



UNIVERSIDADE FEDERAL DO RIO GRANDE - FURG
CENTRO DE CIÊNCIAS COMPUTACIONAIS
PROGRAMA DE PÓS-GRADUAÇÃO EM COMPUTAÇÃO
CURSO DE MESTRADO EM ENGENHARIA DE COMPUTAÇÃO

Dissertação de Mestrado

News Check: Ferramenta de classificação de manchetes de notícias utilizando mineração de dados

Janaina Adolfo Da Silva

Dissertação de Mestrado apresentada ao Programa de Pós-Graduação em Computação da Universidade Federal do Rio Grande - FURG, como requisito parcial para a obtenção do grau de Mestre em Engenharia de Computação

Orientadora: Prof^ª. Dr^ª. Graçaliz Pereira Dimuro

Rio Grande, agosto de 2022

Ficha Catalográfica

S586n Silva, Janaina Adolfo da.
 News Check: ferramenta de classificação de manchetes de notícias utilizando mineração de dados / Janaina Adolfo da Silva. – 2022.
 49 f.

 Dissertação (mestrado) – Universidade Federal do Rio Grande – FURG, Programa de Pós-Graduação em Computação, Rio Grande/RS, 2022.
 Orientadora: Dra. Graçaliz Pereira Dimuro.

 1. *Fake news* 2. Aprendizado de máquina 3. Mineração de dados
 4. Crença 5. Atratividade I. Dimuro, Graçaliz Pereira II. Título.

CDU 004.6


Catálogo na Fonte: Bibliotecário José Paulo dos Santos CRB 10/2344


DISSERTAÇÃO DE MESTRADO

**News Check: Ferramenta de classificação de manchetes de notícias
utilizando mineração de dados**

Janaina Adolfo da Silva

Banca examinadora:



Profa. Dra. Diana Francisca Adamatti

Prof. Dr. Giancarlo Lucca

Profa. Dra. Raquel de Miranda Barbosa

Profa. Dra. Graçaliz Pereira Dimuro
Orientadora

RESUMO

DA SILVA, Janaina Adolfo. **News Check: Ferramenta de classificação de manchetes de notícias utilizando mineração de dados**. 2022. 49 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Computação. Universidade Federal do Rio Grande - FURG, Rio Grande.

A evolução da tecnologia trouxe benefícios e malefícios para a sociedade, como a distribuição livre da informação, ao custo do contínuo crescimento das notícias falsas. Graças ao problema gerado pela grande circulação de notícias falsas, torna-se necessário estudar as *fake news*: Qual a sua definição? Como as pessoas creem nesse tipo de conteúdo? O presente trabalho foca numa pesquisa através do que torna uma notícia atrativa, utilizando dados sobre redes sociais como o Facebook e o Twitter e os vieses cognitivos, além de pesquisa e desenvolvimento, a partir do uso do aprendizado de máquina, de um classificador de manchetes de notícias com foco na temática sobre o coronavírus, utilizando o algoritmo Naive Bayes, o mais indicado para classificação textual. Assim, foi desenvolvido um sistema chamado News Check onde conta-se com 500 frases de manchete de notícias verificadas, em português brasileiro em seu banco de dados. Foi atingido, no melhor caso, o score de 76%, no caso médio o score de 68% e no pior caso o score de 58%. Porém, mesmo no pior caso, as notícias falsas foram classificadas com 72% de precisão. Conclui-se desta maneira, que por mais que o algoritmo se aproxime do triplo da capacidade humana de identificar *fake news*, o mesmo não substitui a necessidade da atenção à leitura e desenvolvimento do senso crítico de cada leitor.

Palavras-chave: Fake news, aprendizado de máquina, mineração de dados, crença, atratividade.

ABSTRACT

DA SILVA, Janaina Adolfo. **News Check: Classification tool of news headlines utilizing data mining**. 2022. 49 f. Dissertação (Mestrado) – Programa de Pós-Graduação em Computação. Universidade Federal do Rio Grande - FURG, Rio Grande.

The evolution of technology has brought benefits and harms to society, such as the free distribution of information, at the cost of the continuous growth of fake news. Due to the problem generated by the large circulation of fake news, it becomes necessary to study it: What is its definition? How do people believe in this kind of content? The present paper focuses on a research through what makes news attractive, utilizing data about social networks such as Facebook and Twitter and cognitive biases, as well as a research and development, through the use of machine learning, of a news headlines classifier focused on the coronavirus theme, using the naive Bayes algorithm, the most suitable for textual classification. Thus, a system called News Check was developed with 500 verified news headline phrases, in Brazilian Portuguese in its database. In the best case, it was reached a score of 76%, in the average case, a score of 68% and in the worst case, a score of 58%. But even in the worst case, fake news was rated with 72% accuracy. As a conclusion, as much as the algorithm approaches triple the human capacity to identify fake news, it does not replace the need to pay attention to the reading and development of each reader's critical sense.

Keywords: Fake news, machine learning, data mining, belief, attractiveness.

LISTA DE FIGURAS

Figura 1	<i>fake news</i> sobre o uso da cloroquina como tratamento para covid-19. .	16
Figura 2	O processo de KDD	32
Figura 3	Site News Check	34
Figura 4	Notícia verdadeira	35
Figura 5	Notícia falsa	35
Figura 6	Notícia verdadeira com os detalhes estatísticos	36
Figura 7	Notícia falsa com os detalhes estatísticos	37

LISTA DE TABELAS

Tabela 1	Tempo médio de 5 execuções	21
Tabela 2	Resumo dos trabalhos relacionados	25
Tabela 3	Exemplos de aplicações de filtro em frase	28
Tabela 4	Exemplo de resultado de saída da função <i>Bag-of-Words</i>	29
Tabela 5	Tabela exemplo de matriz de confusão	30
Tabela 6	Melhor Caso - Score 76%.	39
Tabela 7	Caso Médio - Score 68%.	39
Tabela 8	Pior Caso - Score 58%.	39

LISTA DE ABREVIATURAS E SIGLAS

SVM	Support vector machine (Máquina de Vetores Suporte)
CPPD	Categorical Probability Proportional Difference

SUMÁRIO

1	Introdução	11
1.1	Objetivos	13
1.1.1	Objetivo geral	13
1.1.2	Objetivos específicos	13
1.1.3	Justificativa	13
2	Revisão da literatura	14
2.1	Atratividade das <i>fake news</i>: ilustração e conteúdo textual	15
2.2	Perigo eminente à saúde global em consequência das <i>fake news</i>	17
2.3	Dados das redes sociais	17
2.4	Cognitividade	18
2.5	Mineração de dados	19
2.5.1	Classificação	19
3	Trabalhos Relacionados	22
4	Metodologia	26
4.1	Ferramentas Utilizadas	27
4.1.1	Separação e filtros de dados	27
4.1.2	Métricas das respostas do algoritmo	29
4.2	Aplicação do framework de Fayyad	30
4.3	Processamento de dados	32
4.4	Interface do sistema	33
5	Resultados e discussão	38
5.1	Resultados obtidos	38
5.2	Limitações do estudo	39

6	Conclusão	41
6.1	Contribuições da dissertação	42
6.2	Trabalhos Futuros	43
	Referências	44
 ANEXOS		
A	Endereço do dataset utilizado	49

1 INTRODUÇÃO

As notícias falsas, ou *fakenews*, há muito tempo estão presentes no cotidiano, tornaram-se um assunto relevante em várias épocas, como por exemplo, entre 2015 e 2016 por terem sido grandes influenciadoras nas eleições norte americanas e no processo de impeachment ocorrido no Brasil. Segundo os autores [Delmazo e Valente \(2018\)](#) as *fakenews* antecederam a existência da *internet*, apresentando-se:

- **Itália:** No século XVI, com o surgimento dos pasquins disseminou-se notícias desagradáveis e falsas, sobre personagens públicos ([Darnton, 2017, apud Delmazo e Valente, 2018](#));
- **Paris:** No século XVII, com o surgimento dos Canards, também começou a circular notícias falsas ([Darnton, 2017, apud Delmazo e Valente, 2018](#));
- **Alemanha:** No século XIX, os escritores locais fingiam escrever do exterior, isso ocorria pois, era muito caro enviar repórteres para o exterior. Outro caso foi de Theodor Fontaine, que enviou textos para o jornal Kreuzzeitung de Berlim, como se estivesse em Londres, mas nunca esteve lá nos anos de 1860 ([McGuillen, 2017, apud Delmazo e Valente, 2018](#)).

Segundo o autor [Branco \(2017\)](#), houveram alguns casos sérios no Brasil:

- Em maio de 2014, após uma notícia falsa sobre uma sequestradora de crianças, que as utilizava para bruxaria na cidade do Guarujá, se disseminou no Facebook. A grande maioria dos moradores desta cidade fizeram justiça com as próprias mãos, levando a morte uma dona de casa de 33 anos, por se parecer com a mulher que estava na foto da tal notícia;
- Em 2016, na Baixada Fluminense, associaram um serralheiro como se fosse um estuprador de crianças, depois desse boato o morador passou a receber ameaças de morte;

- Em 2017, em Araruama, Rio de Janeiro, foi divulgado no WhatsApp o boato de sequestro de crianças, por causa deste boato uma multidão tentou linchar um casal.

No ano de 2020 com a pandemia do covid-19, as *fakenews* assumiram grande popularidade novamente, um exemplo são as notícias de medicamentos para cura do coronavírus. Com esta nova realidade, a população começa a buscar por informações e métodos para se proteger. Assim, surgindo o problema da ânsia pela informação, na qual as pessoas acabam recebendo e compartilhando notícias sem comprovar sua veracidade, causando desinformação, medo e estado de caos (de Sousa Júnior et al., 2020).

Como contraponto, estudos identificam as *fakenews* relacionadas com a covid-19, um deles foi a criação de um aplicativo chamado “Eu fiscalizo”, onde os usuários notificam sobre notícias falsas sobre a covid-19 (Portal Fiocruz, 2020).

Müller e de Souza (2018) dissertam sobre a diferença entre *fakenews* e boato. No primeiro, há uma intenção proposital de desinformar, de maneira que gere alguma espécie de lucro (seja dinheiro, engajamento ou influência) para o redator da informação. Já para ser considerada boato, nunca se sabe quem é o autor original da notícia e ela necessita passar por muita gente. Os autores deixam claro que “muita gente” é um termo vago e que necessita de quantificação. Além disso, um boato pode ser verdadeiro ou falso, já uma, *fakenews* é sempre falsa.

Assim, os autores informam que o boato circula de maneira oral. Já as *fakenews*, podem circular de qualquer forma. Embora os autores proponham uma diferenciação entre *fakenews* e boato, através destas definições, pode-se entender que não existe boato no ramo das redes sociais, visto que sempre pode-se chegar a quem postou a notícia originalmente e dificilmente ficará claro se o autor disseminou este conteúdo de forma ingênua ou visando o lucro, visto que as redes sociais apoiam materiais que geram engajamento.

Dadas às noções de significado de notícias falsas, apresentadas anteriormente e a alta velocidade de circulação deste tipo de material no âmbito digital, sejam redes sociais, blogs ou sites de notícias, tem-se como objetivo desta dissertação o desenvolvimento de um verificador de notícias, utilizando os conceitos de mineração de dados, chamado News Check.

Esta ferramenta auxilia os usuários leigos em tecnologia a verificar notícias falsas sobre a prevenção do vírus sars-cov-19 através de uma implementação que verifica manchetes de notícias e as classifica em verdadeira ou falsa utilizando uma interface de um sistema web, desenvolvido especificamente para este projeto. Sua maneira de uso é relativamente simples, onde o usuário deverá inserir uma manchete e pressionar um botão, assim obtendo a resposta se a notícia em questão é verdadeira ou falsa.

1.1 Objetivos

1.1.1 Objetivo geral

Esta dissertação tem como objetivo estudar as *fake news* relacionadas com o Covid-19 e propor uma solução de maneira a classificar notícias em verdadeiras ou falsas, através de técnicas de mineração de dados.

1.1.2 Objetivos específicos

- Estudar como ocorre a crença nas *fake news*;
- Desenvolver um banco de notícias para servir como treinamento para ampliar a eficiência do classificador automático;
- Desenvolver um algoritmo com o intuito de classificar as notícias;
- Compreender o ambiente em que mais circula as notícias atualmente, as plataformas web;
- Desenvolver uma plataforma web em que o usuário possa inserir uma notícia qualquer e testar se a mesma é verdadeira ou falsa sem necessitar entender detalhes técnicos sobre programação.

1.1.3 Justificativa

Segundo [Almeida et al. \(2019\)](#), “construir modelos de aprendizagem com recursos extraídos de manchetes de notícias pode levar a resultados de eficácia competitiva, quando comparados com modelos baseados em textos de notícias.”

Dada a citação acima, buscou-se desenvolver um verificador de manchetes de notícias, na língua portuguesa, que abrange temas como vacinas contra o coronavírus, remédios sem eficácia comprovada contra o vírus e algumas notícias não relacionadas gerais, por não encontrarmos na literatura trabalhos que unam estas temáticas com um verificador de manchetes de notícias.

O tema coronavírus e suas vacinas tomaram relevância num período muito próximo do início de desenvolvimento desta dissertação, abril de 2020, estendendo-se até o desenvolvimento, justificando assim a escolha pela abordagem deste tema.

2 REVISÃO DA LITERATURA

Os autores [Bakir e Mcstray \(2018\)](#) definem *fake news* como “uma falsidade completa ou conteúdo que possui deliberadamente elementos enganosos incorporados no conteúdo ou contexto”.

[Wardle \(2017, apud Bakir e Mcstray, 2018\)](#) classifica a *fake news* nas sete categorias abaixo:

- **“Conexão falsa:** Quando títulos, figuras ou legendas não condizem com o conteúdo;
- **Conteúdo falso:** Quando o conteúdo é genuíno, mas é compartilhado com informação contextual falsa;
- **Conteúdo manipulado:** Quando o conteúdo e figuras são genuínas, mas são manipuladas para convencer;
- **Conteúdo enganoso:** Uso enganoso da informação para enquadrar um problema ou indivíduo;
- **Conteúdo impostor:** Fontes genuínas são personificadas;
- **Conteúdo construído:** Conteúdo 100% falso para dissuadir;
- **Sátira/Paródia:** Conteúdo com potencial para enganar, mas sem a intenção do mesmo”.

Para [Allcott e Gentzkow \(2017\)](#) “artigos noticiosos que são intencionalmente falsos e aptos a serem verificados como tal, e que podem enganar os leitores”. Já segundo os autores [Guess et al. \(2018\)](#) “um novo tipo de desinformação política” marcada por uma “dubiedade factual com finalidade lucrativa”.

De acordo com [Branco \(2017\)](#) há quatro categorias distintas que os sites compartilham *fake news*, são elas:

1. “Os que intencionalmente buscam enganar através de manchetes tendenciosas;
2. Os de reputação razoável que compartilham boatos em larga escala sem verificar corretamente os fatos;

3. Os que relatam de forma tendenciosa fatos reais, manipulando a informação;
4. Os que humoristicamente trabalham com situações hipotéticas”.

A lógica para disseminação das *fake news*, é aproveitar a bolha que se encontra o usuário, como por exemplo: O usuário A que tem seu próprio partido, mas o usuário B é contra este partido para presidência do país, para expressar essa opinião, o B utiliza em suas redes sociais *hashtags* contra partido do A. Assim os perfis falsos controlados por vários robôs, varrem as redes sociais e acabam encontrando essas *hashtags* do usuário B, desta maneira começam a enviar notícias falsas sobre o assunto para este usuário. Por fim o usuário B compartilha essas informações com todos a sua volta (Branco, 2017).

2.1 Atratividade das *fake news*: ilustração e conteúdo textual

Segundo o estudo realizado pela Universidade de Columbia e o Instituto Nacional Francês que mostrou que 59% dos links compartilhados nas redes sociais nem são clicados (Dewey, 2016), ou seja, **uma manchete atraente**, já é o suficiente para propagação das *fake news*.

O estudo realizado na Universidade de Warwick, no Reino Unido, testou a capacidade das pessoas de identificar imagens manipuladas, que são utilizadas em *fake news*. O teste foi online e contou com um banco de dados com 40 imagens sendo 10 originais e 30 manipuladas (6 foram utilizadas em 5 tipos de manipulação diferentes) (G1, 2017):

- 60% identificaram manipulação;
- 45% apontaram corretamente onde tinha manipulação;
- 40% não identificaram manipulação;

Para chamar atenção do leitor a manchete tem que ter título interessante, uma fotografia chamativa e ser sobre assuntos que estão em alta no momento, fazendo as pessoas fiquem curiosas e interessadas pela notícia (Pereira e Salazart, 2018).

Segundo o autor Baptista (2020) as *fake news* obedecem a uma estrutura específica (partindo da escolha da ilustração até a formação do título e da linguagem usada ao longo do texto) permitindo assim, não só chamar a atenção do usuário, mas também promover a crença, o consumo e a divulgação do conteúdo deliberadamente falso.

Já para Carinhato et al. (2019) as *fake news* assumem a forma de texto e imagem aparecendo num espaço de disputa discursiva e apelam para o uso de distorções, inversões e hipérboles, trabalhando com a produção de novas memórias, não factuais. São produzidas em redes sociais e partem de recursos de acusação *ad hominem*, com capacidade

ilimitada de propagação, sua adesão se dá, de acordo com a pós-verdade, de forma coletiva, na modalidade do pânico e do rumor, geralmente contra minorias ou contra sujeitos que lutam por direitos.

A atratividade das *fake news* baseia-se nas crenças políticas, religiosas e ideológicas dos leitores. Como pode ser visto na Figura 1, a notícia falsa sobre o uso da cloroquina como tratamento para covid-19 que curou 4 pessoas, mesmo sem comprovação científica de sua eficácia. Podemos perceber que a manchete traz um título chamativo, com a foto de uma pessoa internada e assunto sobre cura da covid pelo remédio.

Figura 1: *fake news* sobre o uso da cloroquina como tratamento para covid-19.



Fonte: Adaptado de [Rudnitzki et al. \(2020\)](#).

2.2 Perigo eminente à saúde global em consequência das *fake news*

Segundo [de Sousa Júnior et al. \(2020\)](#), o compartilhamento de notícias falsas também instauram o medo e o caos entre seus receptores, trazendo problemas graves em relação à luta que os órgãos de saúde travam para conscientizar e prevenir a população. As mais incomuns e não comprovadas maneiras de “combater” o coronavírus foram propostas por fontes não oficiais:

- “Chá de abacate com hortelã previne o coronavírus”;
- “Hidroxicloroquina e cloroquina curam o coronavírus”;
- “Cientistas indianos encontraram semelhança entre o vírus HIV com o coronavírus”;
- “Álcool-gel não tem eficácia, vinagre sim”.

A população idosa é mais vulnerável à propagação de notícias falsas, já que, segundo [Yabrude et al. \(2020\)](#), “os indivíduos acima de 65 anos de idade são sete vezes mais propensos a espalhar notícias falsas do que as pessoas com menos de 29 anos.” Este público é o mais prejudicado com este tipo de conteúdo, por sua baixa familiaridade com a internet, não sabendo distinguir memes verdadeiros de falsos, além de crenças antigas que o popular “chazinho da avó” pode curar este tipo de doença, vide o exemplo “chá de abacate com hortelã previne o coronavírus” citado anteriormente.

2.3 Dados das redes sociais

Segundo [Mohsin \(2020\)](#), em 2019 o Facebook tinha 2,60 bilhões de usuários ativos mensais, com 1,73 bilhão de usuários que acessam diariamente pelo menos um dos principais produtos da rede Facebook como o próprio Facebook, WhatsApp, Instagram ou Messenger. Como perfil de usuário desta rede social, a maioria, 65%, têm faixa etária menor do que 35 anos, na qual 96% de seu público a utilizam via dispositivos móveis, gastando, em média, 58,5 minutos diários nesta plataforma.

Já segundo [Lin \(2020\)](#) em 2019 o Twitter tinha 11,7 milhões de downloads na App Store, para seus 330 milhões de usuários ativos, nos quais 40% (145 milhões) utilizam o serviço diariamente e 20% acessam pelo menos uma vez por mês. Coletivamente produzindo por dia 500 milhões de *tweets* em apenas 3,39 minutos de uso médio. Diferente do Facebook, a maioria de seus usuários (63%) tem variação de idade entre 35 a 65 anos com maioria masculina (66%).

Exemplificando o Twitter, a popularidade do meme é o número de *tweets* que contêm o meme, de maneira que apenas alguns memes são amplamente difundidos, a grande maioria não. A competição entre memes é feroz, hashtags parecidas competem entre si, e apenas algumas poucas têm vida útil longa, a maioria tem vida curta. Além disso, os usuários são mais propensos a retuitar memes sobre os quais postaram no passado (Weng et al., 2012).

Em 2020, quando iniciou-se a confecção deste trabalho, o mundo já encontrava-se em plena pandemia gerada pelo Covid-19. Foi recomendado que as pessoas evitassem sair de suas casas, de modo a protegerem-se da contaminação pelo vírus.

Com isto, os trabalhadores que puderam adaptar-se para o sistema home office, aumentaram a demanda de usuários por todas as redes sociais populares, visto que nem todas as empresas utilizaram sistemas de comunicação profissionais. Segundo Kemp (2020) até outubro de 2020 este aumento de demanda resultou em 4,66 bilhões de pessoas conectadas na internet, de um total de 7,81, destas, 4,14 bilhões utilizam redes sociais.

2.4 Cognitividade

O cérebro humano tem dificuldade de processar o excesso de informação que temos atualmente. Alguns efeitos que influenciam nossa tomada de decisão, segundo Cognitive Bias of the Day (2018) são:

- **Viés cognitivo:** Erros sistemáticos nos julgamentos que os humanos fazem consistentemente;
- **Viés de confirmação:** A tendência de interpretar novas evidências como confirmação das crenças ou teorias existentes;
- **Efeito propaganda:** É um fenômeno pelo qual a taxa de absorção de crenças, ideias, modismos e tendências aumenta quanto mais eles já foram adotados por outros, "entrar no movimento", independentemente das evidências subjacentes;
- **Cascata de disponibilidade:** Uma nova ideia, geralmente aquela que parece explicar um processo complexo de uma maneira simples, normalmente dita por um líder ou influência local. Gera necessidade de aceitação social e a aparente sofisticação do novo pensamento sobrecarregam seu pensamento crítico;
- **Efeito de influência contínua:** O efeito de desinformação ocorre quando a lembrança de memórias se torna menos precisa por causa das informações recebidas depois do evento.

As pessoas são afetadas pela conotação emocional de uma mensagem, tendem a dar mais credibilidade para sites que focam no fator estético, ou seja, menor a probabilidade do leitor criticar conteúdo embutido em bons recursos visuais. Mesmo quando a notícia for retratada, o cérebro registra melhor a notícia original, este é o real efeito das *fake news* (Benson, 2016).

2.5 Mineração de dados

A mineração de dados, do inglês *Data Mining*, surgiu nos anos 80, como uma metodologia com o propósito de gerenciar grandes quantidades de dados. Em sua bibliografia diferentes autores de diferentes épocas definem o tema por função e área de pertencimento. Segue abaixo algumas definições para ilustrar o tema.

Para Cabena et al. (1998, apud Costa et al., 2012) “é uma área interdisciplinar, mobilizando principalmente conhecimentos de análise estatística de dados, aprendizagem de máquina, reconhecimento de padrões e visualização de dados”.

Segundo de Amo (2004) “data mining consiste sobretudo na análise dos dados após a extração”. Está presente nas áreas de estatística, aprendizado de máquina e são baseadas em crescimento-poda-validação. Como exemplo, podemos citar quando uma empresa quer fazer marketing, na qual vai analisar todo histórico de pesquisa e compras de seus clientes.

Fayyad et al. (1996, apud Camilo e da Silva, 2009) definem mineração de dados levando em consideração a área de aprendizado de máquina: “consiste na realização da análise dos dados e na aplicação de algoritmos de descoberta que, sob certas limitações computacionais, produzem um conjunto de padrões de certos dados”.

2.5.1 Classificação

Classificação é o processo de encontrar um conjunto de modelos que descrevem e distinguem classes ou conceitos, utilizando o modelo para prever a classe de novos registros no sistema. O modelo construído baseia seu julgamento na análise prévia de um conjunto de dados de amostragem ou treinamento, contendo objetos corretamente classificados previamente (de Amo, 2004).

Segundo da Costa Côrtes et al. (2002) a classificação é a “descrição por classes e conceitos”, consistindo “em examinar uma certa característica nos dados e atribuir uma classe previamente definida. Dados podem ser associados a classes ou a conceitos através de um processo de discriminação ou de caracterização”.

Já para os autores Camilo e da Silva (2009) a classificação analisa um conjunto de

dados já classificados, para assim treinar uma nova entrada. Este método pode ser usado como por exemplo: “Determinar quando uma transação de cartão de crédito pode ser uma fraude” ou “diagnosticar onde uma determinada doença pode estar presente”.

2.5.1.1 Classificação Bayesiana

4 Nesta dissertação tratamos o problema de classificação textual (Ikonomakis et al., 2005). Para tal, foi utilizado o algoritmo Naive Bayes (Amaral, 2016). Este método é baseado no teorema de Thomas Bayes, uma técnica estatística, que torna “possível encontrar a probabilidade de um certo evento ocorrer, dada a probabilidade de um outro evento que já ocorreu” (Camilo e da Silva, 2009):

$$P(y_i/x) = \frac{P(y_i)P(x/y_i)}{P(x)} \quad (1)$$

$$P(x) = \sum_{i=1}^n P(y_i)P(x/y_i) \quad (2)$$

Após o treinamento, insere-se uma nova amostra, assim o classificador tomará uma decisão, representada por $P(y_i/x)$ que assumirá a maior probabilidade, calculada pela equação 1.

Já na equação 2, $P(x)$, representa a densidade de probabilidade das classes, ou a evidência e $P(x/y_i)$ é a função de probabilidade de cada classe y_i . Então realiza-se o somatório de 1 ou mais elementos, representados pela letra n designando a última equação e a letra i designando o iterador.

Esse classificador calcula a probabilidade de uma nova amostra pertencer ou não a alguma das classes pré determinadas, predizendo a mais provável. Desta maneira, calcula, na presente dissertação, uma distribuição geradora para cada classe através da análise das relações entre as palavras da notícia e as classes verdadeira ou falsa. Como, por exemplo, a probabilidade de uma notícia verdadeira ter uma palavra específica presente no corpo da mensagem.

Comparativos mostram que os algoritmos *Naive Bayes*, mesmo com sua simplicidade de implementação, obtiveram resultados compatíveis com os métodos de árvore de decisão e redes neurais, tornando-o um dos mais utilizados (ZHANG 1995 apud Camilo e da Silva, 2009). Para seu pleno funcionamento, parte do princípio que não exista relação de dependência entre os atributos (Camilo e da Silva, 2009).

Segundo de Oliveira e Pereira (2017) a classificação bayesiana propõe “algoritmos estatísticos que classificam objetos analisando a probabilidade de sua pertinência em cada uma das possíveis classes predefinidas e escolhendo aquela mais provável”. Os “resulta-

dos empíricos descritos na literatura mostram que o algoritmo Naive Bayes tem bons resultados e custo computacional baixo”.

Para [Maia \(2005\)](#) esta classificação é simples, rápida e de fácil implementação, e a “essência da abordagem Bayesiana é prover regras que expliquem como mudar o grau de crença atual em uma hipótese quando da constatação de novas evidências”.

Por ser uma estrutura simplificada tem diversas vantagens como: “Classificação, é alcançada em tempo linear”; estrutura “facilmente atualizada permitindo adicionar ou remover evidências no modelo”. Mas, “sua suposição de independência condicional entre as variáveis nem sempre é verdadeira, podendo trazer influências negativas ao resultado da inferência” ([Maia, 2005](#)).

A utilização desta ferramenta foi designada pelo seu índice de precisão, custo computacional com melhor compatibilidade a um banco de dados pequeno (500 entradas) além de ser um algoritmo recomendado para classificação textual, visto que compara palavras livre de seu papel na sentença.

Outro fator é a velocidade de execução, comparados aos testes realizados com Naive Bayes Gaussiano, KNN e Árvore de decisão, como pode ser observado na Tabela 1. Foi um dos mais rápidos nos testes aqui realizados, que se torna um fator importante visto que foi desenvolvido para funcionar em uma plataforma web. No pior caso, empata com a árvore de decisão e no melhor caso e no caso médio, foi o algoritmo de melhor precisão.

Tabela 1: Tempo médio de 5 execuções

Algoritmo	Tempo em segundos
Arvore de decisão	1.24
NB Gaussiano	1.36
Knn	1.66
Naive Bayes	1.12

Fonte: Própria.

3 TRABALHOS RELACIONADOS

[Oguri \(2006\)](#) investigou métodos de aprendizado de máquina para análise de sentimento em mídia textual, assim, testando os classificadores SVM (Support vector machine, do inglês máquina de vetores suporte) e *Naive Bayes* com diferentes modelos de representação textual e compara seus desempenhos.

Tratou a análise de sentimento como um problema de categorização de texto partindo da premissa de que cada documento está associado a uma classe positiva ou à negativa.

Diferenciou seu trabalho ao aplicar filtros de subjetividade que removem textos que não geram opinião. Dentro desta nova realidade, seus resultados indicam que o classificador de *Naive Bayes* se sobressai ao SVM.

[Almeida e Yamakami \(2011\)](#) revisaram “os métodos mais populares empregados como técnicas para seleção de termos em conjunto com sete modelos diferentes de filtros anti-spam Naïve Bayesianos.”

Apresentaram “um tutorial sobre diversos métodos seletores de termos empregados para reduzir a dimensionalidade do espaço de atributos na tarefa de filtragem automática de *spams* realizada por classificadores Naïve Bayesianos”.

Dentre os classificadores que apresentam, o NB Booleano e o NB Básico obtiveram os melhores desempenhos para a maioria das bases de dados. Assim, concluem concordando com a literatura afirmando “que o emprego de atributos Booleanos é melhor que por frequência de termos”.

Ao final, sugeriram como trabalho futuro que, por causa dos *spammers* inserirem “uma grande quantidade de ruídos nas mensagens com o intuito de dificultar a estimação das probabilidades.” Os “filtros deveriam adotar técnicas mais flexíveis para comparar os termos na etapa de classificação. Métodos baseados em lógica fuzzy poderiam ser utilizados para permitir tal flexibilização.”

[Leite \(2015\)](#) construiu um modelo capaz de classificar, em categorias, os dados

capturados da rede social Twitter. Os dados coletados do Twitter passaram por um processamento de linguagem natural antes de ser gerado o modelo, a fim de retirar *stopwords*, acentos, pontuação e sufixos. O modelo obtido apresentou acurácia satisfatória e foi gerado utilizando a técnica de classificação Naive Bayes.

Os tweets coletados tiveram pré-processamento para remover todas as palavras que não possuem relevância para gerar o modelo. Inicialmente, foram descartados os tweets repetidos e os que não eram em português. A etapa mais demorada foi a categorização manual dos tweets.

O modelo demonstrou ser possível categorizar tweets em categorias pré-definidas com uma precisão bastante satisfatória utilizando o algoritmo de classificação Naive Bayes. Como trabalho futuro o autor se propõe a disponibilizar em um website os tweets categorizados automaticamente para o público geral, criando um portal de notícias utilizando os dados do Twitter como fonte.

[Oliveira \(2016\)](#) apresentou um identificador de emoções em textos para as seis emoções básicas (alegria, tristeza, surpresa, medo, raiva e desgosto) em manchetes de notícias escritas em português brasileiro. Utiliza uma abordagem de aprendizado de máquina baseada no classificador Naïve Bayes. O conjunto de dados foi composto de manchetes de notícias retiradas de jornais online. Estas notícias foram submetidas a um classificador Naive Bayes, obtendo uma taxa de acerto média de 59,5%.

Aplicou técnicas de processamento de linguagem natural e aprendizado de máquina no desenvolvimento do método e na realização dos experimentos. O método foi desenvolvido na linguagem Python utilizando a NLTK (*Natural Language ToolKit*) para o pré-processamento das manchetes de notícias. Como trabalhos futuros, o autor pretende incrementar o conjunto de manchetes de notícias e otimizar a classificação.

[Santos \(2017\)](#) analisou a execução de técnicas de Mineração de Dados no Twitter utilizando aplicação do processo KDD (*Knowledge Discovery in Databases*) e a execução das técnicas de *Data Mining K-Nearest Neighbor*, Máquina de Vetor de Suporte e Naives Bayes.

A realização da coleta dos dados é relativa ao, na época, presidente do Brasil ser absolvido do crime de corrupção passiva e a classificação das opiniões contidas nos elementos extraídos. Após a utilização desse procedimento, percebe-se que a técnica *K-Nearest Neighbor* apresentou melhores resultados pelas métricas de avaliações aplicadas.

Dentre as sugestões de continuidade do trabalho sugeridas pelos autores encontra-se o uso de outros filtros no momento da coleta de dados não se limitando a palavra ‘Temer’, mas outras palavras chaves relacionadas com o tema político e tratamento de ambiguidade das palavras.

[Carvalho et al. \(2018\)](#) comparou as técnicas de representação de texto, seleção de atributos e ferramentas de aprendizagem de máquina para se classificar notícias políticas coletadas em portais online sobre as eleições brasileiras de 2014 quanto ao seu sentimento (positivo, negativo ou neutro).

Avaliou os classificadores Naïve Bayes, Support Vector Machines e Regressão Logística (ou MaxEnt) com as técnicas de seleção de atributos Qui Quadrado, Categorical Proportional Difference e Categorical Probability Proportional Difference (CPPD). Os experimentos conduzidos visam otimização de representação vetorial do texto, seleção de atributos e do classificador para a base de dados proposta.

O autor constatou que, para essa aplicação, a combinação do método CPPD de seleção de atributos e o classificador Regressão Logística obtiveram o melhor desempenho sobre as outras técnicas e classificadores escolhidos por selecionarem os melhores atributos e organizá-los em ordem de relevância para uma determinada classe.

Como trabalhos futuros, o autor pretende coletar mais notícias da política brasileira não se resumindo ao âmbito das eleições. Aplicação e desenvolvimento de uma ferramenta colaborativa que permita às pessoas avaliarem a notícia enquanto lêem o artigo em questão.

[Monteiro e Nogueira \(2019\)](#) apresentaram um sistema que realiza a coleta e classificação de notícias, utilizando aprendizado de máquina para descobrir, classificar e armazenar textos de notícias falsas para posterior aplicação a etapa ETL de um Data Warehouse e um ambiente de consulta.

Para isso, foi criado um dataset e os métodos Regressão Logística, Naive Bayes e SVM foram avaliados. Por fim, o melhor algoritmo foi acoplado a um sistema web que realiza a classificação de *fake news* baseado em aprendizado automático.

Os autores objetivam avaliar outras características técnicas de pré-processamento, aumentar a base de treino, aplicar os novos resultados a interface web, e posteriormente, o acoplamento a ETL do Data Warehouse como seus trabalhos futuros.

Por fim, segue abaixo, de maneira resumida, na Tabela 2, a lista de palavras chave procuradas, as fontes dos trabalhos e a relação de similaridade destes trabalhos previamente citados na presente dissertação.

Tabela 2: Resumo dos trabalhos relacionados

Título	Autores	Ano	J/C	Termos de pesquisa	Relação
Aprendizado de máquina para o problema de sentiment classification	Oguri	2006	PUC-Rio	Naive Bayes	Avaliou o desempenho do classificador Naive Bayes para problemas de categorização de texto.
Redução de dimensionalidade aplicada a classificação de spams usando filtros bayesianos	Almeida e Yamakami	2011	Revista Brasileira de Computação	Naive Bayes	Trabalharam com classificadores de email, utilizando técnicas de filtragem através do algoritmo Naive Bayes.
Mineração de textos do twitter utilizando técnicas de classificação	Leite	2015	Universidade Federal do Ceará	Naive Bayes	Utilização de aprendizado de máquina, classificador Naive Bayes e trabalham com notícias em português brasileiro. Como trabalho futuro, propõe englobar sistemas web na solução.
Identificando emoções em manchetes de notícias escritas em português do Brasil utilizando Naive Bayes	Oliveira	2016	Universidade Federal do Ceará	Naive Bayes	Utilizou aprendizado de máquina com classificador Naive Bayes, além de uma ferramenta em comum com o uso do Python.
Análise de opiniões utilizando técnicas de mineração de dados em redes sociais. Estudo de caso: twitter.	Santos	2017	UniEVANGÉLICA	Naive Bayes	Trabalho relativamente recente que usa aprendizado de máquina com classificador Naive Bayes, além de trabalhar com notícias em português brasileiro.
Estudo Comparativo de Análise de Sentimento Aplicado à Notícias Políticas	Carvalho	2018	Universidade Federal do Maranhão	Naive Bayes	Utilizou aprendizado de máquina com o classificador Naive Bayes, além de trabalhar com notícias em português brasileiro.
Projeto de um Sistema Web a Classificação de Fake news	Monteiro	2019	16º Congresso da SBC	Naive Bayes	Apresentou um sistema que utiliza aprendizado de máquina, com o classificador Naive Bayes acoplados a um sistema web

Fonte: Própria.

4 METODOLOGIA

Neste capítulo serão apresentados os pontos de construção do sistema, relacionando a teoria previamente citada com suas aplicações na prática.

Na Seção 4.1, foram abordadas as ferramentas aqui utilizadas, como a linguagem de programação (Python), as linguagens de marcação (HTML e CSS), os *frameworks* (Flask e Sklearn) para a construção do sistema. Mais profundamente nesta Seção, são trabalhados os filtros de dados utilizados, com exemplos de funcionamento e as métricas de resposta do algoritmo, como o relatório da classificação, a matriz de confusão e as 10 palavras mais comuns em notícias verdadeiras e falsas.

Na Seção 4.2, encontram-se as relações em como foram utilizadas na prática os passos do *framework* de Fayyad, nos passos: limpeza, integração e seleção dos dados; transformação dos dados; *Data mining* e avaliação de padrões; e apresentação do conhecimento. Nesta Seção, está incluída a classificação que escolhemos para tratar boato a ambiguidade bibliográfica entre boato e notícia falsa.

Na Seção 4.3, foram explicados, dos filtros testados, os que tiveram influência positiva no aprendizado da máquina, aumentando a porcentagem de acerto do algoritmo, como, a tokenização, a transformação para letras minúsculas, as remoções de sinais de pontuação e números e a *Bag-of-Words*. Também é explicitado que embora a remoção de **stopwords** não influencie positivamente na precisão, ela permite a remoção de informações úteis das 10 palavras mais encontradas em notícias verdadeiras e falsas, além das alterações feitas no uso deste filtro.

Por fim, na Seção 4.4, é apresentada a interface de usuário do sistema, como ela funciona e quais informações a mesma fornece, de maneira a descrever as diferenças de quando a notícia é identificada como verdadeira ou como falsa, além dos dados estatísticos adicionais, das 10 palavras mais utilizadas em notícias e *fakenews* e da matriz de confusão resultante do treinamento.

4.1 Ferramentas Utilizadas

Esta dissertação utiliza 3 tecnologias principais, **Python**¹, **Flask**² e **Bootstrap**³. Através da linguagem de programação Python foi utilizada a biblioteca “scikit-learn” (sklearn) que, dentre as várias funções que se propõe estão a classificação, a regressão e a clusterização. Utilizamos aqui somente a primeira funcionalidade visto o objetivo principal do trabalho.

Com o Python, foi realizado o algoritmo para uso da biblioteca “sklearn”, que recebe um corpus e o classifica baseado em um arquivo no formato csv previamente populado com notícias verdadeiras e falsas. Baseado neste arquivo, a biblioteca treina um “robô” que aprende através da mineração de dados (Fayyad et al., 1996) a classificar estas notícias.

Através do uso do framework Flask, foi permitido a este algoritmo Python estruturar-se como uma página *web*, semelhante ao uso da linguagem PHP para realizar a estrutura back-end da página. Além disso, evita retrabalho ao reaproveitar código front-end para diversas páginas, evitando acréscimo de linhas código Bootstrap repetidas e desnecessárias.

Finalmente, para estruturar a interface em que o usuário interage, foi escolhido o framework Bootstrap, ferramenta para desenvolvimento front-end mais popular da atualidade (Scudero, 2018), por sua coleção de funções que facilitam a construção de uma página através do uso das tecnologias HTML e CSS.

4.1.1 Separação e filtros de dados

Após ler o arquivo csv em código python, a primeira decisão é separar a quantidade total de dados entre treinamento e teste. Valores padrões se constituem, normalmente, em um balanço 70-30, 80-20 ou 90-10. Para esta dissertação foi optado o ultimo caso, em que 90% dos dados foram escolhidos para treinamento e os 10% restantes para teste, de maneira que esta seleção sempre embaralhada (função *shuffle*).

Dentre os vários processos para a limpeza de dados, as ferramentas utilizadas nesta dissertação foram a tokenização (Torres et al., 2012); transformação em letras minúsculas (normalização) e remoção de sinais de pontuação e números (Rodríguez e Bezerra, 2020); a *Bag-of-Words* (Hartmann, 2016) e a remoção de *stopwords* (Espina e Rino, 2001 apud dos Santos Castro, 2010).

O primeiro filtro é uma função disponível pela própria linguagem *Python*, não ne-

¹<https://www.python.org/>

²<https://flask.palletsprojects.com/en/1.1.x/>

³<https://getbootstrap.com/>

cessitando de nenhum *framework* adicional, a normalização, que apenas atualiza letras maiúsculas de uma sentença e as transforma em letras minúsculas. Isto se deve, pois para a máquina a palavra “Olá” é diferente da palavra “olá”.

Como segundo passo, foi realizado uma chamada de função para tokenizar, processo que segundo [Torres et al. \(2012\)](#), “examina um texto não estruturado e identifica suas características importantes separando o texto em tokens (palavras)”.

Após a tokenização, chegamos a fase de remoção de *stopwords*, que segundo [Espina e Rino \(2001 apud dos Santos Castro, 2010\)](#), são palavras que não têm “significado relevante ao texto, como artigos, preposições e outros, e que possam ser removidos sem prejuízo ao conteúdo textual”. Já para [de Oliveira et al. \(2007\)](#), outra característica marcante das *stopwords* é seu alto índice de incidência.

Embora esta remoção diminua a precisão em nosso algoritmo, este filtro possibilita e retirada de informações uteis em uma das saídas do algoritmo, que entrega as 10 palavras mais influentes em notícias verdadeiras e falsas.

Diferente dos seres humanos, as máquinas têm uma maior facilidade de aprendizado quando processam apenas os itens mais valiosos de uma sentença, sinais de pontuação e números, agregam muito pouco valor à sentença, assim sendo removidos. Por fim, seguem abaixo, na Tabela 3, exemplos práticos dos filtros utilizados até o momento.

Tabela 3: Exemplos de aplicações de filtro em frase

Frase original	“Vacinação garantiu queda de mortes em 2022, segundo especialistas.”
Normalização	“vacinação garantiu queda de mortes em 2022, segundo especialistas.”
Tokenização	'vacinação' 'garantiu' 'queda' 'de' 'mortes' 'em' '2022' ',' 'segundo' 'especialistas' '.'
Remoção de stopwords	'vacinação' 'garantiu' 'queda' 'mortes' '2022' ',' 'segundo' 'especialistas' '.'
Remoção de sinais de pontuação	'vacinação' 'garantiu' 'queda' 'mortes' '2022' 'segundo' 'especialistas'
Remoção de números	'vacinação' 'garantiu' 'queda' 'mortes' 'segundo' 'especialistas'

Fonte: Própria.

Como último passo do processo de filtragem de dados, é utilizada a técnica chamada *Bag-of-Words*, que segundo [Hartmann \(2016\)](#), “calculam a similaridade lexical, ou n-grams” e “conseguem capturar a semântica contida nas sequências de n palavras”.

Para exemplificar a técnica *Bag-of-Words*, tomaremos uma lista de duas entradas como exemplo:

1. “Hoje o dia está lindo.”;
2. “Hoje a noite está maravilhosa.”.

Após a aplicação dos filtros da Tabela 3, temos:

1. “hoje” “dia” “lindo”;
2. “hoje” “noite” “maravilhosa”.

A técnica de *Bag-of-Words*, realiza uma matriz de cálculo para contar quantas vezes cada palavra se repete e manda a saída da Tabela 4 para o algoritmo de classificação.

Tabela 4: Exemplo de resultado de saída da função *Bag-of-Words*

	hoje	dia	lindo	noite	maravilhosa
1	1	1	1	0	0
2	1	0	0	1	1

Fonte: Própria.

Este é um exemplo básico, na prática, o que irá ser comparado, são os dados do arquivo csv com a entrada do usuário no sistema. Mas, assim, podemos entender o princípio de funcionamento da técnica *Bag-of-Words* de maneira isolada.

4.1.2 Métricas das respostas do algoritmo

Como primeira métrica, são aproveitados os dados fornecidos pelas *features* separadas na *bag of words*, vista na Seção 4.1.1, assim, é realizada a contagem das 10 palavras mais utilizadas em notícias verdadeiras e falsas, gerando uma saída com a palavra em si e sua porcentagem de ocorrência.

Dentre todos os retornos da função *classification report* (Pedregosa et al., 2011), daremos atenção somente aos descritos abaixo, pois são os valores tipicamente levados em consideração quando o banco de dados de treinamento é balanceado, isto é, no caso desta dissertação, um número igual de notícias verdadeiras e falsas dentro do arquivo csv.

Precision: É a proporção $\frac{tp}{(tp+fp)}$ onde *tp* verdadeiros positivos e *fp* o número de falsos positivos. É intuitivamente a habilidade do classificador de não classificar uma amostra negativo como positivo.

Recall: É a proporção $\frac{tp}{(tp+fn)}$ onde tp é o número de verdadeiros positivos e fn o número de falsos negativos. É intuitivamente a habilidade do classificador de achar todas as amostras positivas. O melhor valor é 1 e o pior é 0.

Support: Número de verdadeiras ocorrências para cada label.

Macro avg: Calcula as métricas para cada label, e encontra sua média. Não leva em consideração falta de equilíbrio nas labels.

A matriz de confusão (Monard e Baranauskas, 2003) C , tem $C_{i,j}$ de maneira que i é o grupo de observações conhecidas j as predições, então a contagem de verdadeiros negativos é $C_{0,0}$, falso negativo é $C_{1,0}$, verdadeiro positivo é $C_{1,1}$ e falso positivo é $C_{0,1}$, como pode ser observado na Tabela 5, abaixo.

Tabela 5: Tabela exemplo de matriz de confusão

Matriz de confusão		Previsto pelo Modelo	
		Falso (N)	Verdadeiro (P)
Situação real	Falso (N)	Verdadeiro Negativo (TN)	Falso Positivo (FP)
	Verdadeiro (P)	Falso Positivo (FN)	Verdadeiro Negativo (TP)

Fonte: Própria.

4.2 Aplicação do framework de Fayyad

Nesta dissertação, foi utilizada a metodologia proposta por Fayyad et al. (1996), como mostrado na Figura 2. A seguir, para cada etapa, apresentamos o que foi desenvolvido neste trabalho.

- (a) **Limpeza, integração e seleção dos dados:** Foram utilizados diversos sites (G1⁴, UOL Notícias⁵, Fake⁶, Agência Lupa⁷ e E-farsas⁸) de fontes confiáveis de notícias, que mostram fatos e inverdades comprovando o porquê da mentira. Assim, juntamos as notícias correlacionadas com a proposta, de diversas fontes, de maneira manual, sem necessitar de descarte;
- (b) **Transformação dos dados, .csv:** Nesta etapa houveram algumas transformações, visto que normalmente as notícias verdadeiras se apresentavam no formato de texto,

⁴<https://g1.globo.com/>

⁵<https://noticias.uol.com.br/>

⁶<https://g1.globo.com/fato-ou-fake/>

⁷<https://piaui.folha.uol.com.br/lupa/>

⁸<https://www.e-farsas.com/>


e as falsas em formato de imagem ou vídeo. Dito isto, foi necessário assistir os vídeos e observar as imagens para informar o que ocorria em ambos, para que os dois tipos de notícia apresentem-se da mesma maneira, quando este serviço já não havia sido prestado pelo próprio jornalista da notícia, e posteriormente adicionar em um arquivo .csv, que separa cada linha com o dicionário notícia e sua classificação, separando-os por vírgula.

- (c) **Transformação dos dados:** Foram utilizadas ferramentas de processamento de dados que influenciaram positivamente no aprendizado da máquina, em código Python. Ferramentas como a Normalização, a Tokenização, a remoção de *stopwords*, as remoções de sinais de pontuação e números e a *Bag-of-Words* foram implementadas neste passo, a fim de facilitar o aprendizado da máquina aumentando sua probabilidade de acerto no treinamento e predição de novos dados. Embora a remoção de *stopwords* reduza a precisão do algoritmo, utilizamos este filtro para proporcionar a métrica de 10 palavras mais utilizadas em determinado tipo de notícia.
- (d) **Data mining e avaliação de padrões:** Após concluídas as etapas anteriores, foi executado o algoritmo alimentado pelas notícias. Assim, após seu processamento, foi realizado seu treinamento para aprender com os padrões disponíveis no banco de dados do arquivo .csv;
- (e) **Apresentação do conhecimento:** Técnicas de visualização e representação de conhecimento são a saída final do programa. Assim é possível acessar a taxa de acerto e erro do aprendizado a partir dos labels utilizados (verdadeiro e falso) para classificar as notícias.

Como visto nas Seções 1 e 2, alguns autores classificam notícias falsas e boatos como distintos, outros os englobam em uma classificação genérica chamada "clickbait" e outros exemplificam *fake news* como boatos, assim, juntando ambos em uma mesma classificação.

Por esta dissertação tratar de *fake news* com o potencial de afetar a saúde pública nacional, utilizaremos a seguinte lógica de classificação de informações: Se a notícia já foi comprovada, ela será classificada como verdadeira, por exemplo, a eficácia das vacinas. Se a notícia for falsa, será classificada como *fake news*, por exemplo, o uso de hidroxicroquina para tratar o coronavírus. E por último, se a notícia tratar-se de um boato, também será considerada como uma *fake news*, como por exemplo, chá de hortelã pode combater o coronavírus.

Figura 2: O processo de KDD



Fonte: Adaptado de [Fayyad et al. \(1996\)](#).

4.3 Processamento de dados

Dentre as várias formas de limpeza de dados conhecidas, para esta dissertação, foram utilizadas a Normalização, a Tokenização, as remoções de sinais de pontuação e números e a *Bag-of-Words*. Isto se deve por alguns motivos, como a falta de necessidade de empregar técnicas de pré-processamento, como correção ortográfica e remoção/tratamento de dados faltantes, visto que todas as notícias foram removidas manualmente, de sites de verificação de notícias, onde os dados já se apresentavam de maneira correta.

Como caso especial temos a remoção de *stopwords*, que não foi utilizada de maneira pura como proposto pelo framework *sklearn*. Por trabalhar-se com manchetes de notícias em português brasileiro, a tradução de *stopwords* se trata de uma conversão direta (e não adaptada) ao português, como por exemplo, a palavra “para” que no inglês pode referenciar o verbo “stop” ou a preposição “to”. Onde, em inglês, apenas a preposição “para” é removida do texto, mas em português, o verbo “parar” também é removido.

Para evitar-se casos como este, onde a palavra descrita como uma *stopwords* poderá ou não ser uma de fato, por apresentar mais de um uso na língua, foram realizadas algumas adaptações na lista de *stopwords*, para assim poder-se utilizar este filtro:

- Remoção da palavra ‘para’;
 - Como visto anteriormente, a preposição e o verbo têm significados distintos.

- Remoção da palavra 'são';
 - Embora o verbo seja uma *stopword* em ambas as línguas, expressões como 'O estado de São Paulo' foram comprometidas.
- Remoção da palavra 'pelo';
 - A preposição e o substantivo têm significados distintos.
- Remoção da palavra 'nossa';
 - A interjeição e o pronome têm significados distintos.
- Adição da palavra 'é';
 - Utilizada da mesma maneira que 'ser' e 'estar', em que as mesmas também são *stopwords*.
- Adição da palavra 'à';
 - Adicionada por não expressar informação o suficiente por si só. Uso equivalente á expressão "para a" em que ambos são *stopwords*.

Das outras maneiras de filtro, características do processamento de dados, como a remoção de sinais acentuação, lematização e radicalização não puderam ser incluídas, devido a sua utilização diminuir a precisão do algoritmo de classificação textual.

Como exemplo, mesmo os ditos melhores *frameworks* de lematização, com taxa de precisão de 96% e 97% de precisão na língua inglesa, *stanza* e *spacy* respectivamente, apresentam certa dificuldade em transformar palavras que não estejam em inglês, como por exemplo, a lematização da palavra "filhas", de maneira correta, tem de ter como resultado da função lematizadora a saída "filho", porém em português, diferente do inglês, em que as palavras têm gênero, a resultante da função retorna "filha", destruindo o princípio da técnica.

4.4 Interface do sistema

Depois da implementação do algoritmo de classificação, foi desenvolvido um site simples utilizando o *framework web Flask*, Figura 3, onde há um *input* de texto, que o usuário irá digitar ou colar o título, ou preferencialmente, a manchete da notícia e clicar no botão verificar. Após este evento, aparecerá em baixo do *input*, a manchete da notícia e o status de classificação da notícia, se for verdadeira, aparecerá um aviso num balão em verde dizendo "verdadeira", se for falsa será um balão em vermelho dizendo "Falsa",

como pode ser visto nas Figuras 4 e 5. Logo abaixo, há um botão escrito "Detalhes Estatísticos", ao clicar nele, serão mostradas a taxa de precisão (score) do treinamento do algoritmo e uma tabela com os seguintes dados: *precision*, *recall*, *support*, para verdadeiro e falso e a média macro, Figuras 6 e 7.

Figura 3: Site News Check



Fonte: Própria.

O .csv, atualmente está com total de **500** notícias, **250** verdadeiras e **250** falsas, as notícias verdadeiras foram retiradas de sites de notícias populares como o G1 e o UOL Notícias, para as notícias falsas foram utilizadas os sites Fato ou Fake, Agência Lupa e E-farsas cujo objetivo é desmentir *fake news* para alertar seus usuários.

Como visto na Seção 2.1, a maioria dos usuários não se dedicam a ler a notícia completa, em que, na maioria dos casos, a manchete da notícia é tudo o que é lido no material. Este sistema diferencia-se por tratar justamente da parte de maior interesse para estes tipos de leitores, focando seu treinamento, teste e posterior **juízo automático** de manchetes de notícias em português brasileiro.

Figura 4: Notícia verdadeira




Fonte: Própria.

Figura 5: Notícia falsa




Fonte: Própria.

Figura 6: Notícia verdadeira com os detalhes estatísticos



Fonte: Própria.

Figura 7: Notícia falsa com os detalhes estatísticos



Fonte: Própria.

5 RESULTADOS E DISCUSSÃO

5.1 Resultados obtidos

O uso da biblioteca *sklearn* assume um valor aleatório para o aprendizado do algoritmo, e embora em uma máquina seja possível travar este valor para sempre termos a precisão mais alta, quando for mudado o algoritmo de máquina, por exemplo, enviando-o a um servidor, o número aleatório que gera a maior precisão muda. Desta maneira realizamos os testes sem mexer nesta feature padrão. Justificando as diferenças nos resultados das execuções.

Outra característica padrão é o aprendizado isolado do algoritmo. Cada execução, não leva em consideração as execuções passadas e futuras, focando apenas no próprio escopo. Assim a segunda execução não carrega aprendizado da primeira.

Fizemos uma breve comparação de scores do *sklearn* e do *textblob*, utilizando os mesmos filtros, e obtivemos um score de 68% do segundo framework. Como mesmo com o *sklearn* atingindo um score de 58%, a taxa de acerto de classificação de notícias falsas se manteve em 72%, decidimos utilizar esta ferramenta, pois a classificação de notícias falsas, teoricamente, é mais importante que as de notícias verdadeiras, pelo motivo das verdadeiras já virem de uma fonte confiável.

Em nossos testes realizados, o framework *sklearn* através do classificador *Naive Bayes* atingiu de 58% a 76% de precisão, com média e moda de 68%, em 10 execuções do algoritmo, como podem ser vistos nas Tabelas 6, 7 e 8. Focamos nas porcentagens de *precision* apenas, pelo fato do nosso .csv ser balanceado, com 250 notícias verdadeiras e 250 falsas.

No resultado mais baixo, Tabela 8, ocorreu algo interessante, de maneira que, as notícias falsas foram classificadas com 72% de precisão e as verdadeiras com 44%. Isto é notório, pois, espera-se que o usuário testador da notícia, tenha em mãos uma notícia falsa de um fonte duvidosa. Se este caso for verdadeiro, mesmo com a baixa precisão geral do programa, ainda sim, ele terá a chance de 72%, de ter sua notícia classificada de maneira

correta como falsa.

Tabela 6: Melhor Caso - Score 76%.

#	Precision	Recall	Support
Falso	0.81	0.59	22
Verdadeiro	0.74	0.89	28
Macro AVG	0.77	0.74	50

Fonte: Própria.

Tabela 7: Caso Médio - Score 68%.

#	Precision	Recall	Support
Falso	0.75	0.58	26
Verdadeiro	0.63	0.79	24
Macro AVG	0.69	0.68	50

Fonte: Própria.

Tabela 8: Pior Caso - Score 58%.

#	Precision	Recall	Support
Falso	0.72	0.56	32
Verdadeiro	0.44	0.61	18
Macro AVG	0.58	0.59	50

Fonte: Própria.

5.2 Limitações do estudo

Por utilizarmos o classificador *Naive Bayes*, o mais indicado para classificação textual, que funciona avaliando palavra a palavra sem considerar seu contexto e pela escolha dos assuntos: Coronavírus, vacina e algumas notícias não relacionadas gerais somente em português, nos deparamos com alguns problemas.

O primeiro deles foi a baixa quantidade (relativamente falando) de notícias sobre o tema escolhido. Dos sites confiáveis de onde foram extraídas as notícias verdadeiras e falsas (verificadas) foi coletada uma quantidade baixa de dados, na casa das centenas,

valor considerado ínfimo quando trata-se de aprendizado de máquina. Isto se dá por duas razões: A primeira é o quão recente é o assunto, de maneira que até a construção deste artigo, o tema coronavírus têm menos de 3 anos de circulação. A segunda foi a opção de trabalhar somente com notícias em português, assim diferenciando-o.

O segundo problema foram os dados, as notícias em si. Algumas notícias tiveram que ser levemente alteradas visto que a maioria das *fake news* se apresentavam em vídeo ou foto, e as notícias verdadeiras, em texto. Desta forma, notícias falsas como “Joãozinho é ladrão, veja o que ele fez no vídeo abaixo” induziram a máquina a aprender que todas as notícias que continham a palavra “vídeo” eram falsas. Desta maneira ao invés de usarmos a notícia que divulgava o vídeo ou imagem, recolhemos a descrição da ação ocorrida no vídeo ou imagem em si, ou caso não houvesse, foi realizada esta transcrição.

Como consequência, há a possibilidade de presença de subjetividade no resultado final da conversão da notícia em vídeo para texto e imagem para texto, tanto pelo jornalista quem redigiu a notícia quanto pela autora desta dissertação.

O terceiro impeditivo está diretamente relacionado com o anterior. Na tabela de dados desenvolvida e utilizada para esta dissertação, as notícias foram classificadas entre falsa ou verdadeira. Porém, para aumentar a precisão do modelo, precisamos adicionar ou criar novas classes, mesmo que à primeira vista pareçam inúteis, como quantidade de palavras, de caracteres ou de linhas. A grande questão é que tivemos que alterar levemente algumas notícias, como no caso de descrever a ação de um vídeo, tornando injusta e imprecisa este tipo de contagem.

Repetição de notícias com o mesmo nome próprio também tiveram que ser ignoradas e removidas da base de dados, pois a máquina não diferencia nomes próprios do resto das palavras. Como por exemplo as *fake news*: “João da Silva roubou uma laranja” e “João Ferreira plantou uvas”, fazem com que o robô aprenda a identificar a palavra “João” em qualquer frase classificando-a como *fake news*, assim, quando aparece em uma terceira notícia, esta notícia provavelmente é uma *fake news*. Isto se deve também ao uso do classificador *Naive Bayes*, de maneira que para a máquina, o primeiro e o segundo João são a mesma entidade, visto que ignora contexto não associando o nome próprio ao sobrenome. Desta maneira nos mantemos no tema coronavírus mais assiduamente.

A quinta questão é a repetição de notícias, foi muito comum encontrar uma mesma notícia escrita de maneira muito similar em portais diferentes, o que agrava o problema é a proposta de trabalhar com manchetes notícias, que por terem tamanho menor comparadas ao texto, apresentavam ainda menos variação.

6 CONCLUSÃO

Como já descrito na Seção 1, as *fake news* não são um tópico recente, e já era cotidiana sua circulação até mesmo no século XVII. Devido à popularização da internet com cada vez mais pessoas conectadas, o problema tomou proporções intensas nos anos de 2015 e 2016 por conta das eleições norte-americanas e agora nos anos de 2019 a 2022, por conta da pandemia global causada pelo Covid-19 e as vacinas para combatê-la.

Através das pesquisas realizadas, podemos perceber que as *fake news* seduzem, pois, contêm uma manchete atrativa, atacam na crença do leitor, justamente informando o que ele quer ouvir, tem um texto simples que as pessoas leigas acabam conseguindo entender, ilustrações muito chamativas, além de atacarem necessidades básicas, como por exemplo, notícias sobre ações falsas do governo, como a doação de gás de cozinha, através do vale-gás social, programa que na data de confecção da pesquisa desta dissertação, não existe, para quem se inscrever em determinado link. Os leitores que se encontram em vulnerabilidade socioeconômica, acabam clicando sem ao menos pesquisar se é verdade.

As notícias verdadeiras, em sua grande maioria, apresentam textos extensos que cansam o leitor médio que acaba perdendo a vontade de continuar a leitura com textos com palavras muito rebuscadas, além de poucas ilustrações para atrair novamente a atenção do usuário à leitura. Outro fator excludente, é que parte das notícias verdadeiras, exigiam algum tipo de cadastro pago para acessar o conteúdo.

Na implementação aqui proposta, o problema da notícia escrita de maneira muito rebuscada, manteve-se, apresentando-se de maneira levemente diferente. Para o sistema *News Check*, uma frase relativamente formal caracteriza-se, normalmente, como verdadeira e uma frase relativamente informal (incluindo erros ortográficos), como falsa, a menos que os assuntos já estejam previstos no banco de dados nos temas coronavírus e vacina do coronavírus.

Como visto na Seção 2.1, apenas 41% dos links são clicados, de maneira que apenas 60% de seus leitores conseguem identificar uma manipulação. Desta maneira podemos entender que apenas 25% das notícias são identificadas como falsas por seus leitores

($0.41 * 0.60 = 0.246$). Dito isto, mesmo no pior caso, com o score de 58%, o *News Check* consegue identificar 72% das notícias falsas para seus usuários, valor muito próximo ao triplo da capacidade humana percebida de 74% ($0.246 * 3$).

Na Seção 2.2, podemos perceber que o público idoso é 7 vezes mais propenso a espalhar notícias falsas do que o público jovem, por sua baixa familiaridade com a tecnologia. O que pode ser justificado de maneira mais efetiva através do viés cognitivo, o viés de confirmação, o efeito propagando e a cascata de disponibilidade no caso do exemplo dado: da crença que o "chazinho da avó" pode resolver problemas relacionados ao covid-19.

Este exemplo pode ainda ser extrapolado, por conta da dissonância cognitiva, que por motivos de crenças, o cidadão pode arriscar a vida de todos a sua volta, por exemplo, quando alguma informação é falsamente tratada como verdadeira por uma figura respeitada por sua patente.

Soluções relativamente rápidas e de fácil uso como o algoritmo aqui proposto, tornam-se interessantes a medida que cada vez mais o usuário tem como fonte de informação as redes sociais como o Facebook, que alcança uma margem de 2,60 bilhões de usuários ativos mensalmente, com quase 1 hora de uso por dia ou como o Twitter, com 330 milhões de usuários ativos com 3,39 minutos de uso médio. A dedicação a estas redes sociais se caracteriza por períodos pequenos e diferente da leitura de um jornal em que o leitor se propõe a parar para ler todo o material. Isto nos leva a crer na falta de paciência ou interesse do leitor para verificar notícias manualmente, assim preferindo acreditar na primeira mensagem que viu.

Por fim, o uso de deste tipo de algoritmo exige cuidados, visto que por ser um modelo probabilístico, pode apresentar resultados distintos para uma mesma manchete testada. Logo o sistema comporta-se como uma ferramenta de auxílio ao público mais vulnerável digitalmente e não substitui, em nenhuma hipótese, a necessidade de atenção à leitura e o desenvolvimento de senso crítico do usuário.

6.1 Contribuições da dissertação

Como principais contribuições da dissertação, podemos observar:

- A pesquisa sobre a falta de habilidade do leitor de identificar notícias falsas, além de possíveis justificativas para tal;
- A observação que a internet amplifica e altera, dando um perfil próprio, para problemas sociais como a circulação de *fake news* e possíveis soluções parciais em proporção semelhante;

- O desenvolvimento de um verificador de manchetes de notícias adaptado à língua e cultura brasileira;

6.2 Trabalhos Futuros

Visto que as notícias aqui colhidas tratam-se de um tema relativamente novo, na qual os principais portais de verificação de notícias analisaram coletivamente um número baixo de matérias sobre a Covid-19, assim afetando o treinamento da máquina pela baixa quantidade de dados. O principal objetivo futuro é popular o banco de dados com mais notícias que realmente circulam no mundo real, tanto verdadeiras quanto falsas verificadas alcançando assim, a maior marca possível, superando as 500 notícias ao total, 250 verdadeiras e 250 falsas atuais.

Além de popular com mais notícias, outros dados podem ser adicionados, como a origem da notícia no arquivo csv e o gênero dos propagadores de *fakenews*. Para assim ser possível inferir informações extras sobre a circulação de notícias falsas.

Outros trabalhos futuros também podem ser sugeridos, como a perda do foco no tema Covid-19, ampliando-se, porém, ainda assim, coletando os dados de portais de verificação de notícias. Coleta de notícias de outros portais aqui utilizados e alterações na interface *web* do sistema, a fim de deixá-lo mais próximo ao padrão conhecido da internet da década de 2020.

REFERÊNCIAS

- [1] ALLCOTT, Hunt, GENTZKOW, Matthew. We define “fake news” to be news articles that are intentionally and verifiably false, and could mislead readers. **Journal of Economic Perspectives**, [S. l.], v. 31, p. 211–236, 2017.
- [2] ALMEIDA, Tiago A., YAMAKAMI, Akebo. Redução de dimensionalidade aplicada na classificação de spams usando filtros bayesianos. **Revista Brasileira de Computação Aplicada**, Passo Fundo, v. 3, n. 1, p. 16–29, mar. 2011.
- [3] ALMEIDA, Thais Gomes de et al. **Liardetector**: a linguistic-based approach for identifying fake news. 2019. Tese (Mestrado em Informática) - Curso de Informática - Universidade Federal do Amazonas, Manaus, 2019.
- [4] AMARAL, Fernando. **Introdução à ciência de dados: mineração de dados e big data**. Rio de Janeiro: Alta Books Editora, 2016.
- [5] BAKIR, Bangor, MCSTRAY, Andrew. Fake News and The Economy of Emotions: Problems, causes, solutions. **Digital Journalism**, United Kingdom, v. 6, n. 2, p. 154–175, 2018.
- [6] BAPTISTA, João. Ethos, pathos e logos. Análise comparativa do processo persuasivo das (fake) news. **Eikon**, Universidade da Beira Interior Portugal, v. 1, n. 7, 2020.
- [7] BENSON, Buster. Cognitive bias cheat sheet. **Better Humans**, 2016. Disponível em: <https://medium.com/better-humans/cognitive-bias-cheat-sheet>. Acesso em: 21 dez. 2020
- [8] BRANCO, Sérgio. Fake News e os Caminhos para Fora da Bolha. **Interesse Nacional**, São Paulo, v. 10, n. 38, p. 51–61, 2017.
- [9] CAMILO, Cássio Oliveira, DA SILVA, João Carlos. Mineração de dados: Conceitos, tarefas, métodos e ferramentas. **Universidade Federal de Goiás (UFG)**, Goiás, v. 1, n. 1, p. 1–29, 2009.

- [10] CARINHATO, Cristiane et al. **O funcionamento discursivo das fake news: a criação do produto midiático**. 2019. Tese (Especialização em Linguagem e Educação a Distância) - Curso de Pós-Graduação em Linguagens e Educação a Distância - Universidade Federal de Santa Catarina, Videira, SC, 2019.
- [11] CARVALHO, Caio Magno Aguiar de et al. **Estudo comparativo de análise de sentimentos aplicado à notícias públicas**. 2018. Tese (Mestrado em Engenharia Elétrica) – Curso de Pós-graduação em Engenharia Elétrica – Universidade Federal do Maranhão, Maranhão, 2018.
- [12] COSTA, Evandro et al. Mineração de dados educacionais: conceitos, técnicas, ferramentas e aplicações. **Jornada de Atualização em Informática na Educação (JAIE 2012)**, [S. l.], p. 1–29, 2012.
- [13] DA COSTA CÔRTEZ, Sérgio, PORCARO, Rosa Maria, LIFSCHITZ, Sérgio. Mineração de Dados – Funcionalidades, Técnicas e Abordagens. **PUC-RIO**, Rio de Janeiro, p. 1–34, 2002.
- [14] DE AMO, Sandra. **Técnicas de Mineração de Dados**. In: **Jornada de Atualização em Informática (JAI)**, n° 23, 2004, [S. l.]. Belo Horizonte: Universidade Federal de Uberlândia, 2004, p. 26.
- [15] DE OLIVEIRA, Altamar Sales et al. O USO DE SOFTWARE PARA A MINERAÇÃO DE TEXTOS. **Boletim Técnico da Faculdade de Tecnologia de São Paulo**, São Paulo, n° 23, [n. p.], 2007.
- [16] DE OLIVEIRA, Gabriela Silva, PEREIRA, Silvio do Lago. IMPLEMENTAÇÃO DE CLASSIFICAÇÃO BAYESIANA. **Boletim Técnico da Faculdade de Tecnologia de São Paulo**, São Paulo, n° 43, [n. p.], 2017.
- [17] DE SOUSA JÚNIOR, João Henriques et al. Da Desinformação ao Caos: uma análise das Fake News frente à pandemia do Coronavírus (COVID-19) no Brasil. **Cadernos de Prospecção**, [S. l.], v. 13, n. 2, p. 331, 2020.
- [18] DELMAZO, Caroline, VALENTE, Jonas C.L. Fake news nas redes sociais online: propagação e reações à desinformação em busca de cliques. **Media & Jornalismo**, [S. l.], v. 18, n. 32, p. 155–169, 2018.
- [19] DEWEY, Caitlin. 6 in 10 of you will share this link without reading it, a new, depressing study says. **Washinton Post**, 16 jun. 2016. Disponível em: <http://www.washingtonpost.com/news/the-intersect/wp/2016/06/16/six-in-10-of-you-will-share-this-link-without-reading-it-according-to-a-new-and-depressing-study>. Acesso em: 18 nov. 2020.

- [20] DOS SANTOS CASTRO, Flaviana. MINERAÇÃO DE TEXTOS NA SAÚDE POR MEIO DA UTILIZAÇÃO DA FERRAMENTA EUREKHA. **Revista de Iniciação Científica**, Criciúma, Santa Catarina, v. 7, n. 1, [n. p.], 2010.
- [21] ESTUDO identifica principais fake news relacionadas à Covid-19. **Portal Fiocruz**, 21 mai. 2020. Disponível em: <https://portal.fiocruz.br/noticia/estudo-identifica-principais-fake-news-relacionadas-covid-19>. Acesso em: 06 jun 2020.
- [22] FAKE news: 40% das pessoas não conseguem detectar imagens manipuladas, diz estudo. **G1**, 17 jul. 2017. Disponível em: <https://g1.globo.com/ciencia-e-saude/noticia/fake-news-40-das-pessoas-nao-conseguem-detectar-imagens-manipuladas-diz-estudo.ghtml>. Acesso em: 18 nov. 2020.
- [23] FAYYAD, Usama, PIATETSKY-SHAPIRO, Gregory, SMYTH, Padhraic. From data mining to knowledge discovery in databases. **AI magazine**, [S. l.], v. 17, n. 3, p. 37, 1996.
- [24] GUESS, Andrew, NYHAN, Brendan, REIFLER, Jason. Selective exposure to misinformation: Evidence from the consumption of fake news during the 2016 US presidential campaign. **European Research Council**, [S. l.], v. 9, n. 3, p. 4, 2018;
- [25] HARTMANN, Nathan Siegle. Solo Queue at ASSIN: Combinando Abordagens Tradicionais e Emergentes. **Linguamática**, [S. l.], v. 8, n. 2, p. 59–64, 2016.
- [26] IKONOMAKIS, M., KOTSIANTIS, Sotiris, TAMPAKAS, V. Text classification using machine learning techniques. **WSEAS transactions on computers**, Grécia, v. 4, n. 8, p. 966–974, 2005.
- [27] KEMP, Simon. DIGITAL 2020: 3.8 BILLION PEOPLE USE SOCIAL MEDIA. **We are Social**, 30 jan. 2020. Disponível em: <https://wearesocial.com/blog/2020/01/digital-2020-3-8-billion-people-use-social-media>. Acesso em: 20 dez. 2020.
- [28] LIST of all Cognitive Biases. **Cognitive Bias of the Day**, 2018. Disponível em: <http://cognitivebiasoftheday.com/list>. Acesso em: 21 de dezembro de 2020.
- [29] LEITE, João Lucas Araújo. **Mineração de textos do twitter utilizando técnicas de classificação**. 2015. Trabalho de conclusão de curso (Graduação em Engenharia de Software) - Curso Bacharelado em Engenharia de Software - Universidade Federal do Ceará, Quixadá, Ceará, 2015.
- [30] LIN, Ying. 10 TWITTER STATISTICS EVERY MARKETER SHOULD KNOW IN 2021 [INFOGRAPHIC]. **Oberlo**, 2020. Disponível em: <https://www.oberlo.com/blog/twitter-statistics>. Acesso em: 20 dez. 2020.

- [31] MAIA, Roberto Bomeny. **Detecção da Intrusão Utilizando Classificação Bayesiana**. 2005. Tese (Mestrado em Engenharia Elétrica) - Curso de Pós-Graduação de Engenharia - Universidade Federal do Rio de Janeiro, Rio de Janeiro, 2005.
- [32] MOHSIN, Maryam. 10 FACEBOOK STATISTICS EVERY MARKETER SHOULD KNOW IN 2021 [INFOGRAPHIC]. **Oberlo**, 2020. Disponível em: <https://www.oberlo.com/blog/facebook-statistics>. Acesso em: 20 dez. 2020.
- [33] MONARD, Maria Carolina, BARANAUSKAS, José Augusto. Conceitos sobre aprendizado de máquina. *In*: REZENDE, Solange Oliveira. **Sistemas inteligentes-Fundamentos e aplicações**, Barueri, SP: Editora Manole Ltda, v. 1, n. 1, 2003, p. 32.
- [34] MONTEIRO, Roger Oliveira, NOGUEIRA, Rodrigo Ramos. **Projeto de um Sistema Web a Classificação de Fake News**. *In*: CONGRESSO LATINO-AMERICANO DE SOFTWARE LIVRE E TECNOLOGIAS ABERTAS (LATI-NOWARE), n° 16, 2019, Foz do Iguaçu. Anais. Porto Alegre: Sociedade Brasileira de Computação, 2019, p. 120–123.
- [35] MÜLLER, Felipe de Matos, DE SOUZA, Márcio Vieira. **FAKE NEWS: UM PROBLEMA MIDIÁTICO MULTIFACETADO**. *In*: **Anais do Congresso Internacional de Conhecimento e Inovação – ciki**, v. 1, n. 1, 2018, México. Anais. Santa Catarina: Universidade Federal de Santa Catarina, 2018, [n. p.].
- [36] OGURI, Pedro. **APRENDIZADO DE MÁQUINA PARA O PROBLEMA DE SENTIMENT CLASSIFICATION**. 2006. Tese (Mestrado em Informática) - Curso de Bacharel em Informática - PUC-Rio, Rio de Janeiro, 2006.
- [37] OLIVEIRA, André Davys Carvalho Melo de. **Identificando emoções em manchetes de notícias escritas em português do Brasil utilizando Naïve Bayes**. 2016. Trabalho de conclusão de curso (Graduação em Ciência da Computação) - Curso de Ciência da Computação - Universidade Federal do Ceará, QUIXADÁ – CEARÁ, 2016.
- [38] PEDREGOSA, F. et al. Scikit-learn: Machine Learning in Python. **Journal of Machine Learning Research**, [S. l.], v. 12, p. 2825–2830, 2011.
- [39] PEREIRA, Cristiane Pinto, SALAZART, Júlia. ESTUDO DE FAKE NEWS NA REDE SOCIAL FACEBOOK. **REVISTA CONGREGA-MOSTRA DE TRABALHOS DE CONCLUSÃO DE CURSO**, [S. l.], n. 2, p. 421–435, 2018.

- [40] RODRÍGUEZ, Marcia Marina, BEZERRA, Byron Leite Dantas. Processamento de Linguagem Natural para Reconhecimento de Entidades Nomeadas em Textos Jurídicos de Atos Administrativos (Portarias). **Revista de Engenharia e Pesquisa Aplicada**, Recife, Brasil, v. 5, n. 1, p. 67–77, 26 abr. 2020.
- [41] RUDNITZKI, Ethel et al. Sete das dez imagens mais compartilhadas em grupos de WhatsApp durante a pandemia são falsas. **Publica**, 28 jul. 2020. Disponível em: <https://apublica.org/2020/07/sete-das-dez-imagens-mais-compartilhadas-em-grupos-de-whatsapp-durante-a-pandemia-sao-falsas/>. Acesso em: 18 nov. 2020.
- [42] SANTOS, Tatiane Gomes dos. **ANÁLISE DE OPINIÕES UTILIZANDO TÉCNICAS DE MINERAÇÃO DE DADOS EM REDES SOCIAIS. ESTUDO DE CASO: TWITTER**. 2017. Trabalho de conclusão de curso (Graduação em Engenharia de Computação) - Curso de Bacharelado em Engenharia de Computação - Centro Universitário de Anápolis – UniEVANGÉLICA, ANÁPOLIS - GO, 2017.
- [43] SCUDERO, Erick. Os 6 frameworks front-end mais amados no mundo (segundo o GitHub). **Becode**, 2018. Disponível em: <https://becode.com.br/frameworks-front-end-mais-amados-segundo-github/>. Acesso em: 19 jun. 2022.
- [44] TORRES, Guilherme M., ZAINA, Luciana A. M., ALMEIDA, Tiago A. de Almeida. **Aprendizagem em Redes Sociais: uma Análise de Dados do Twitter**. In: **Anais Estendidos do XVIII Simpósio Brasileiro de Sistemas Multimídia e Web**, São Paulo, 2012. Anais. Porto Alegre, RS, Brasil: Sociedade Brasileira de Computação, 2012. p. 87–90.
- [45] WENG, Lilian et al. Competition among memes in a world with limited attention. **Scientific reports**, [S. l.], v. 2, n. 1, p. 1–9, 2012.
- [46] YABRUDE, Angela Theresa Zuffo et al. Desafios das Fake News com Idosos durante Infodemia sobre Covid-19: Experiência de Estudantes de Medicina. **Revista Brasileira de Educação Médica**, [S. l.], v. 44, [n. p.], 2020.

A ENDEREÇO DO DATASET UTILIZADO

https://github.com/Jana-SI/CSV_News_Check.git