores para as posteriores, pois sofrem com o problema da dissipação do gradiente. Haykin (2008, p. 24) explica que “gradientes são valores usados para atualizar os pesos das redes neurais”. Se um valor de gradiente se torna extremamente pequeno, não contribui com o aprendizado e para de aprender. Como essas camadas não aprendem, as RNN podem esquecer o que foi visto em sequências mais longas, caracterizando assim uma memória de curto prazo. Uma solução para a memória de curto prazo é a Rede Neural Recorrente LSTM, que possui mecanismos internos chamados portões que podem regular o fluxo de informações.

A arquitetura da Rede Neural Long Short Term Memory (LSTM) é uma rede neural recorrente que faz a construção de treinamento acessando conexões de aprendizagem por meio de exemplos. Interagem num método especial e contêm quatro camadas de redes neuronais. Um exemplo de como acontece esse processo pode ser observado pela representação da Rede neural tipo LSTM na Figura 1.

Figura 1 – Rede Neural LSTM



Fonte: Bufo (2000, p. 23).

O processo de transferência de dados é o mesmo que o das redes neurais recorrentes padrão, mas, a operação de propagação da informação é diferente. Quando a informação passa, a operação decide qual a informação a processar e qual a informação que deve deixar passar. A operação principal é constituída por células e portões. O estado das células funciona como um caminho para a transferência da informação. É possível considerar as células como memória e com capacidade estruturada em cadeia para repetir o módulo. Existem vários portões no processo LSTM. Quando o estado da célula transporta a informação, estes portões ajudam o novo fluxo de informação. Os portões indicarão quais os dados que são úteis para guardar e quais os dados que não são úteis, o que faz com que seja possível lançar dados relevantes por meio da cadeia de sequência para uma fácil previsão (BUFO, 2000).

Já as Redes Convolucionais, segundo Goodfellow, Bengio e Courville (2016) realizam o reconhecimento óptico de caracteres para digitalizar texto e tornar possível o processamento de linguagem natural em documentos

analógicos e manuscritos, arquivos de áudio quando estes são representados visualmente, análise de texto, bem como dados gráficos. Assim, as imagens são símbolos a serem transcritos. Para os autores, a etapa de convolução caracteriza-se pela passagem do núcleo (*kernel*) pela imagem (*input*) e o resultado desse processamento é denominado mapa de características (*output*), que permitirá o reconhecimento de padrões, inclusive de outros padrões da rede.

2.2 TRABALHOS CORRELATOS

Muitos autores utilizaram diferentes modelos preditivos na elaboração de diferentes estudos, a partir de objetivos, ferramentas de desenvolvimento e funcionalidades também diferenciadas. Mas, seus principais resultados podem orientar a tomada de decisão, indicando as melhores escolhas na construção de modelos preditivos e orientar a formatação para a coleta dos dados e estratégias de avaliação da ferramenta. Este estudo apresenta alguns trabalhos correlatos que contribuíram nesta pesquisa para definir as estratégias da construção do modelo preditivo para a ferramenta a ser criada.

São três os trabalhos correlatos com características semelhantes aos principais objetivos do estudo proposto. O primeiro trabalho correlato é o estudo realizado por Vargas *et al.* (2018), que utiliza técnicas de aprendizado profundo unindo Rede Neural Recorrente e Rede Neural Convolucional. O segundo, realizado por Li *et al.* (2020), utilizou Rede Neural Multimodal orientada a eventos para previsão do valor das ações da bolsa de valores. O terceiro, uma pesquisa realizada por Li e Pan (2020), propõe um método para usar duas Redes Neurais Recorrentes seguidas de uma Rede Neural Totalmente Conectada (Fully Connected Neural Network - FCNN) para prever o movimento das ações. As experiências de Vargas *et al.* (2018) estão descritas no Quadro 1.

Quadro 1 – Deep Learning for Stock Market Prediction Using Technical Indicators and Financial News Articles

| | |
|--------------------------------|--|
| Referência | Vargas <i>et al.</i> (2018) |
| Objetivos | Prever os movimentos direcionais diários do preço das ações da Chevron Corporation (CVX) utilizando títulos de notícias financeiras e indicadores técnicos como entrada. |
| Principais funcionalidades | Os dois conjuntos de indicadores técnicos, são: Conjunto 1: Estocástico %K, Estocástico %D, Momentum, Taxa de Variação, Williams %R, Acumulação Distribuição (A/D) Oscillator and Disparity. O Conjunto 2: Média Móvel Exponencial, Média Móvel Convergente e Divergente, Relative Strength Index (RSI), On Balance Volume (OBV) e Bandas de Bollinger. Uma comparação é feita entre os quatro modelos utilizados que recebem um dos conjuntos de indicadores técnicos em execuções diferentes. O modelo RCNN visa obter vantagens de ambos os modelos: CNN e Rede Neural Recorrente (Recurrent Neural Network - RNN). O CNN tem uma capacidade superior de extrair informações semânticas de textos em comparação com RNN e RNN é melhor para capturar as informações de contexto e na modelagem de características temporais complexas. Finalmente, quando os modelos criam as previsões dos movimentos direcionais do preço das ações, um agente de negociação decide quando comprar ou vender uma ação. O banco de dados usado neste trabalho consiste em 106.494 artigos de notícias do site da <i>Reuters</i> , correspondentes ao período de 20 de outubro de 2006 a 21 de novembro de 2013. O tema principal de todos esses artigos são notícias do mercado financeiro. Cada notícia consiste em seu título, conteúdo e data de publicação. A data de publicação é empregada para o alinhamento das notícias com uma série temporal financeira correspondente. A acurácia do modelo capaz de prever os preços das ações conseguiu atingir 56.84% nos dados de teste. |
| Ferramentas de desenvolvimento | O primeiro é o modelo de Rede Neural Long Short-Term Memory (LSTM) apenas com o conjunto 1 de indicadores, I-RNN; o segundo é o modelo Rede Neural LSTM, apenas com o conjunto 2 de indicadores, I-RNN-2; o terceiro é o modelo híbrido composto por Rede Neural Convolucional (Convolutional Neural Network - CNN) e LSTM com o conjunto 1 de indicadores, SI-RCNN; e, finalmente, o quarto é o modelo híbrido composto por CNN e LSTM com o conjunto 2 de indicadores, SI-RCNN-2. |
| Resultados e conclusões | O modelo híbrido proposto apresentou os melhores resultados utilizando como entrada um conjunto de indicadores técnicos extraídos das empresas relacionadas e títulos de notícias financeiras publicados na véspera do dia da previsão. Alcançou acurácia de 56.84% ao prever o preço das ações. Os autores sugerem estratégias para eliminar pequenas variações e focar somente nas variações significativas de preços. |

Fonte: elaborado pelo autor.

O estudo de Vargas *et al.* (2018) aproxima-se deste trabalho por usar títulos de notícias financeiras e indicadores técnicos como entrada. O trabalho de Li *et al.* (2020) está descrito no Quadro 2.

Quadro 2 – A Multimodal Event-driven LSTM Model for Stock Prediction Using Online News

| | |
|--------------------------------|--|
| Referência | Li <i>et al.</i> (2020) |
| Objetivos | Realizar previsões dos preços de ações levando em consideração que as informações sobre os fundamentos (volume de negócios, preços de abertura e volumes de negociação) e notícias das empresas afetam o movimento das ações caracterizando assim um problema multimodal. |
| Principais funcionalidades | Para isso foi utilizado Máquina de Vetor de Suporte (Support Vector Machine - SVM), Árvore de Decisão (Decision Tree - DT), Rede Neural <i>Backpropagation</i> (BP), Rede Neural LSTM e o modelo TeSIA. Como métricas, foram selecionadas a Directional Accuracy (DA), que é uma métrica para tarefas de classificação de ações e a Matthews Correlation Coefficient (MCC), que leva em consideração verdadeiros e falsos positivos e negativos e é geralmente considerado uma medida equilibrada que pode ser usada mesmo se as classes forem de tamanhos muito diferentes. DA tende a apresentar viés quando as classes não são balanceadas, ou seja, se apresentarem tamanhos muito diferentes. No experimento foram utilizados dados de ações da China Securities Index (CSI 100), fornecidos por Li <i>et al.</i> (2014). Adicionalmente, o rastreador (web crawler) de Li <i>et al.</i> (2020), buscou 45.021 notícias das 100 companhias listadas na CSI 100, entre 01/01/2015 e 31/12/2015, do site www.eastmoney.com , que é um dos portais de informações financeiras da China. |
| Ferramentas de desenvolvimento | Rede Neural Long Short-Term Memory (LSTM) orientado a eventos para atender os diferentes tempos de amostragem. Isso é, fundindo os dados dos fundamentos da empresa que são em intervalos iguais e as notícias, que são em intervalos não iguais. |
| Resultados e conclusões | Em termos das métricas DA, MCC, SVM e os modelos DT alcançaram o melhor desempenho para o Target 1, entre os três targets considerados. O modelo BP alcançou seu melhor desempenho para o Target 2, enquanto que LSTM, TeSIA e a abordagem proposta por Li <i>et al.</i> alcançou seu melhor desempenho para o Target 3 (preço de entrada – preço de saída). |

Fonte: elaborado pelo autor.

O estudo de Li *et al.* (2020) relaciona-se com o protótipo proposto neste trabalho por utilizar a rede neural LSTM e fundir os dados coletados de ações e notícias. O trabalho desenvolvido por Li e Pan (2020) está descrito no Quadro 3.

Quadro 3 – A Novel Ensemble Deep Learning Model for Stock Prediction Based on Stock Prices and News

| | |
|--------------------------------|--|
| Referência | Li e Pan (2020) |
| Objetivos | Usar a análise de sentimentos para extrair informações úteis de múltiplas fontes de dados e um modelo de aprendizado profundo de conjunto de mistura para prever o movimento futuro das ações. |
| Principais funcionalidades | A métrica utilizada foi o índice S&P 500 |
| Ferramentas de desenvolvimento | Modelo Combinado. O primeiro nível contém duas Redes Neurais Recorrentes (RNN), uma Rede Neural de Memória de Longo Prazo (LSTM) e uma unidade de Rede Neural Recorrente Bloqueada (Gated Recurrent Unit - GRU). O segundo nível conta com uma Rede Neural Totalmente Conectada (Fully Connected Neural Network - FCNN). Os modelos RNNs, LSTM e GRU podem capturar efetivamente os eventos de série temporal nos dados de entrada e a Rede Neural Totalmente Conectada é usada para reunir vários resultados de previsões individuais para melhorar ainda mais a precisão da previsão. Os dados usados por Li e Pan (2020) foram retirados do estudo de Li <i>et al.</i> (2019) e foram divididos em: dados de notícias, obtidos de CNBC.com , Reuters.com , WSJ.com , Fortune.com , com datas no período de dezembro de 2017 até o fim de junho de 2018, e, dados de ações que são do índice S&P Index 500, no mesmo intervalo de datas dos dados de notícias. O S&P 500 é um índice do mercado de ações que mede o desempenho das ações das 500 maiores empresas de capital aberto dos Estados Unidos. |
| Resultados e conclusões | Os resultados apontados pelo modelo estudado por Li e Pan (2020) reduzem o erro quadrático médio (MSE) em 57,55%, aumentando a taxa de precisão em 40%, Recall em 50%, pontuação F1-score em 44,78%, direção do movimento em 33% e precisão (MDA) em 34%. Validando assim, o modelo aplicado, principalmente em termos de compensação entre o retorno e o risco. |

Fonte: elaborado pelo autor.

Li e Pan (2020) utilizaram ações do mercado ocidental e redes neurais artificiais em seu protótipo, o que aproxima os dados dos autores deste estudo. De forma geral, os trabalhos auxiliam a compreensão do processo das RNAs em relação ao recolhimento de dados das ações da bolsa de valores e à avaliação das métricas dos modelos de aprendizado de máquina.

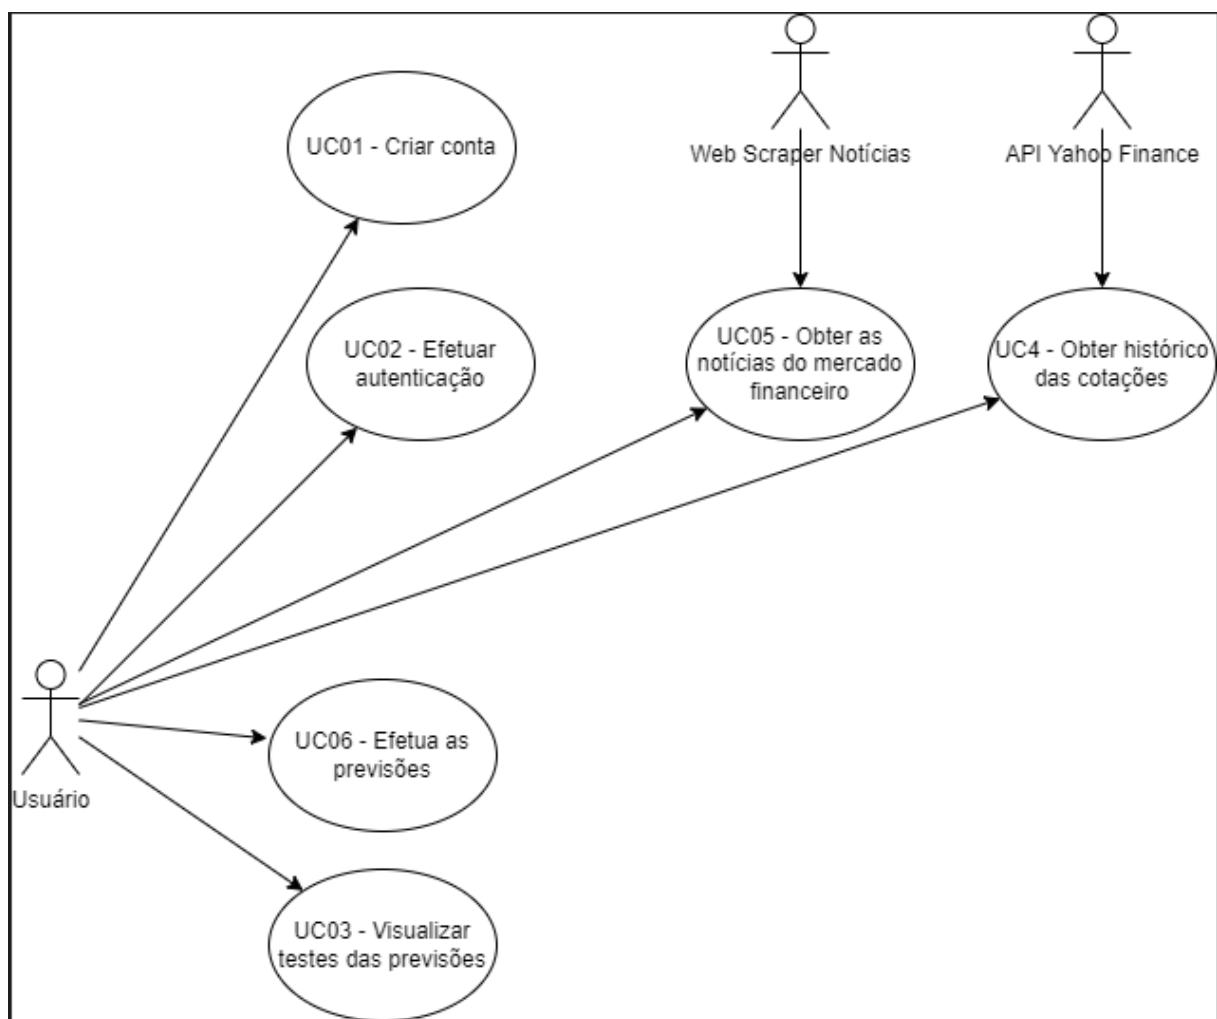
3 DESCRIÇÃO DO PROTÓTIPO

Este capítulo apresenta as especificações para o protótipo proposto neste trabalho, apontando os requisitos principais (funcionais e não funcionais), o modelo e sua estrutura.

3.1 ESPECIFICAÇÕES

Para que o usuário consiga visualizar as previsões, faz-se necessário o acesso a uma plataforma Web que realize as previsões por meio de um modelo de Rede Neural Artificial, atualize as cotações atuais de cada ativo, e apresente os resultados. Sendo assim, o protótipo contém as especificações cujas funcionalidades são apresentadas na Figura 2.

Figura 2 – Diagrama de Caso de Uso



Fonte: elaborado pelo autor.

O usuário pode criar uma conta no sistema (UC01), realizar o *login* (UC02) e visualizar os resultados dos testes de previsões (UC03). Para a exibição das previsões é necessário obter os resultados (UC06), fornecidas pelo ator Rede Neural Artificial. Esse ator é alimentado com dados históricos das cotações das ações (UC05) e com dados de notícias do mercado financeiro (UC04), gerando os resultados das previsões.

O acesso a uma plataforma Web alicerçada pelos Requisitos Funcionais (RF) e Requisitos Não Funcionais (RNF) possibilita essa estruturação ao protótipo. Sendo assim, o protótipo contém os RF apresentados pelo Quadro 4, que também aponta seus Casos de Uso (UC).

Quadro 4 – Requisitos funcionais (RF) e matriz de rastreabilidade

| Requisitos Funcionais | Caso de Uso |
|---|-------------|
| RF01: Obter as cotações históricas das ações | UC04 |
| RF02: Obter o histórico das notícias do mercado financeiro | UC05 |
| RF03: Possuir um módulo para acompanhamento do resultado dos testes | UC03, UC06 |
| RF04: Permitir a criação de uma conta de usuário no sistema | UC01 |
| RF05: Permitir a autenticação do usuário no sistema | UC02 |

Fonte: elaborado pelo autor.

Considerando os RNF, o Quadro 5 descreve as funcionalidades do protótipo.

Quadro 5 – Requisitos não funcionais (RNF)

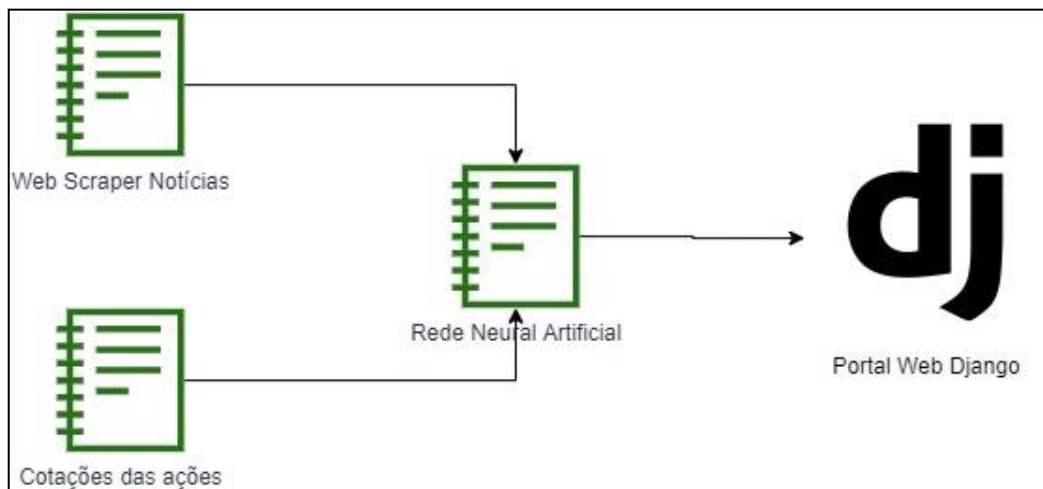
| Requisitos Não funcionais |
|---|
| RNF01: Utilizar um modelo preditivo baseado em técnicas de Redes Neurais Artificiais |
| RNF02: Ser implementado na linguagem de programação Python usando o <i>framework</i> Django para a aplicação <i>web</i> |
| RNF03: Utilizar o ambiente de desenvolvimento <i>PyCharm</i> |
| RNF04: Utilizar o ambiente de desenvolvimento <i>Jupyter Notebook</i> |
| RNF05: Utilizar o <i>framework</i> Pandas para análise de dados |

Fonte: elaborado pelo autor.

3.2 IMPLEMENTAÇÃO DO PROTÓTIPO

Para criar o protótipo, este projeto trabalhou com três empresas que fazem investimentos na bolsa de valores brasileira como fonte de dados: Banco do Brasil (BBAS3); PetroRIO (PRIO3) e; Vale do Rio Doce (VALE3), no período entre 01/01/2018 e 20/05/2022. A arquitetura do protótipo é exibida na Figura 3.

Figura 3 – Arquitetura do protótipo



Fonte: elaborado pelo autor.

O *Web Scraper* foi implementado em *Python* usando a biblioteca *Beautiful Soup* para realizar a varredura de notícias (extraídas do site *br.investing.com*) e obtenção do texto nas *tags* HTML. Ao percorrer cada notícia (linha 23), consegue-se obter o título, a data da publicação, o *ticker* da ação e o canal da notícia. Essas requisições são controladas pelo método *get_news* por meio do parâmetro *conter_limit* conforme o Quadro 6, que retorna uma lista (linha 40) que será convertido na estrutura de dados *Dataframe* da biblioteca *Pandas*.

Quadro 6 – Varredura de notícias

```

1 def get_data(url):
2     try:
3         r = Request(url, headers={"User-Agent": "Mozilla/5.0"})
4         c = urlopen(r).read()
5         soup = BeautifulSoup(c, "html.parser")
6         return soup
7     except:
8         pass
9
10 def get_url(prefix, page=''):
11     return f'{prefix}/{page}'
12
13 def get_news(tk, prefix_url, counter_limit):
14     list_news = []
15     counter = 2
16     ticker = tk
17
18     while True:
19         soup = get_data(get_url(prefix_url, counter))
20
21         result = soup.find('span', class_='blueRightSideArrowPaginationIcon')
22
23         for link in soup.findAll('article'):
24             # getting the news
25             article = link.find('a', class_='title')
26
27             chanel = link.find("span", {"class": "articleDetails"})
28
29             if chanel is not None:
30                 chanel = chanel.span.text
31
32             # getting news release time
33             release_time = link.find_all("span", {"class": "date"})
34
35             if len(release_time) > 0 and article is not None:
36                 curr_article = article.get('title')
37                 curr_time = release_time[0].string
38                 curr_time = curr_time[3:]
39
40                 list_news.append([curr_article,
41                                 ticker,
42                                 chanel,
43                                 datetime.datetime.now(tz=timezone.utc),
44                                 curr_time])
45

```

Fonte: elaborado pelo autor.

A API Yahoo Finance, dentro do ambiente de desenvolvimento Jupyter Notebook, buscou as cotações das ações e permite selecionar o período e a empresa desejada utilizando um `DataReader` (linhas 1, 6, 12). Esse *download* é exibido no Quadro 7, que resulta numa estrutura de dados chamada `Dataframe` da biblioteca Pandas.

Quadro 7 – Busca por cotações

```

1 ibov_prio3 = web.DataReader('PRI03.SA', data_source='yahoo', start='2016-1-1', session=sesh)[['High', 'Low', 'Open', 'Close']]
2 ibov_prio3['cod_negociacao'] = 'PRI03'
3 ibov_prio3.reset_index(inplace=True)
4 ibov_prio3.sort_values('Date', ascending=True, inplace=True)
5
6 ibov_vale = web.DataReader('VALE3.SA', data_source='yahoo', start='2016-1-1', session=sesh)[['High', 'Low', 'Open', 'Close']]
7 ibov_vale['cod_negociacao'] = 'VALE3'
8 ibov_vale.reset_index(inplace=True)
9 ibov_vale.sort_values('Date', ascending=True, inplace=True)
10
11
12 ibov_bb = web.DataReader('BBAS3.SA', data_source='yahoo', start='2016-1-1', session=sesh)[['High', 'Low', 'Open', 'Close']]
13 ibov_bb['cod_negociacao'] = 'BBAS3'
14 ibov_bb.reset_index(inplace=True)
15 ibov_bb.sort_values('Date', ascending=True, inplace=True)

```

Fonte: elaborado pelo autor.

3.3 IDENTIFICAÇÃO DOS SENTIMENTOS

As notícias do mercado corporativo dessas três empresas (BBAS3; PRIO3 e VALE3) foram unidas ao preço da ação na abertura do dia no pregão da bolsa de valores, ao preço da ação no fechamento do dia e ao preço das ações no dia seguinte. Caso o preço da ação da empresa subiu atribuiu-se um sentimento positivo às notícias, se o preço caiu, o sentimento foi considerado negativo em relação à notícia. Para estruturar essa parte técnica, este trabalho usou como base a estrutura de Li *et al.* (2020). A análise das cotações foi realizada por meio de um algoritmo (de classificação binária) que correspondesse à reação do mercado, usando 0 (zero) para a reação negativa e 1 (um) para a reação positiva. Observa-se a seguir, no Quadro 8, como a organização foi estruturada por Li *et al.* (2020).

Quadro 8 – Abertura e fechamento do preço da ação e influência da notícia

| Tracks | Targets formula |
|----------|---|
| Target 1 | $price_{i+k}^{open} - price_{i+k-1}^{open}$ |
| Target 2 | $price_{i+k}^{close} - price_{i+k-1}^{close}$ |
| Target 3 | $price_{i+k}^{close} - price_{i+k-1}^{open}$ |

Fonte: Li *et al.* (2020, p. 10).

Nesse contexto, k representa o número de dias que a notícia influencia a ação à frente, considerando o período de abertura e fechamento da notícia e o preço da ação a partir da influência positiva ou negativa obtida da notícia. Dessa forma, a previsão consegue trabalhar com variáveis possivelmente correlacionadas e reorganizar os dados de aprendizagem conforme a variação acontece, estabelecendo inferências capazes de orientar o treinamento de uma RNA.

A junção desses contextos está representada pelo Quadro 9. Observa-se que a segunda coluna apresenta uma notícia, seguida do nome da empresa pesquisada, da data do pregão na bolsa de valores, do preço da ação da empresa na abertura do pregão do dia, do preço da ação no fechamento do dia e do sentimento positivo (1) ou negativo (0) em relação à notícia. Bem como apresenta os sentimentos da análise desse contexto. Essa base compõe a entrada de dados utilizada na Rede Neural Artificial.

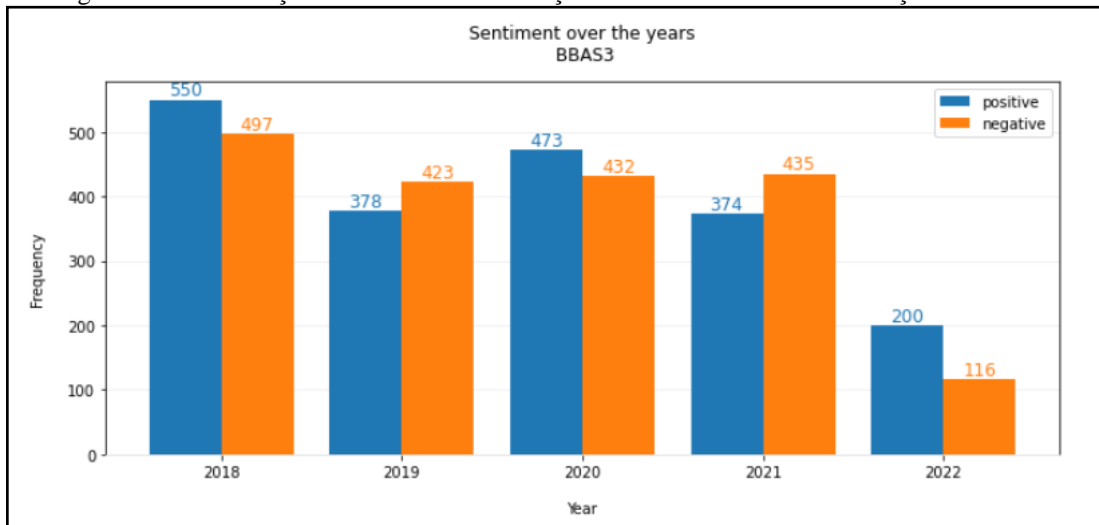
Quadro 9 – Junção das cotações, notícias e sentimentos

| | article | cod_negociacao | data_pregao | preco_abertura | preco_ultimo_negocio | sentiment |
|---|---|----------------|-------------|----------------|----------------------|-----------|
| 3 | China anima Bolsa, mas vencimento de opções so... | VALE3 | 2022-05-20 | 82.01 | 81.26 | 1 |
| 4 | Descolado do exterior, Ibovespa sobe 0,71%, a ... | VALE3 | 2022-05-20 | 82.01 | 81.26 | 1 |
| 5 | Ibovespa avança com siderurgia e mineração, me... | VALE3 | 2022-05-19 | 77.78 | 79.85 | 1 |
| 6 | Ibovespa avança com siderurgia e mineração, me... | VALE3 | 2022-05-19 | 77.78 | 79.85 | 1 |
| 7 | Ibovespa tem leve alta com Vale e siderúrgicas... | VALE3 | 2022-05-19 | 77.78 | 79.85 | 1 |

Fonte: elaborado pelo autor.

Os sentimentos relacionados às notícias de cada uma das empresas pesquisadas no período correspondente à 01/01/2018 e 20/05/2022 compuseram a base de dados de aprendizagem do protótipo. O levantamento de dados possibilitou elaborar um gráfico de sentimentos positivos e negativos em relação aos dados que alimentaram a base, correspondente a cada empresa. Os sentimentos gerados em relação ao Banco do Brasil estão expostos na Figura 4.

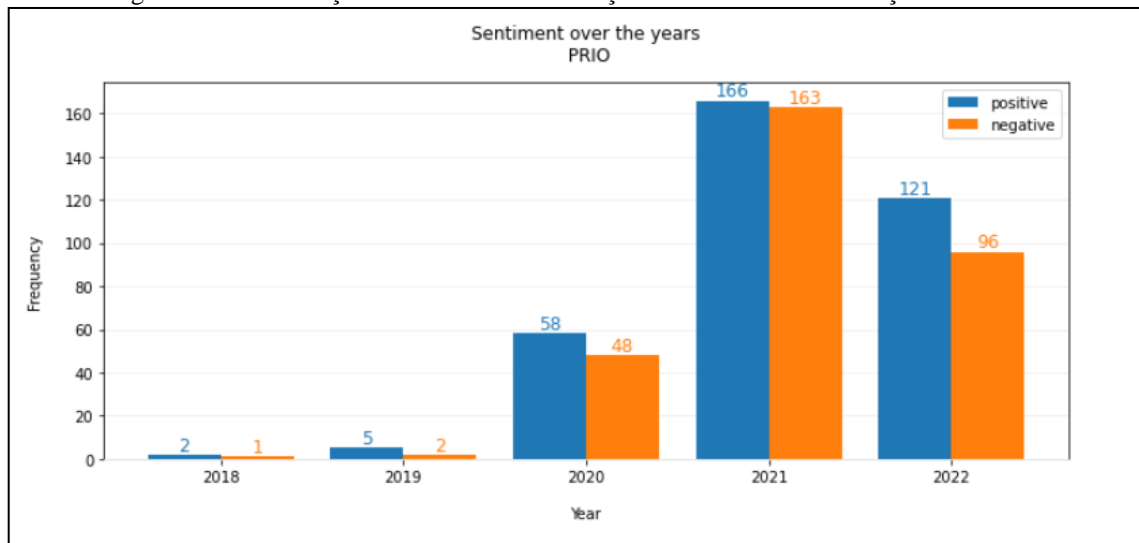
Figura 4 – Classificação dos sentimentos das ações do Banco do Brasil em relação às notícias



Fonte: elaborado pelo autor.

Observa-se uma oscilação nos sentimentos positivos de um ano para outro. Em 2018, 2020 e 2022 os sentimentos positivos superaram os negativos. Em 2019 e 2021 os sentimentos negativos se sobressaíram. No entanto, não há uma diferença significativa entre os sentimentos (positivos e negativos) quando se considera cada ano isoladamente. A diferença entre os sentimentos de 2018, por exemplo, teve 550 sentimentos positivos e 497 negativos, ou seja, uma diferença de somente 53 sentimentos. A PetroRio obteve um gráfico de sentimentos conforme mostra a Figura 5.

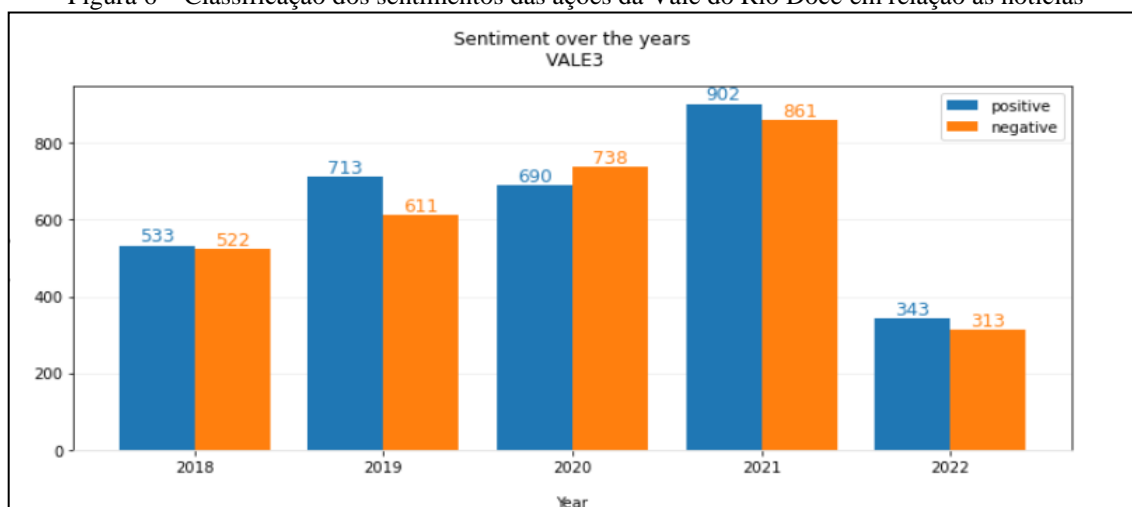
Figura 5 – Classificação dos sentimentos das ações da Petro RIO em relação às notícias



Fonte: elaborado pelo autor.

Apesar do resultado de sentimentos positivos destacar-se em todos os anos, apontando um impacto positivo em relação à reação do mercado às notícias da PetroRio, observa-se um movimento muito baixo de ocorrência de notícias nos anos de 2018 e 2019. Considerando a movimentação anualmente, também não há uma variação considerável entre os sentimentos positivos e negativos. A Vale do Rio Doce, apresenta resultados conforme expõe a Figura 6.

Figura 6 – Classificação dos sentimentos das ações da Vale do Rio Doce em relação às notícias



Fonte: elaborado pelo autor.

Os sentimentos relacionados à Vale3 oscilaram anualmente, mas, somente em 2020 apresentaram sentimentos negativos maiores. Ademais, a variação anual também foi relativamente pequena entre os sentimentos positivos e negativos. Esses contextos implicam em reconhecer que a previsão dos dados, considerando as empresas pesquisadas não é linear. A variação apresentada pelos gráficos demonstra uma volatilidade desse mercado, sobretudo ao considerar o período de estudo (2018-2022) como um contexto informacional para formar uma base de dados de aprendizagem. De forma abrangente, a Tabela 1 aponta o total de sentimentos positivos e negativos em relação às notícias e o total de notícias de cada empresa.

Tabela 1 – Sentimentos positivos e negativos em relação às notícias das empresas pesquisadas

| Empresas | Notícias Positivas | Notícias Negativas | Total |
|--------------|--------------------|--------------------|---------------|
| BAS3 | 1.975 | 1.903 | 3.878 |
| PRIO | 352 | 310 | 662 |
| VALE3 | 3.181 | 3.045 | 6.226 |
| TOTAL | 5.508 | 5.258 | 10.776 |

Fonte: elaborado pelo autor.

Obteve-se um total de 10.766 notícias entre 01/01/2018 e 20/05/2022. É preciso considerar ainda que os gráficos possuem dados referentes ao enfrentamento da pandemia da COVID-19, que se estendeu de 2020 a 2021 (de maneira mais intensa, mas que ainda faz parte do contexto social e organizacional brasileiro).

3.4 ARQUITETURA DA REDE NEURAL LSTM

A rede neural LSTM foi criada utilizando a biblioteca de código-aberto Keras (MAZINI; SATO, 2020), que está na plataforma de Aprendizado de Máquina *Tensor Flow*. Para a sua utilização, é necessário converter a entrada da base de dados textual para numérica (linha 5, Quadro 10). Para isso é usada então uma instância de classe `Tokenizer` com o parâmetro `num_words` igual a 4000 o que significa que somente serão consideradas no cálculo as 4000 palavras mais frequentes no dicionário. O parâmetro `split` separa as palavras através do caracter espaço em branco. Define-se, então, a base de dados textual a ser usada no método `fit_on_texts` na linha 6. Seleciona-se o método `text_to_sequences` para converter cada texto numa sequência de inteiros conforme indicado na linha 8. Finalmente para que os vetores com as notícias tenham o mesmo tamanho, usa-se o método `pad_to_sequences` atribuindo o valor `post` para o parâmetro `padding` para que os finais dos vetores tenham valor zero.

Ao separar a base de dados em 80% para treino e 20% para teste (linha 17), cria-se então o modelo da rede neural artificial do tipo sequencial (linha 23) que age como uma pilha linear de camadas. A primeira camada é do tipo `Embedding` (linha 9, Quadro 10) para converter cada palavra num vetor de tamanho fixo. Essa camada recebe 3 argumentos onde o primeiro é o tamanho do vocabulário, o segundo é o número de dimensões que desejam-se incorporar e o terceiro é o comprimento máximo do documento. Foi decidido utilizar a estrutura LSTM com função de ativação `relu` (linha 26). A camada última é do tipo `Dense` (linha 28) onde todos os neurônios conectam-se entre si com a função de ativação `sigmoid`. Os testes trouxeram bons resultados ao utilizar duas camadas de `Dropout` (linhas 25 e 27) que é uma técnica para redução de sobreajuste. Quando foi utilizada a técnica `Gridsearch`, que é uma técnica para obter melhores parâmetros para o modelo, o otimizador `adam` trouxe melhores resultados que o `rmsprop` (linha 31). A rede neural do protótipo está apresentada pelo Quadro 10.

Quadro 10 – Rede neural artificial

```

1 y=df.sentiment
2 |
3 max_words=4000
4
5 tokenizer=Tokenizer(num_words=max_words, split=" ")
6 tokenizer.fit_on_texts(df.clean_article.values)
7
8 X=tokenizer.texts_to_sequences(df.clean_article.values)
9 #cria vetores de tamanho fixo para as noticias
10 X=pad_sequences(X, padding='post')
11
12
13 X_final=np.array(X)
14 y_final=np.array(y)
15
16 #Separar em treino 80% e teste 20%
17 X_train, X_test, y_train, y_test=train_test_split(X_final, y_final, test_size=0.2, random_state=0)
18
19 embedding_vector_features = 40
20 voc_size = 4000
21
22 # Criação do modelo sequencial
23 model = Sequential()
24 model.add(Embedding(voc_size, embedding_vector_features, input_length=X.shape[1]))
25 model.add(Dropout(0.2))
26 model.add(LSTM(100, activation='relu'))
27 model.add(Dropout(0.2))
28 model.add(Dense(1, activation='sigmoid'))
29
30 # Compilação do modelo
31 model.compile(loss='binary_crossentropy',optimizer='adam',metrics=['accuracy'])
32 # Treinamento do modelo
33 model.fit(X_train, y_train, epochs=100, batch_size=20)

```

Fonte: elaborado pelo autor.

4 RESULTADOS

Os resultados deste estudo atendem aos objetivos específicos, apontando de que maneira contribuem para compreender o protótipo e os processos que o compõem. Na seção 4.1 até a seção 4.2 são apresentados cada um dos objetivos e seus respectivos resultados.

4.1 EFICIÊNCIA DAS PREVISÕES DO PROTÓTIPO

Para avaliar a assertividade das previsões é preciso utilizar uma ferramenta avaliativa que seja estatisticamente compatível com a amostragem. A Matriz Confusão, segundo Centeno (2004), permite a visualização do desempenho do algoritmo de classificação criado, de forma simples, eficiente e detalhada. Em relação à avaliação do protótipo criado, as previsões estão detalhadas pela Matriz Confusão, considerando que: a Matriz Confusão aponta a *acurácia* por meio dos verdadeiros positivos e verdadeiros negativos, ou seja, a soma das previsões corretas que a ferramenta alcançou. Aponta também o *recall*, definindo a eficiência (ou sensibilidade) da ferramenta em prever os resultados positivos; assim como a *precision*, apontando quantos acertos as previsões dos positivos realmente alcançaram. Mas, é o *f1-score* que mostra o balanço entre a precisão e o *recall* do modelo testado, ou seja, a qualidade geral do modelo. O *support* comporta o total de casos analisados na testagem. Nesse contexto, observa-se os resultados a partir do relatório de classificação que o protótipo alcançou na Matriz Confusão, considerando as três empresas pesquisadas, como se observa na Tabela 2, que apresenta os dados detalhadamente:

Tabela 2 – Relatório de Classificação do Protótipo na Matriz Confusão

| Empresa | Resultados | <i>Precision</i> | <i>Recall</i> | <i>F1-Score</i> | <i>Support</i> |
|-----------------|---------------------|------------------|---------------|-----------------|----------------|
| Banco do Brasil | 0 = Negativo | 0.51 | 0.50 | 0.51 | 385 |
| | 1 = Positivo | 0.52 | 0.53 | 0.53 | 391 |
| | Acurácia | | | 0.52 | 776 |
| | <i>Macro avg</i> | 0.52 | 0.52 | 0.52 | 776 |
| | <i>Weighted avg</i> | 0.52 | 0.52 | 0.52 | 776 |
| PetroRio | 0 = Negativo | 0.33 | 0.29 | 0.30 | 56 |
| | 1 = Positivo | 0.52 | 0.57 | 0.35 | 77 |
| | Acurácia | | | 0.45 | 133 |

| | | | | | |
|------------------|---------------------|------|------|-------------|-------|
| | <i>Macro avg</i> | 0.43 | 0.43 | 0.43 | 133 |
| | <i>Weighted avg</i> | 0.44 | 0.45 | 0.44 | 133 |
| Vale do Rio Doce | 0 = Negativo | 0.52 | 0.53 | 0.52 | 624 |
| | 1 = Positivo | 0.52 | 0.51 | 0.52 | 622 |
| | Acurácia | | | 0.52 | 1.246 |
| | <i>Macro avg</i> | 0.52 | 0.52 | 0.52 | 1.246 |
| | <i>Weighted avg</i> | 0.52 | 0.52 | 0.52 | 1.246 |

Fonte: elaborado pelo autor.

Observa-se entre os dados acima um destaque das variáveis positivas no *recall* da PetroRio (0.57) e do Banco do Brasil (0.53), assim como destacou-se o valor das previsões positivas para a variável *precision*, alcançando o mesmo valor (0.52) em todas as empresas. De forma geral, no entanto, a acurácia que mediu a efetividade do *F1-Score*, ou seja, a média de precisão do protótipo testado não ultrapassou 52% para BBAS3 e VALE3, enquanto que a PetroRio alcançou 0.45. Esse resultado menos eficiente pode estar atrelado ao baixo número de notícias da empresa no período analisado, o que sugere um foco investigativo futuro. Ainda assim, os resultados apontam para uma baixa efetividade da ferramenta. Esse resultado pode ser aprimorado buscando aumentar a precisão e a acurácia da ferramenta ou criando critérios de otimização, já que, quanto maior for o *f1-score* da ferramenta, mais assertiva ela será em suas previsões e maior confiabilidade e segurança proporcionará ao investidor do mercado financeiro. No entanto, deve-se considerar que a inserção de neurônios e camadas à rede neural LSTM aumentam o tempo de processamento dos dados, tornando-os lentos e interferindo na agilidade e no tempo de previsão dos resultados. Dessa maneira, Vargas *et al.* (2018) sugerem estruturar o protótipo para não perder essas características, que também compõem aspectos de qualidade e eficácia. Recomendam ainda, a inclusão de algum tipo de estratégia de negociação capaz de eliminar pequenas variações e focar somente nas variações significativas de preços das ações.

4.2 CADASTRO E ACESSO DO USUÁRIO AO PROJETO

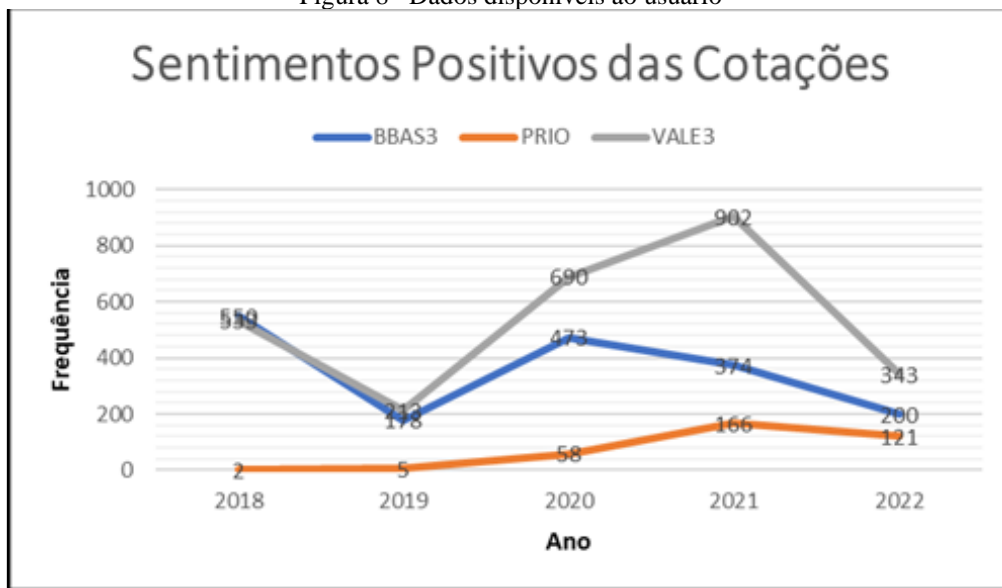
Para disponibilizar um cadastro permitindo ao usuário acessar os sentimentos em relação às ações das empresas pesquisadas por meio de uma página *web*, foi necessário primeiramente elaborar um portal de busca na *web*. Isso permite que o usuário acesse o estudo no *site* da FURB. Ao preencher um cadastro, com seu *e-mail* de contato e criar uma senha de acesso o usuário faz o *login* e obtém acesso. A tela que apresentar-se-á ao usuário é idêntica à Figura 7.

Figura 7 – Tela para acesso do usuário ao projeto

Fonte: elaborado pelo autor.

Essa página *web* disponibiliza ao usuário os sentimentos em relação às ações das empresas pesquisadas. Os resultados do projeto e sugestões de compra ou venda das ações dessas empresas alcançaria aspectos aproximados aos mostrados pela Figura 8, considerando que esses resultados seriam variáveis, já que apontam sentimentos e sugestões diferentes em relação às datas consultadas e às empresas consultadas. A Figura 8 aponta o número de sentimentos positivos obtidos pelas empresas ao total de cada ano analisado (deve-se considerar que em 2022 as previsões estão baseadas no período correspondente a 01/01/2022 e 20/05/2022).

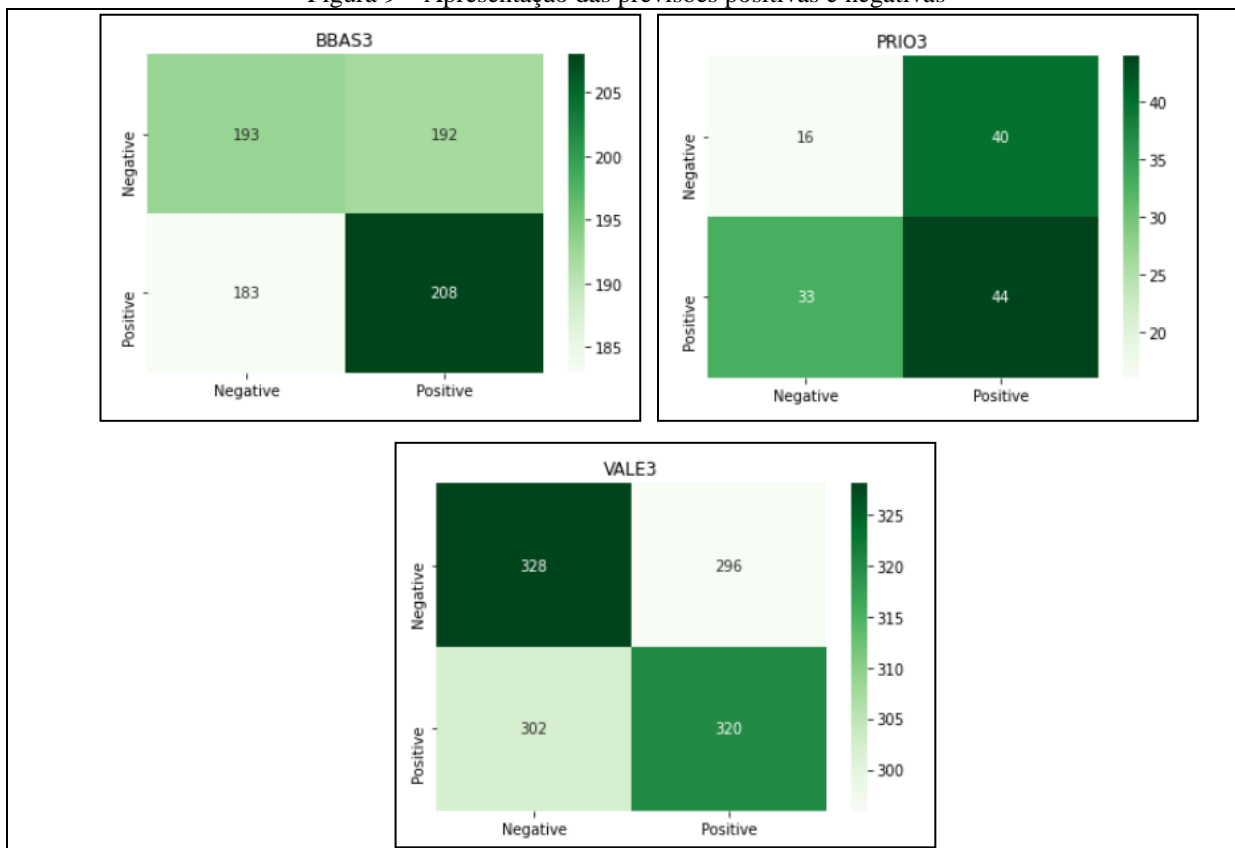
Figura 8– Dados disponíveis ao usuário



Fonte: elaborado pelo autor.

Este estudo também oferece a possibilidade de o usuário fazer consultas em períodos determinados, cotações diárias, ou acessar os sentimentos de todos os aspectos analisados pela Matriz Confusão, obtendo diferentes formas de observar as avaliações resultantes da análise destas empresas nos períodos citados. Uma dessas possibilidades pode ser observada pela Figura 9.

Figura 9 – Apresentação das previsões positivas e negativas



Fonte: elaborado pelo autor.

A Figura aponta os sentimentos positivos e negativos analisados pela Matriz Confusão de cada uma das empresas pesquisadas no período entre 01/01/2018 e 20/05/2022. Cada usuário pode estabelecer como prefere acessar os dados que estão disponíveis.

5 CONCLUSÕES

Este estudo teve por objetivo identificar os sentimentos relacionados às notícias das empresas BBAS3, PRIO e VALE3, no período correspondente à 01/01/2018 e 20/05/2022, por meio da criação de um modelo de Rede Neural Artificial. O trabalho buscou encontrar formas eficientes de analisar e antecipar-se ao movimento do mercado financeiro, considerando as variáveis da bolsa de valores, a partir das notícias do mercado e a lucratividade que a antecipação dessas previsões pode trazer para investidores e empresas. Dessa forma, o estudo foi estruturado para o atendimento dos objetivos específicos, explanados a seguir.

Ao analisar os sentimentos que cada empresa obteve considerando as notícias do mercado financeiro e seu impacto sobre as cotações na bolsa de valores no período correspondente à 01/01/2018 e 20/05/2022, extraiu-se os dados que compuseram a base de dados de aprendizagem do protótipo deste estudo. Obteve-se um total de 10.766 notícias entre os anos de 2018 e 2022, sendo que, 3.878 notícias são referentes às ações do BBAS3, 662 provém da PRIO e 6.226 têm como fonte a VALE3. Os sentimentos que foram adicionados a esses dados consideraram o impacto da notícia sobre o mercado financeiro, usando 0 (zero) para reações negativas e 1 (um) para reações positivas. De forma geral, os sentimentos alcançaram maior número de resultados positivos nos anos analisados, excetuando-se os anos de 2019 e 2021 para o Banco do Brasil e em 2020 para a Vale do Rio Doce. Esses resultados podem estar atrelados aos reflexos da pandemia, que também tiveram um impacto significativo sobre as empresas brasileiras, sobretudo em 2020 e 2021, embora ainda haja consequências empresariais, sociais e econômicas decorrentes das medidas usadas no enfrentamento ao coronavírus.

Para fazer a validação da assertividade das previsões feitas pelo protótipo, um percentual de aproximadamente 20% das notícias de cada empresa e os resultados do mercado financeiro não foram repassadas como informações que compunham a base de dados da ferramenta criada, possibilitando, assim, usar esses dados como teste de sua acurácia. Os resultados apontaram que houve um destaque das variáveis positivas no *recall* (eficiência em prever resultados positivos) da PetroRio (0.57) e do Banco do Brasil (0.53), assim como destacou-se o valor das previsões positivas para a variável *precision* (quantos acertos as previsões dos positivos realmente alcançaram) obtendo o mesmo valor (0.52) em todas as empresas. De forma geral, no entanto, a acurácia que mediu a efetividade do *F1-Score*, ou seja, a média de precisão do protótipo testado, apresentou baixa efetividade, já que atingiu no máximo 52% de precisão.

Ao disponibilizar um cadastro permitindo ao usuário acessar os dados do projeto, permite-se também o acesso aos sentimentos em relação às ações das empresas pesquisadas por meio de uma página web. O usuário poderá circular entre os dados e deparar-se-á com diferentes formas de gráficos contendo as informações tanto abrangendo o contexto total dos dados das empresas pesquisadas, quanto de forma isolada a cada empresa, ou limitada a um período temporal.

Este estudo oportuniza preencher uma lacuna ainda não explorada eficientemente pela tecnologia: realizar testes históricos de previsões de subida ou descida do preço das ações na bolsa de valores, cuja volatilidade desencoraja muitos investidores. O estudo das notícias do mercado financeiro e seu impacto nas cotações mostrou-se promissora em preencher essa lacuna, mostrando resultados de testes históricos para investidores e empresas. Isso se apresenta como um aspecto significativo para a economia, o desenvolvimento social, empresarial e midiático brasileiro.

Sugere-se investigar *a posteriori* se o número de notícias interfere na qualidade do treinamento e da assertividade dos resultados preditivos do protótipo. Apóia-se também como sugestão de investigações futuras, as proposições feitas por Vargas *et al.* (2018) quanto a eliminar as pequenas variações das ações, concentrando-se somente nas variações mais significativas para ampliar a acurácia das previsões sem perder velocidade no processamento dos dados e na apresentação dos resultados preditivos.

REFERÊNCIAS

- ARBEL, Nir. **How LSTM networks solve the problem of vanishing gradients**. 2018. Disponível em: <https://medium.datadriveninvestor.com/how-do-lstm-networks-solve-the-problem-of-vanishing-gradients-a6784971a577>. Acesso em: 23 jun. 2022.
- BRAGA, Antônio de Pádua; CARVALHO, André Ponce L. F.; LUDERMIR, Tereza Bernarda. **Redes Neurais Artificiais: Teoria e Aplicações**, Editora LTC, 2. ed., 226 p., 2007.
- BUFO, Moacir José. **Aplicação de rede neural artificial como auxiliar na predição do desempenho de um landfarming**. 2000. 192 p. Dissertação (Mestrado em Engenharia Agrícola) - Universidade Estadual de Campinas, Campinas.
- CARVALHO, Rainara Maia; ANDRADE, Rossana Maria de astro.; OLIVEIRA, Káthia Marçal de. Aquarium-a suite of software measures for hci quality evaluation of ubiquitous mobile applications. **Journal of Systems and Software**, Elsevier, v. 136, p. 101–136, 2018.

- CENTENO, Jorge Antônio Silva. **Sensoriamento Remoto e Processamentos de Imagens digitais**. Curitiba: Universidade Federal do Paraná. Curso de Pós Graduação em Ciências Geodésicas, 2004. 219 p. ISBN 85887830503
- ELAGAMY, Mazen Nabil; STANIER, Clare; SHARP, Bernadette (2018). **Text Mining Approach to Analyse Stock Market Movement**. In: Proceedings of the The International Conference on Advanced Machine Learning Technologies and Applications (AMLTA, 2018). Springer, pp. 661-670. ISBN 978-3-319-74690-6
- FERRO, Luciano. **Aplicação da rede neural MLP (Multilayer Perceptron) em indústria de pisos e revestimentos do Polo Cerâmico de Santa Gertrudes - SP**. 2013. 143 f. Tese (Doutorado) - Universidade Estadual Paulista Júlio de Mesquita Filho, Instituto de Geociências e Ciências Exatas, 2013. Disponível em: Acesso em: 09/06/2021.
- GIACOMEL, Felipe dos Santos. **Um método algorítmico para operações na bolsa de valores baseado em ensembles de redes neurais para modelar e prever os movimentos dos mercados de ações**. 2016. 92 f. Dissertação (Mestrado) - Curso de Programa de Pós-graduação em Computação, Instituto de Informática, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2016. Disponível em: <https://lume.ufrgs.br/handle/10183/134586>. Acesso em: 09/06/2021.
- GOODFELLOW, Ian; BENGIO, Yoshua; COURVILLE, Aaron. **Deep learning**. Cambridge: The MIT Press, 2016, 800 pp, ISBN: 0262035618. Disponível em: https://www.researchgate.net/publication/320703571_Ian_Goodfellow_Yoshua_Bengio_and_Aaron_Courville_Deep_learning_The_MIT_Press_2016_800_pp_ISBN_0262035618/link/5b880b494585151fd13c8b95/download. Acesso em: 08/06/2021.
- HAYKIN, Simon. **Neural Networks and Learning Machines**. Third edition. New York: Pearson Education, 2008. Disponível em: <http://dai.fmph.uniba.sk/courses/NN/haykin.neural-networks.3ed.2009.pdf>. Acesso em: 07/06/2021.
- HIRANSHA, Martin et al. "NSE Stock Market Prediction Using Deep-Learning Models", *Procedia Computer Science*, 132 (2018): 1351-1362. Disponível em: <https://doi.org/10.1016/j.procs.2018.05.050>. Acesso em 09/06/2021.
- INVESTING.COM. **Plataforma de mercados financeiros**. [S.l.], [2022?]. Disponível em: https://www.google.com/search?q=O+QUE+%C3%89+O+site+br.investing.com&rlz=1C1FCXM_pt-PTBR984BR984&sxsrf=ALiCzsbGG2MihBaa4iie-ox2Vf4u1xQR1g%3A1657586054047&ei=hsHMYoO6ApCb5OUPormCuA8&ved=0ahUKEwiDlb6jfl4AhWQDbkGHAKcAPcQ4dUDCA4&oq=O+QUE+%C3%89+O+site+br.investing.com&gs_lcp=Cgdnd3Mtd2l6EAw6BggAEB4QCEoECEYYAEoECEYYAFAAWM4kYIkuaABwAHgAgAG5AYgByAqSAQQwLjEwmAEAoAEBwAEB&scIint=gws-wiz. Acesso em: 07/06/2021.
- LI, Shihua, Li *et al.* Object-oriented method combined with deep convolutional neural networks for land-use-type classification of remote sensing images. **Journal of the Indian Society of Remote Sensing**, 47(6), pp. 951-965, Jan., 2019. Disponível em: https://www.researchgate.net/publication/330429024_ObjectOriented_Method_Combined_with_Deep_ConvolutionalNeural_Networks_for_LandUseType_Classification_of_Remote_Sensing_Images/link/5cb049a64585156cd79176ad/download. Acesso em: 10/06/2021.
- LI, Tao; *et al.* Mapping Near-surface Air Temperature, Pressure, Relative Humidity and Wind Speed over Mainland China with High Spatiotemporal Resolution. **Advances In Atmospheric Sciences**, vol. 31, September 2014, 1–9. Disponível em: https://www.researchgate.net/publication/267633552_Li_et_al_2014_AAS/link/545598b40cf2bccc490cce7c/download. Acesso em: 09/06/2021.
- LUGER, George F. **Inteligência Artificial**. 6. ed. São Paulo: Pearson Education, 2013.
- MACHADO, Daniel José. **Comparando modelos alternativos de precificação de ativos: uma análise para o mercado brasileiro**. 2017. 178 f. Tese (Doutorado em Administração de Empresas) - Universidade Presbiteriana Mackenzie, São Paulo, 2017. Disponível em: <http://tede.mackenzie.br/jspui/handle/tede/3444>. Acesso em: 09/06/2021.
- MALHOTRA, Naresh; ROCHA, Ismael.; LAUDISIO, Maria Cecília. **Introdução à Pesquisa de Marketing**. São Paulo: Pearson Prentice Hall, 2005.
- MAZINI, Dhaniel Nunes; SATO, Renato Cesar. **Extração de dados financeiros com um web scraper: um estudo sobre a rentabilidade dos dividendos**. Presentations and Accepted Papers at WAIAF, 2020. Disponível em: http://www.comp.ita.br/labsca/waiaf/papers/DhanielMazini_paper_20.pdf. Acesso em: 09/06/2021.
- MUELLER, John Paul; MASSARON, Luca. **Machine Learning for Dummies**. Nova Jersey: John Wiley & Sons, Inc, 2016. 399 p.
- PAGOLU, Venkata Sasank; CHALLA, Kamal Nayan Reddy; PANDA, Ganapati. "Sentiment Analysis of Twitter Data for Predicting Stock Market Movements", International conference on Signal Processing, Communication, Power and Embedded System (SCOPEs), 2016. Held 3-5 October 2016, Paralakhemundi, Odisha, India. Disponível em: <https://www.semanticscholar.org/paper/Sentiment-analysis-of-Twitter-data-for-predicting-Pagolu-Challa/fcbba03b6156295a5738f9f03d157f67f665365c>. Acesso em: 07/06/2021.
- QIN Li et al. (2020). **Study on the prediction of stock price based on the associated network model of LSTM**. *Int J Mach Learn Cybern* 11(6):1307–1317. Disponível em: https://www.researchgate.net/publication/338783254_A_Multimodal_Eventdriven_LSTM_Model_for_Stock_Prediction_Using_Online_News. Acesso em: 08/06/2021.
- RICHARDSON, Roberto Jarry. **Pesquisa social: métodos e técnicas**. São Paulo: Atlas, 1999.

SAMMUT, Claude; WEBB, Geoffrey. (Editors). 2010. In: Sammut C., Webb GI (Eds.) **Encyclopedia of Machine Learning and Data Mining**. Claude Sammut & Geoffrey I. Webb (eds.), Encyclopedia of Machine Learning, DOI 10.1007/978-0-387-30164-8, Springer Science+Business Media LLC 2011. Springer, Boston, MA. Disponível em: <http://pzs.dstu.dp.ua/DataMining/bibl/Encyclopedia%20Machine%20Learning%202011.pdf>. Acesso em: 06/06/2021.

SANTOS, Murilo Alves; *et al.* Aplicação de redes neurais no Brasil: um estudo bibliométrico. **Biblionline**, v. 12, n. 2, p. 101-116, 2016. Disponível em: https://www.researchgate.net/publication/303957049_APLICACAO_DE_REDES_NEURAIIS_NO_BRASIL_UM_ESTUDO_BIBLIOMETRICO. Acesso em: 07/06/2021.

SILVA, Anderson Rodrigues da. **Aspectos regulatórios da bolsa de valores no Brasil**. 2017. 135 f. Dissertação (Mestrado) - Curso de Direito, Programa de Estudos Pós-graduados em Direito, Pontifícia Universidade Católica de São Paulo, São Paulo, 2017. Disponível em: <https://tede2.pucsp.br/handle/handle/20876>. Acesso em: 09/06/2021.

TRISOTTO, Fernanda. Apesar da pandemia, Bolsa de Valores teve ano de recordes. E o que esperar de 2021? **Gazeta do Povo**. 30/12/2020. Disponível em: <https://www.gazetadopovo.com.br/economia/bolsa-de-valores-ano-2020-recordes-pandemia/>. Acesso em: 10/06/2021.

VARGAS, Manoel R; ANJOS, Carlos E. M. dos; BICHARA, Gustavo L. G., EVSUKOFF, Alexandre G. "Deep learning for stock market prediction from financial news articles", **IEEE International Conference on Computational Intelligence and Virtual Environments for Measurement Systems and Applications (CIVEMSA)**, pp. 60-65, 2018. Disponível em: https://www.researchgate.net/profile/AlexandreEvsukoff/publication/328400101_Deep_Learning_for_Stock_Market_Prediction_Using_Technical_Indicators_and_Financial_News_Articles/links/5c6ab8294585156b57036c91/Deep-Learning-for-Stock-Market-Prediction-Using-Technical-Indicators-and-Financial-News-Articles.pdf. Acesso em: 09/06/2021.

VERGARA, Sylvia Constant. **Projetos e relatórios de pesquisa em administração**. São Paulo: Atlas, 2006.

YANG, Li; YI, Pan. A Novel Ensemble Deep Learning Model for Stock Prediction Based on Stock Prices and News. **Semantic Scholar**. 23/07/2020. Disponível em: <https://www.semanticscholar.org/paper/A-Novel-Ensemble-Deep-Learning-Model-for-Stock-on-Li-Pan/d5aaa87a737c4ff98e0955b951b9892d03d221af>. Acesso em: 08/06/2021.