

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL
INSTITUTO DE INFORMÁTICA
CURSO DE CIÊNCIA DA COMPUTAÇÃO

GABRIEL FONSECA MARTINS

**Um estudo utilizando-se de análise de
sentimentos e aprendizado de máquina
para a classificação de tweets sobre a
vacinação no Brasil**

Monografia apresentada como requisito parcial
para a obtenção do grau de Bacharel em Ciência
da Computação

Orientador: Prof. Dr. Dante Augusto Couto
Barone

Co-orientador: M.Sc. Eduardo Gabriel Côrtes

Porto Alegre
2022

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos André Bulhões Mendes

Vice-Reitora: Prof^ª. Patricia Helena Lucas Pranke

Pró-Reitor de Graduação: Prof^ª. Cíntia Inês Boll

Diretora do Instituto de Informática: Prof^ª. Carla Maria Dal Sasso Freitas

Coordenador do Curso de Ciência de Computação: Prof. Rodrigo Machado

Bibliotecária-chefe do Instituto de Informática: Beatriz Regina Bastos Haro

*“If a machine is expected to be infallible,
it cannot also be intelligent.”*

— ALAN TURING

AGRADECIMENTOS

Agradeço aos meus pais, ao meu irmão e a minha família por todo o suporte, incentivo e apoio dado não somente ao decorrer destes anos de graduação, mas também durante toda a minha vida.

Aos meus colegas e amigos por estarem presentes ao longo desta jornada, tanto nos momentos difíceis quanto nos momentos de descontração.

Ao meu orientador, o professor doutor Dante Augusto Couto Barone e ao meu co-orientador Eduardo Gabriel Côrtes por todos os conselhos e orientações, e também pela oportunidade de realizar este trabalho. Agradeço também a todos os professores e funcionários da UFRGS, pela competência, pela dedicação, e pelos conhecimentos que continuamente transmitem a todos os seus alunos.

RESUMO

Devido a atual situação de COVID-19 no mundo, cientistas e profissionais da área de saúde precisaram elaborar, criar, testar e lançar em tempo recorde uma vacina para tentar controlar a pandemia. E desde sempre a vacinação é um tópico muito discutido pelas pessoas. No ambiente da plataforma online Twitter, usuários expressam seus sentimentos, opiniões e crenças sobre diversos assuntos através de *tweets*, e o assunto da vacinação não ficaria de fora. Utilizando técnicas de aprendizado de máquina sobre um grande conjunto de dados, *tweets*, por exemplo, é possível gerar um modelo para tentar prever a opinião dos usuários sobre a vacinação. O estudo e trabalho realizado foi de utilizar-se destas técnicas de inteligência artificial, mais especificamente modelos supervisionados para classificação, para rotular e classificar os *tweets* de um grande conjunto de dados em classes a favor ou contra a vacinação. Em seguida, incorporar e utilizar-se de técnicas de análise de sentimento nestes *tweets* sobre vacina e vacinação, a fim de perceber se estes possuem sentimento muito positivo, positivo, neutro, negativo ou muito negativo, para então verificar se ao adicionar estes novos fatores melhoraria-se os resultados do modelo classificador de texto a determinar se estes *tweets* são favoráveis ou contrários à vacinação. Além de por fim analisar e tentar entender os principais motivos por tais sentimentos sobre o tópico em geral. Sendo assim, foi feita uma análise sobre o contexto e motivos dos sentimentos, mostrando-se como distribuem-se os cinco sentimentos em ambas as classes: anti-vacina e pró-vacina. Em especial, notou-se que a política está extremamente entrelaçada com o tópico de vacinas e vacinação. Que houve um aumento na positividade dos sentimentos em relação ao tópico ano 2021 quando comparado com o tópico ano 2020. E que os sentimentos mais expressados pelas classes pró-vacina é o positivo, já pela classe anti-vacina é o neutro. Finalmente, a partir dos experimentos realizados no trabalho, concluiu-se que a metodologia proposta em incorporar os *scores* da análise de sentimentos como uma das *features* em um modelo estado da arte *Linear SVC*, quando utilizando-se uma pontuação TF-IDF, não avança de forma significativa as suas classificações, entretanto demonstra a sua atual eficácia para o seu devido propósito.

Palavras-chave: Inteligência artificial. aprendizado de máquina. processamento de linguagem natural. análise de sentimentos. twitter. vacinação.

A study using sentiment analysis and machine learning to classify tweets about vaccination in Brazil

ABSTRACT

Due to the current situation of COVID-19 in the world, scientists and health professionals needed to develop, create, test and launch a vaccine in record time to try to control the pandemic. Vaccination has always been a topic much discussed by people. In the environment of the online platform Twitter, users express their feelings, opinions and beliefs about different subjects through tweets, and the subject of vaccination would not be left out. Using machine learning techniques on a large set of data, tweets, for example, it is possible to generate a model to try to predict the opinion of users about vaccination. The study and work carried out was to use these artificial intelligence techniques, more specifically supervised models for classification, to label and classify tweets from a large set of data into classes for or against vaccination. Then, incorporate and use sentiment analysis techniques in these tweets about vaccine and vaccination, in order to see if they have a very positive, positive, neutral, negative or very negative sentiment, and then verify that if by adding these new factors it would improve the results of the text classifier model to determine whether these tweets are in favor or against vaccination. In addition, to analyze and try to understand the main reasons for such feelings about the topic in general. Therefore, an analysis was made of the context and reasons for these sentiments, showing how the five sentiments are distributed in both classes: anti-vaccine and pro-vaccine. In particular, it was noted that the politics are extremely intertwined with the topic of vaccines and vaccination. That there was an increase in the positivity of sentiments in relation to the year 2021 topic when compared to the year 2020 topic. And that the sentiment most expressed by the pro-vaccine classe is positive, while the anti-vaccine class is neutral. Finally, from the experiments carried out in the work, it was concluded that the methodology proposed in incorporating the sentiment analysis scores as one of the features in a state-of-the-art Linear SVC model, when using a TF-IDF score, does not advance its classification ratings significantly, however it demonstrates its current effectiveness for its intended purpose.

Keywords: artificial intelligence. machine learning. natural language processing. sentiment analysis. twitter. vaccination.

LISTA DE FIGURAS

Figura 4.1	<i>Workflow</i> dos experimentos e do trabalho	25
Figura 5.1	Visualização da distribuição de classes do <i>dataset</i>	26
Figura 5.2	Visualização da distribuição dos valores para cada sentimento	27
Figura 5.3	Gráfico da distribuição de sentimentos de <i>tweets</i> anti-vacina	28
Figura 5.4	Gráfico da distribuição de sentimentos de <i>tweets</i> pró-vacina	28
Figura 5.5	Vinte palavras-chave mais usadas por usuários da classe pró-vacina.....	30
Figura 5.6	Gráfico de sentimentos da classe pró-vacina sobre palavra vida.....	31
Figura 5.7	Vinte palavras-chave mais usadas por usuários da classe anti-vacina.....	32
Figura 5.8	Gráfico da distribuição de sentimentos sobre o tópico: ano 2020	34
Figura 5.9	Gráfico da distribuição de sentimentos sobre o tópico: ano 2021	35

LISTA DE TABELAS

Tabela 5.1	Tabela da distribuição de sentimentos no conjunto de dados	29
Tabela 5.2	Métricas do experimento <i>baseline</i>	36
Tabela 5.3	Métricas do experimento com a análise de sentimentos.....	37

LISTA DE ABREVIATURAS E SIGLAS

COVID-19	Coronavirus Disease 2019
RAM	Random Access Memory
PLN	Processamento de Linguagem Natural
RNN	Recurrent Neural Network
API	Application Programming Interface
SVC	Support Vector Classification
SVM	Support Vector Machine
BoW	Bag-of-Words
ASCII	American Standard Code for Information Interchange
TF-IDF	Term Frequency–Inverse Document Frequency
BERT	Bidirectional Encoder Representations from Transformers

SUMÁRIO

1 INTRODUÇÃO	11
1.1 Contextualização	11
1.2 Motivação.....	11
1.3 Objetivos	12
1.4 Estruturação do trabalho	13
2 FUNDAMENTAÇÃO TEÓRICA	14
2.1 Processamento de linguagem natural.....	14
2.2 Word Embeddings	14
2.3 Bag-of-words e tokens.....	14
2.4 Máquina de vetores de suporte	15
2.5 Análise de sentimentos.....	15
2.6 Transformadores	16
2.7 Rotulagem de sequência	16
2.8 BERT	17
3 TRABALHOS RELACIONADOS	18
4 METODOLOGIA	21
4.1 Conjunto de dados	21
4.2 Análise de sentimentos.....	23
4.3 Classificação do conjunto de dados	24
5 RESULTADOS E ANÁLISE	26
5.1 Conjunto de dados	26
5.2 Análise de sentimentos.....	27
5.3 Análise sobre as métricas resultantes.....	36
5.4 Desafios da classificação de textos	37
5.5 Limitações do trabalho	38
6 CONCLUSÃO	40
REFERÊNCIAS	41

1 INTRODUÇÃO

O capítulo apresentará uma breve contextualização do tópico abordado, as motivações para os experimentos e estudos e os seus objetivos. Em seguida, é apresentada uma especificação da organização do trabalho.

1.1 Contextualização

As vacinas são armas poderosas contra inúmeras doenças atualmente, mas desde as primeiras campanhas de aplicação, sempre existiu um grupo de pessoas em oposição, seja por motivos de desconfiança de sua eficácia, medo de efeitos adversos, ou talvez simplesmente por falta de conhecimento sobre a vacina em questão (LARSSON, 2020). Já no cenário atual acerca da pandemia de COVID-19, as discussões sobre o tópico tornaram-se um assunto global, pois nunca foi tão comentado e discutido a respeito de vacinas e vacinação anteriormente. Hoje em dia, com a modernização e digitalização das mídias, a internet torna-se um dos principais meios de comunicação para as pessoas obterem informações e discutirem sobre temas e assuntos. Uma das maiores redes sociais, a plataforma online chamada Twitter (GISMONDI, 2021), torna-se o palco para que centenas de milhares de pessoas expressem suas opiniões sobre este tópico em alta, as vacinas e a vacinação.

1.2 Motivação

A motivação pessoal para este trabalho e estudo deu-se pelo fato de que matriculei-me em uma cadeira eletiva da UFRGS, do curso de ciência da computação, chamada Computador e Sociedade, no ano ministrada pelo professor doutor Dante Augusto Couto Barone, onde nela era abordado diversos tópicos e temas, tais como as repercussões das novas tecnologias na sociedade, levando-se em consideração aspectos sociais, econômicos, políticos e educacionais, e também sobre aplicações da informática em diversas outras áreas como indústria nacional, política, saúde, entre outras. Como já estávamos em meio a pandemia de COVID-19, relacionar e utilizar-se de métodos computacionais para melhor compreender a atual situação tornou-se um tópico interessante de analisar-se. Após entrar em contato com o professor doutor Dante Augusto Couto Barone, que aceitou

tornar-se meu orientador, ele menciona o trabalho de Artur Hallberg, um de seus orientandos, que aborda o mesmo tema e assunto sobre o qual eu desejava pesquisar e realizar o trabalho. E então, graças a sugestão de meu orientador, inicio meu trabalho como uma certa continuação do trabalho realizado por Artur Hallberg (HALLBERG, 2021).

Em virtude da atual situação política no Brasil, nota-se a agravação da polarização entre as opiniões das pessoas com respeito ao tópico das vacinas e vacinação, que acabam por misturar posicionamento político com ciência (ARNDT et al., 2021). Torna-se então cada vez mais necessário a criação de métodos e ferramentas capazes de identificar tanto o posicionamento das pessoas com relação ao tópico, quanto que tipo de sentimento estas expressam em seus discursos ou palavras, com o intuito de melhor analisar e compreender suas ideias, motivos e comportamentos como um todo. Como a área de PLN possui diversos desafios, sendo um destes a compreensão da linguagem natural. Este trabalho busca desenvolver a pesquisa na elaboração de métodos capazes de identificar, de forma autônoma, o posicionamento de *tweets* sobre temas sensíveis, como por exemplo o tópico das vacinas e vacinação.

1.3 Objetivos

Os principais objetivos do trabalho são de utilizar-se de técnicas de análise de sentimentos em textos para classificar e atribuir sentimento a um grande conjunto de dados, *tweets* sobre o tópico de vacinas e vacinação, e então realizar uma análise para compreender os principais motivos pelos quais tais sentimentos estão sendo expressos, com relação ao assunto. E também, utilizar-se de técnicas de ML para classificar o conjunto de dados em classes chamadas anti-vacina e pró-vacina, onde estas expressam o posicionamento do usuário sobre o tópico. Para que por fim então, possa realizar-se novamente o experimento de classificação, mas agora adicionando-se uma nova *feature*, o valor do sentimento do *tweet*, com o objetivo de testar e comparar as métricas geradas pela execução de ambos os algoritmos, um puramente pela a análise das palavras contidas no *tweet*, e o outro adicionando-se esta nova *feature* de sentimento.

1.4 Estruturação do trabalho

Este trabalho está organizado de acordo com a seguinte estrutura. O capítulo 2 apresenta a fundamentação teórica envolvida, a qual este trabalho baseia-se. O capítulo 3 realiza uma análise sobre outros estudos e trabalhos relacionados a este. O capítulo 4 apresenta a metodologia e etapas detalhadas de como foi realizado o experimento para atingir os objetivos propostos pelo trabalho. Os resultados obtidos pela execução das técnicas apresentadas no capítulo anterior são apresentados no capítulo 5 e uma análise sobre os mesmos é realizada, além de discutir sobre os desafios encontrados ao realizar-se os experimentos e as limitações deste trabalho. E finalmente, o capítulo 6 apresenta conclusões gerais sobre o trabalho, sobre seus resultados, e direções futuras para este.

2 FUNDAMENTAÇÃO TEÓRICA

Os principais conceitos utilizados no trabalho encontram-se a seguir.

2.1 Processamento de linguagem natural

O processamento de linguagem natural (PLN) é uma vertente da inteligência artificial que ajuda computadores a entender, interpretar e manipular a linguagem humana. O PLN é o resultado de diversas disciplinas, incluindo-se ciência da computação e linguística computacional, a qual busca-se preencher a lacuna entre a comunicação humana e o entendimento dos computadores. (NEVES, 2018)

Para atingir estes objetivos, os algoritmos que envolvem PLN necessitam de valores numéricos que representem o texto, para que possa-se realizar suas operações e classificações. Um dos métodos para representações vetoriais de palavras comumente utilizado é chamado de *word embeddings*. (TAIL, 2020)

2.2 Word Embeddings

Word Embeddings, ou incorporação de palavras, é um termo usado para a representação de palavras para análise de texto, normalmente na forma de um vetor de valor real que codifica o significado da palavra de modo que as palavras que estão mais próximas no vetor espera-se que o espaço seja semelhante em significado (JURAFSKY; MARTIN, 2000). As *word embeddings* podem ser obtidas a partir do uso de modelagem de linguagem e técnicas de aprendizado de *feature*, onde palavras ou frases de um vocabulário são mapeadas a um vetor de números reais.

Word e phrase embeddings, quando usados como representação de entrada subjacente, demonstram aumentar o desempenho em tarefas de PLN, como análise sintática e análise de sentimentos. (WORD EMBEDDINGS)

2.3 Bag-of-words e tokens

Já o modelo *bag-of-words* (BoW) é uma representação simplificada utilizada em PLN e também na recuperação de informações (RI). Nesse modelo, um texto (uma frase

ou um documento) é representado como uma *bag* (um multiconjunto) de suas palavras, onde é desconsiderando a gramática e até mesmo a ordem das palavras, mas mantém-se a multiplicidade delas. O modelo BoW é comumente usado em métodos de classificação de documentos onde a frequência de ocorrência de cada palavra (*token*) é usada como uma *feature* para treinar um classificador. *Tokens* (ou seja, palavras) são a unidade atômica de comparação de texto. Se quisermos comparar dois documentos (ou *strings*), contamos quantos *tokens* eles compartilham em comum. (TEAM, 2020)

2.4 Máquina de vetores de suporte

Uma máquina de vetores de suporte, ou support-vector machine (SVM) em inglês, é um conceito para um conjunto de métodos de aprendizado supervisionado que analisam os dados e reconhecem padrões, muito utilizado para classificação e análise de regressão. O SVM padrão recebe como entrada um conjunto de dados, e então prediz para cada entrada do conjunto, qual de duas possíveis classes a entrada faz parte, o que faz do SVM um classificador linear binário não probabilístico. Dados um conjunto de exemplos de treinamento, cada um devidamente marcado como pertencente a uma de duas categorias (classes), um algoritmo de treinamento do tipo SVM constrói um modelo que atribui novos exemplos (entradas) a uma classe ou outra.

Uma abstração do modelo SVM é como uma representação de exemplos como pontos no espaço, mapeados de maneira que os exemplos de cada categoria sejam divididos por um espaço bem definido e que seja tão amplo quanto possível. Os novos exemplos (entradas) são então mapeados no mesmo espaço e preditos como pertencentes a uma das classes baseadas em qual o lado do espaço eles são colocados. (RAY, 2017)

2.5 Análise de sentimentos

A análise de sentimentos é o uso de métodos como PLN, análise de texto, linguística computacional ou até mesmo biometria para identificar, extrair, quantificar e estudar informações subjetivas e estados afetivos. É comumente aplicado a materiais de “voz do cliente” (GRIFFIN; HAUSER, 1991), como avaliações e respostas a pesquisas, mídia online e social e materiais de saúde para aplicativos que podem variar de *marketing* a atendimento ao cliente e medicina clínica.

Os modelos de análise de sentimentos geralmente concentram-se na polaridade, como positivo ou negativo, mas também podem concentrar-se em sentimentos e emoções, como raiva, alegria, tristeza, etc. A polaridade também pode estender-se para ser mais precisa, de modo a incluir um intervalo como muito positivo, positivo, neutro, negativo e muito negativo. Neste trabalho, utiliza-se deste intervalo de polaridade.

2.6 Transformadores

Transformador, ou *transformer* em inglês, é um modelo de aprendizado profundo introduzido em 2017 que utiliza o mecanismo de atenção, pesando a influência de diferentes partes dos dados de entrada. É usado principalmente no campo de PLN, mas pesquisas recentes também desenvolveram sua aplicação em outras tarefas, como compreensão de vídeo (BERTASIUS; WANG; TORRESANI, 2021). Assim como as redes neurais recorrentes, os *transformer* são projetados para lidar com dados de entrada sequenciais, como linguagem natural, geralmente para tarefas como a tradução ou resumo de texto. No entanto, ao contrário das RNNs, os *transformers* não exigem que os dados sequenciais sejam processados em ordem. Em vez disso, a operação de atenção identifica o contexto para qualquer posição na sequência de entrada. (LINDSAY, 2020) Por exemplo, se os dados de entrada forem uma frase em linguagem natural, o *transformer* não precisará processar o início antes do final da frase. Em vez disso, ele identifica o contexto que confere significado a uma palavra na frase. Devido a esse recurso, o *transformer* permite muito mais paralelização do que RNNs e, portanto, reduz os tempos de treinamento (VASWANI et al., 2017).

2.7 Rotulagem de sequência

Ainda tratando-se de aprendizado de máquina, a rotulagem de sequência é um tipo de tarefa de reconhecimento de padrões, que envolve a atribuição de uma *label* categórica a cada membro de uma sequência de valores sendo observados. Um dos exemplos mais comuns da tarefa de rotulagem de sequência é a marcação de classe gramatical, que busca atribuir uma classe gramatical a cada palavra em uma frase (*string*) ou documento de entrada.

2.8 BERT

BERT, que significa em inglês *Bidirectional Encoder Representations from Transformers*, é baseado em *transformers*. Na época de sua introdução, os modelos de linguagem usavam principalmente redes neurais recorrentes (RNN) e redes neurais convolucionais (CNN) para lidar com tarefas de PLN.

Em 2018, o Google introduziu o BERT de código aberto. Em seus estágios de pesquisa, a estrutura alcançou resultados inovadores em 11 tarefas de compreensão de linguagem natural, incluindo análise de sentimentos, rotulagem de papéis semânticos, classificação de frases e desambiguação de palavras polissêmicas ou palavras com significados múltiplos. (LUTKEVICH, 2020)

O modelo pré-treinado utilizado no trabalho para realizar-se a análise de sentimentos (LAMPERT; LAMPERT, 2021) baseia-se nos conceitos de transformadores e rotulagem de sequência, brevemente explicados aqui. E ele é um tipo de modelo de linguagem BERT.

3 TRABALHOS RELACIONADOS

Ao pesquisar mais a fundo sobre o assunto do trabalho, a primeira análise realizada deu-se pelo trabalho (HALLBERG, 2021), uma recomendação de meu orientador. Os demais trabalhos citados neste capítulo foram selecionados da literatura por se assemelharem a este. Ou seja, realizam análises de algum tópico relevante discutido em redes sociais, principalmente o Twitter. E também, aqueles que utilizam-se das técnicas de análise de sentimentos.

O trabalho (HALLBERG, 2021) é semelhante a este, porém com um maior foco em descobrir os principais fatores sociodemográficos a fim de concluir características sobre os usuários que são a favor ou contra a vacinação. O trabalho de Artur Hallberg cria o *dataset* utilizado por este. Primeiramente foram separados em dois conjuntos *hashtags* relevantes ao tópico, uma vez que as *hashtags* são uma das principais características da plataforma Twitter, e que frequentemente os usuários expressam suas opiniões através dos mesmos, onde elas são utilizadas tanto ao meio das frases quanto ao final delas. Em seguida foi realizado uma classificação utilizando-se destes conjuntos de *hashtags* classificados em pró-vacina e anti-vacina, em que o seu *script* classificou então os *tweets* baseando-se em suas *hashtags*, e atribuiu-se a mesma classe do conjunto de *hashtags* aos *tweets* em que as contém. Utilizando-se de duas ferramentas, o Twint (ZACHARIAS, 2018) e Twarc (SUMMERS et al., 2021), foi gerado uma base de dados com *tweets* de usuários brasileiros a partir do dia primeiro de março de 2019 até o dia primeiro de março de 2021. Estas datas de busca foram escolhidas de forma a capturar um período de dois anos, onde aproximadamente o primeiro ano corresponde a um período pré-pandemia de COVID-19 e aproximadamente o segundo ano a um período já em pandemia. Desta maneira foi possível analisar como a ocorrência da pandemia de COVID-19 influenciou as opiniões sobre vacinas.

No trabalho apresentou-se resultados e conclusões bastante informativas e pertinentes sobre o conjunto de dados e também uma projeção sobre a opinião da população brasileira em certos setores da população no contexto de vacinas e vacinação. Mostrou-se também que não é possível generalizar as análises realizadas no trabalho para toda a população brasileira, pois conforme explicado mais detalhadamente no trabalho, a população da amostra coletada não possui uma distribuição sociodemográfica perfeitamente compatível com a sociodemográfica da população brasileira, mas ainda assim as análises realizadas fornecem conclusões relevantes ao que diz respeito a características do conjunto

coletado, de como por exemplo, idade, gênero, etnia, localização, entre outros fatores, e como estes influenciam o comportamento do usuário em relação a seu posicionamento sobre o tópico das vacinas e vacinação.

É de importância ressaltar algumas das características observadas sobre o conjunto de dados, como o que a menor idade detectada pelo algoritmo de predição de idades utilizado no trabalho, foi de 19 anos, enquanto a maior idade foi de 62. Entretanto, a grande maioria dos usuários amostrados apresentam idades entre 25 e 35 anos. A respeito do gênero, aproximadamente 76% das instâncias coletadas correspondem a usuários homens, versus 24% correspondente a usuárias mulheres. Porém não são resultados surpreendentes, já que havia conhecimento prévio de que a maioria dos usuários da rede social Twitter eram jovens adultos homens. Como era de se esperar, a quantidade de *tweets* a respeito de vacinas e vacinação são muito menores no período chamado pré-pandemia, do que quando começou-se a circular notícias no mundo todo sobre este novo vírus. E também a análise do trabalho mostra que entre os homens há uma porcentagem maior daqueles que expressam ideias anti-vacina, quando comparada à porcentagem de mulheres que expressam estas mesmas ideias, e que conforme a idade aumenta, a porcentagem anti-vacina vai aumentando também, mostrando que os jovens são mais favoráveis as vacinas e a vacinação.

Outro trabalho que também assemelha-se a este é o (BECHINI et al., 2021), onde o objetivo é compreender as opiniões de usuários do Twitter também em relação ao tópico de vacinação, porém na Itália. Foi criado um *pipeline* de classificação, utilizando-se um modelo SVM, para classificar os *tweets* em três classes, sendo elas *neutral*, *in favor* e *not in favor*. Com base nesses *tweets* categorizados, determinou-se as opiniões dos usuários, além de realizar-se uma análise sobre as regiões do país com relação às suas porcentagens de usuários a favor ou contra vacinas.

Ainda utilizando-se a rede social Twitter como forma de obter-se uma grande base de dados, o trabalho (GOMIDE et al., 2011) tem como objetivo utilizar-se de informações obtidas de *tweets* para monitorar epidemias de dengue no Brasil. O trabalho propõe uma metodologia de vigilância baseada em quatro dimensões, sendo elas volume, localização, tempo e a percepção do público. Realiza-se uma análise de sentimentos a fim de selecionar apenas os *tweets* que são relevantes para a esta vigilância da dengue, e então os *tweets* obtidos são analisados sob uma perspectiva espaço-temporal.

O trabalho analisado a seguir é o (TORRES; PIMENTA; MORAES, 2020) onde este se utiliza de diversos métodos para realizar-se uma análise de sentimentos a respeito

da aceitação das vacinas contra o COVID-19, também utilizando-se da rede social Twitter. Nele, coleta-se *tweets* de brasileiros a respeito do tópico das vacinas e vacinação, relacionando-se às palavras-chaves “covid” e “vacina”, para os meses setembro, outubro e novembro do ano de 2020. No estudo, mostra-se então que a maioria dos sentimentos representados pelos *tweets* coletados eram sentimentos negativos com relação às vacinas em desenvolvimento. E que de cinco metodologias utilizadas para realizar a classificação da análise de sentimentos, o método *VaderSentiment* que baseia-se em dicionário léxico, apresentou os melhores resultados em acurácia e precisão.

Por fim, o trabalho (MIGUEL; BARBOSA, 2019) propõe uma metodologia e criação de uma ferramenta para a captura de *tweets* de um determinado assunto na língua portuguesa, e então utiliza-se de métodos de análise de sentimento para classificar o sentimento transmitido pelo *tweet* como positivo ou negativo. Neste trabalho, a classificação e atribuição do sentimento nos *tweets* dão-se pela utilização de um algoritmo *Naive Bayes*, onde os textos são representados como uma *bag-of-words* para serem classificados com base no modelo probabilístico. O trabalho apresenta testes utilizando validação cruzada onde estes obtiveram como resultado uma taxa de acerto entre 72% e 74%. Aqui é considerável notar que métodos como *bag-of-words* e algoritmos *Naive Bayes* já não são mais considerados modelos de classificação estado da arte, para realizar-se análise de sentimento. Atualmente, utilizando-se de modelos como BERT geralmente obtêm-se acurácias muito maiores, fornecendo uma classificação mais precisa. (SUDHIR; SURESH, 2021)

Diferente dos demais trabalhos citados, a proposta deste estudo após a análise de sentimentos é focar-se em compreender os motivos pelos quais os *tweets* sobre o tópico de vacina e vacinação expressam tais sentimentos, e quais suas principais características. Além de tentar avançar nos métodos de classificação textual, ao utilizar-se de técnicas de aprendizado de máquina, a partir dos experimentos realizados neste trabalho. Mais especificamente, utilizar-se de um modelo de classificação do tipo SVM, que este aplica uma pontuação TF-IDF como valores para suas *features*, e em seguida incorporar os *scores* da análise de sentimento como *features* adicionais para este modelo classificador.

4 METODOLOGIA

De modo geral, a estratégia implementada para o trabalho consiste em utilizar algoritmos de aprendizado de máquina com o objetivo de prever a opinião de um grande número de *tweets* e classificá-los em pró-vacina ou anti-vacina utilizando-se de um modelo SVM. Em seguida, realizar uma análise de sentimentos sobre os dados, incorporar o *score* da análise como uma *feature* para o modelo classificador, e então realizar-se novamente a classificação com o modelo SVM, para comparar a qualidade de ambas as classificações a partir de métricas resultantes. Por fim, analisar os resultados obtidos pela a análise de sentimentos a fim de tentar entender os principais motivos por tais sentimentos sobre o tópico de vacinas e vacinação em geral.

4.1 Conjunto de dados

Para tal tarefa, primeiramente é necessário obter-se um conjunto de dados com uma grande quantidade de *tweets* a respeito de vacinas e, ou, vacinação. Como mencionado anteriormente, este conjunto de dados foi previamente coletado e gerado pelo trabalho (HALLBERG, 2021), onde buscou-se na rede social Twitter, *tweets* de brasileiros do período de primeiro de março de 2019 até o dia primeiro de março de 2021. Esta data foi propositalmente escolhida para abranger dois períodos distintos, um ano pré-pandemia, onde o tópico sobre vacinas e vacinação, ainda que já existentes, não estavam em alta nas mídias e no cotidiano das pessoas. E o segundo período então seria um ano onde o surto de COVID-19 já atingiu o mundo todo, tornando-se uma pandemia. Aqui nunca foi-se tão falado sobre vacinas, pois elas são a maior esperança para a população de acabar com esta calamidade na saúde pública mundial. (POLAKIEWICZ, 2020)

Dessa forma, para a captura destes *tweets*, utilizou-se inicialmente da ferramenta Twint (ZACHARIAS, 2018), uma ferramenta capaz de contornar as limitações da API oficial do Twitter, que permite apenas coletar informações de *tweets* de até sete dias atrás, a partir da data e hora da utilização de sua API. Foi escrito então dois *scripts* em Python para a busca e captura de dois conjuntos de dados, um anti-vacina e outro pró-vacina, através da busca de *hashtags* associadas a cada grupo. Este processo criou então duas listas, uma contendo os IDs de *tweets* que expressam ideias anti-vacina, e outra contendo os IDs de *tweets* que expressam ideias pró-vacina. Utilizou-se também de uma segunda ferramenta chamada Twarc (SUMMERS et al., 2021), e principalmente do comando *hy-*

drate desta ferramenta para obter-se mais dados sobre os usuários que publicaram tais *tweets*, como a descrição do usuário (sua biografia), sua geolocalização, entre várias outras informações relevantes, como idade, ocupação, etnia, etc, a fim de realizar as análises para o trabalho (HALLBERG, 2021).

Com este conjunto de dados em mãos, onde este está separado em dois arquivos *.json*, um com os *tweets* de usuários, classificados como anti-vacina, e o outro com os *tweets* de usuários classificados como pró-vacina, começo com o meu estudo e trabalho. O primeiro passo para a análise do trabalho foi criar um *script* na linguagem Python, onde realiza-se um pré-processamento dos dados. Aqui o objetivo é “limpar” os *tweets* de caracteres fora do padrão ASCII. Utilizando-se da função *unidecode* (UNIDECODE), letras com acentos ou cedilha são transformadas em suas respectivas letras sem acento ou cedilha, e em seguida remove-se qualquer espaço extra no início ou no final dos *tweets*. Ainda no pré-processamento, foi decidido remover menções a outros usuários. No Twitter é uma prática muito comum mencionar outros usuários, tanto como em resposta ou como uma maneira de chamar a atenção do mesmo. Para isto inicia-se com o carácter @ e em seguida digita-se o nome do usuário. Julgou-se não necessário incluir estes nomes (menções) no corpo dos *tweets* para o fim das análises deste trabalho, pois eles não possuem nenhum significado semântico. Além das menções, o pré-processamento retira do corpo dos *tweets* no conjunto de dados todas as *hashtags* dos mesmos, uma vez que o conjunto de dados foi gerado a partir de *hashtags* selecionadas como anti-vacina ou pró-vacina, não seria interessante realizar a predição e classificação dos *tweets* com estas *hashtags*, pois o algoritmo de predição iria facilmente aprender a só “olhar” para as *hashtags* para então dizer qual é a classe correta para rotular tal *tweet*. Por fim, também remove-se todos os *links* para outros conteúdos da *web* contidos nos *tweets* do conjunto dados, estes que são sempre iniciados como “https://” e também não possuem nenhum significado semântico para análise.

Ao final desta etapa de pré-processamento do *dataset*, o número total de *tweets* que antes eram de 88.062, agora passam a ser 72.595 no total. A redução no número total de *tweets* do *dataset* deve-se ao fato de que são removidos aqueles *tweets* que porventura tornaram-se uma *string* em branco (vazia) após o pré-processamento, pois não é tão raro as ocorrências onde os usuários do Twitter utilizam-se somente de *hashtags* no que publicam ou realizam um *retweet* seguido de uma menção; neste caso o que este usuário realmente publicou em seu *tweet* é esta menção a algum outro usuário.

4.2 Análise de sentimentos

Agora feito o pré-processamento em ambos os conjunto de dados, o *script* em Python une tudo em um só conjunto, e em seguida utiliza-se de um modelo pré-treinado para a predição de análise de sentimentos (LAMPERT; LAMPERT, 2021). Este modelo foi treinado com um conjunto de dados de grande escala, com 18.437.530 exemplos de *tweets* em múltiplas línguas, coletados entre março de 2020 e novembro de 2021, utilizando-se a API de streaming do Twitter com várias palavras-chave relacionadas à COVID-19. Os rótulos (*labels*) eram gerados automaticamente com base na presença de *emoticons* positivos e negativos.

A escolha deste modelo para a predição é dada pois ele contempla duas necessidades do trabalho, a primeira é um modelo que consiga fazer uma análise de sentimento em textos na nossa língua portuguesa. E a segunda é que o modelo seja treinado com uma base de dados relacionado ao contexto do trabalho, isto é, textos, ou melhor ainda, *tweets*, sobre os tópicos de vacinas e, ou, vacinação. Dado que o foco eram palavras-chave sobre a COVID-19, e que neste conjunto de dados de grande escala, a nossa língua está inclusiva, o modelo é uma escolha perfeita para o estudo e trabalho realizado.

Utiliza-se então a API Transformers (TRANSFORMERS) para realizar-se a classificação dos *tweets* a partir do modelo pré-treinado mencionado anteriormente, em que este então retorna dois valores para cada *string* (*tweet*) do conjunto de dados. Estes valores *floats* são os *scores* atribuídos pelo modelo classificador após a análise de sentimentos e representam o quão forte é o sentimento positivo contido no *tweet* e o quão forte é o sentimento negativo contido no mesmo *tweet*. O próximo passo segue-se então realizando uma subtração destes dois *scores*, formando apenas um valor *float* que representa o sentimento final contido no *tweet*. Este processo é repetido até que todos os *tweets* do conjunto de dados sejam processados. A última etapa deste *script* é salvar todos estes dados processados em um novo *dataset* no formato .csv (PROCESSED-DATASET), contendo as informações necessárias para a análise sobre os resultados dos sentimentos e também para o próximo *script*. Estas são: o número do *tweet* de 0 a 72.594, o texto em si em formato *string*, o *score* final de seu sentimento em *float* e o rótulo herdado, classificado anteriormente no trabalho (HALLBERG, 2021), que categoriza o *tweet* em anti-vacina ou pró-vacina, que funciona como um gabarito para os próximos passos da classificação com o modelo SVM.

4.3 Classificação do conjunto de dados

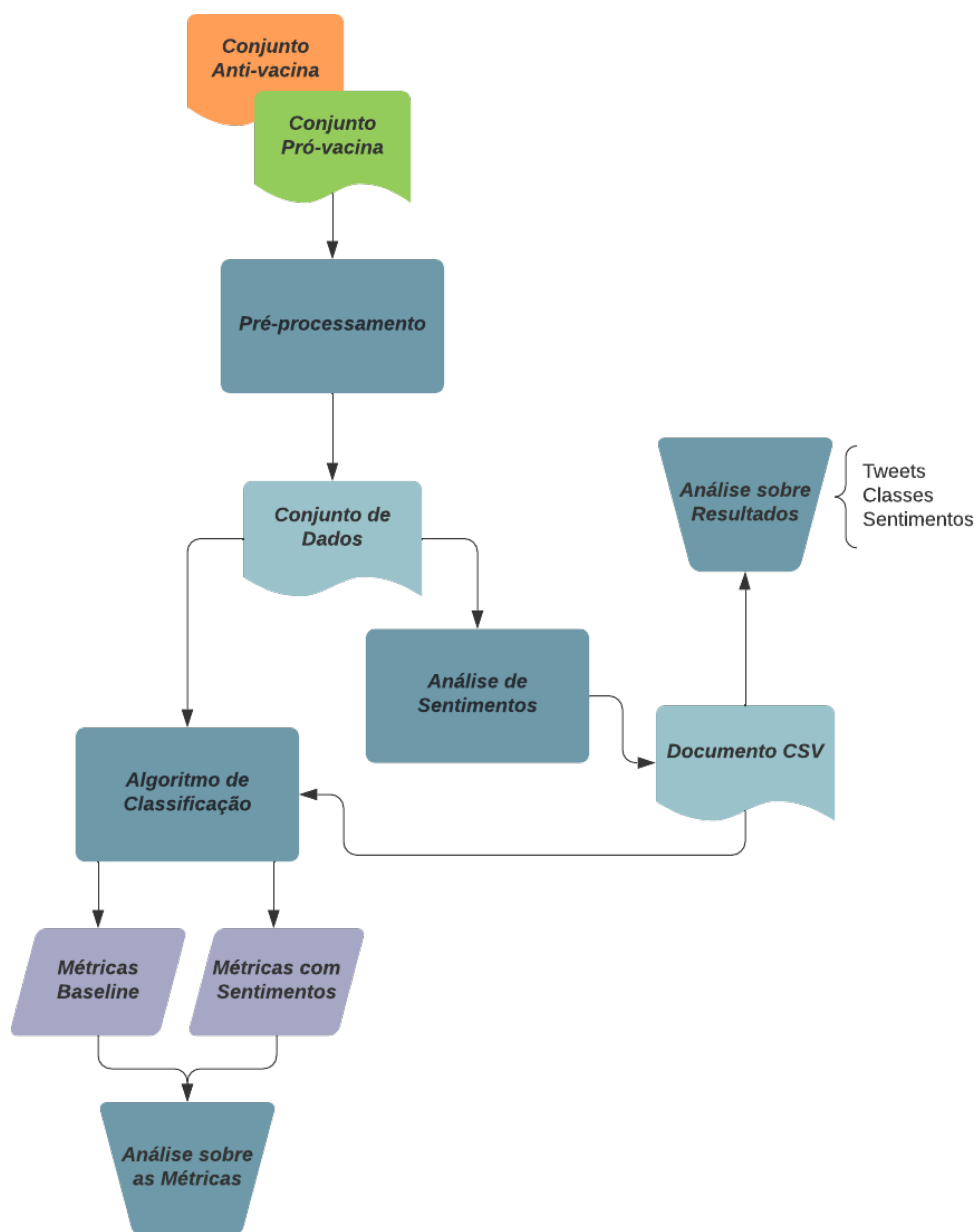
Finalmente, passa-se para o segundo *script*, também escrito em Python, em que será feita a classificação propriamente dita dos *tweets* em anti-vacina ou pró-vacina, de acordo com análises sobre as *strings*. Inicialmente carrega-se o conjunto de dados .json com o pré-processamento aplicado, e com o auxílio da biblioteca *sklearn.svm.SVC* (SCIKIT-LEARN) começa-se um experimento utilizando-se das técnicas de *cross-validation* e *K-folds*. No experimento foi utilizado um valor de K igual a cinco e o número de iterações igual a seis, isto é, o algoritmo irá dividir o conjunto de dados em cinco subconjuntos de forma aleatória com aproximadamente a mesma quantidade de amostras em cada um deles. Em cada uma das seis iterações, um conjunto formado por K-1 subconjuntos são utilizados para treinamento e o subconjunto restante será então utilizado para teste, gerando os resultados de métricas para uma análise e avaliação. Ao final, realizou-se então trinta *folds*, o que considera-se uma quantidade satisfatória para tirar conclusões estatísticas. Utilizou-se de um conjunto de *stop words* de palavras em português que contempla palavras irrelevantes para o estudo, assim elas não serão contabilizadas na função *TfidfVectorizer*, da mesma API (SCIKIT-LEARN), que realiza a conversão das palavras mais utilizadas no conjunto de dados para valores significativos, em *float*, gerando uma matriz de *features*, com o número máximo de *features* setado em mil, para mesurar o uso de memória RAM na execução. Em resumo, o valor TF-IDF é uma pontuação que é aplicada a cada palavra em cada *tweet* no conjunto de dados. Para cada palavra (*token*), o valor TF-IDF aumenta com cada aparição da mesma no *tweet*, mas diminui gradualmente com cada aparição em outros *tweets*. Quanto maior o valor, mais relevante é o termo no *tweet*. A próxima etapa é a utilização do módulo *Linear SVC* da mesma API, que implementa um algoritmo de classificação SVM. Este irá então classificar cada *tweet* do conjunto de dados em uma das duas possíveis classes, sendo elas anti-vacina ou pró-vacina, e gerar as métricas *precision*, *recall* e *F1-score*, que servirão para uma das análises do trabalho.

Agora com este experimento, chamado de *baseline*, finalizado, passa-se para um novo *loop* no *script*, onde executa-se basicamente os mesmos passos anteriores de *cross-validation* com *K-folds*, inclusive com os mesmos parâmetros já mencionados. Porém desta vez o objetivo é incorporar os *scores* da análise de sentimentos, realizada anteriormente, como uma das *features* que o modelo *Linear SVC* utilizará. Desejando-se saber o quanto o valor destes sentimentos impactará nas métricas a serem analisadas. Ao final

desta etapa, o *script* gerou outros trinta *folds* também com as métricas *precision*, *recall* e *F1-score*, onde então os próximos passos foram analisar ambos os resultados do modelo de predição, o *baseline* versus o modelo com a *feature* de análise de sentimento inclusa. E também, posteriormente realizar uma análise sobre os resultados obtidos a partir da realização da análise de sentimentos no conjunto de dados.

Em suma, a metodologia do trabalho e experimentos segue o seguinte *workflow*:

Figura 4.1: *Workflow* dos experimentos e do trabalho



Fonte: Elaborado pelo autor

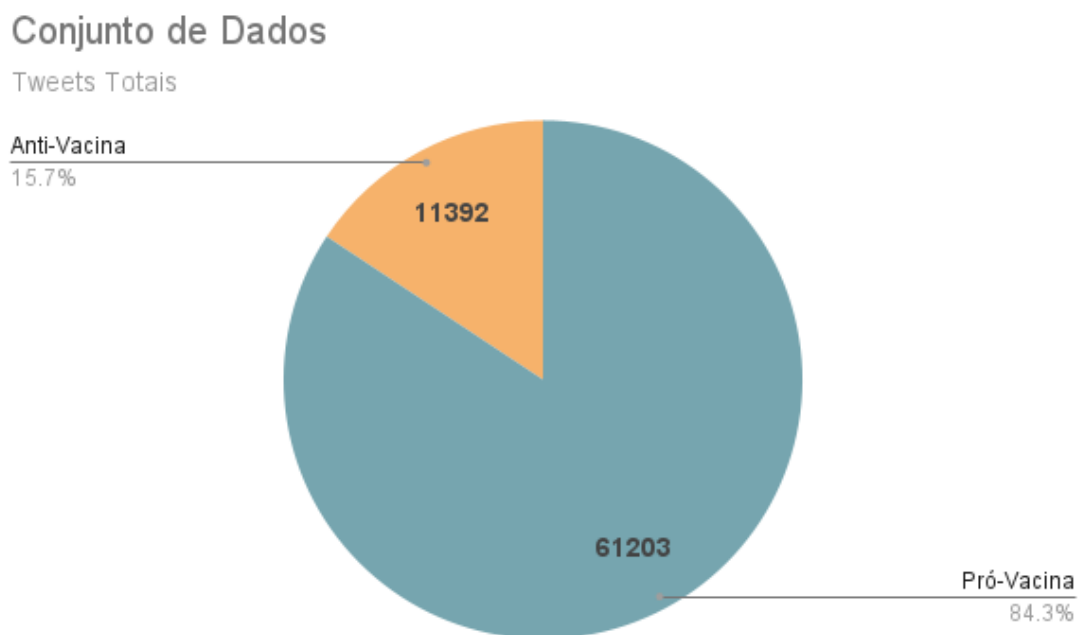
5 RESULTADOS E ANÁLISE

Uma análise dos resultados obtidos através dos experimentos propostos neste trabalho é apresentada a seguir.

5.1 Conjunto de dados

Com o *dataset* processado, de acordo com os passos descritos anteriormente na etapa de pré-processamento, este possui um total de 72.595 *tweets*, onde 61.203 são *tweets* considerados pró-vacina, representando 84,3% do conjunto de dados, e os outros 11.392 *tweets* são considerados anti-vacina, em que representam os restantes 15,7% do conjunto.

Figura 5.1: Visualização da distribuição de classes do *dataset*

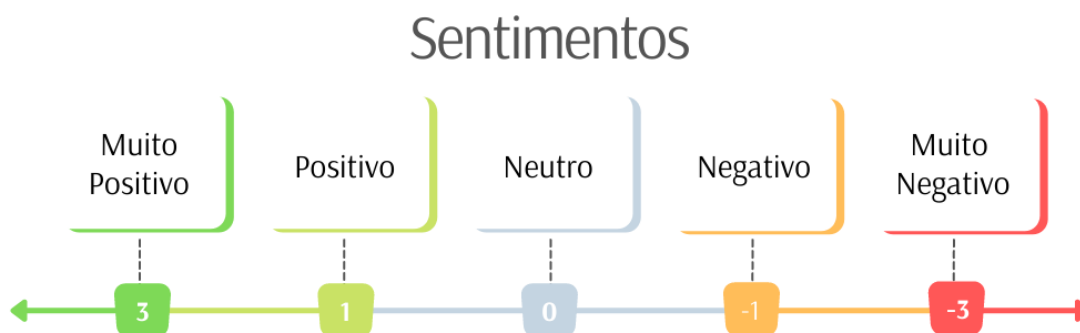


Fonte: Elaborado pelo autor

5.2 Análise de sentimentos

Após a execução do algoritmo de análise de sentimentos, realiza-se uma avaliação e análise empírica sobre os *tweets* e seus *scores* de sentimento atribuídos, e então classifica-se a partir destes valores uma semântica que representa de forma mais adequada estes sentimentos.

Figura 5.2: Visualização da distribuição dos valores para cada sentimento



Fonte: Elaborado pelo autor


Atribuiu-se ao total cinco sentimentos distintos com base na intensidade destes valores, sendo eles muito positivo, positivo, neutro, negativo e muito negativo. Sendo assim, o intervalo de valores de *tweets* com um sentimento muito positivo são aqueles que possuem um *score* de 3 ou superior. Os *tweets* com um sentimento positivo são aqueles que possuem um *score* entre 3, não incluso, e 1. Sucessivamente os *tweets* com um sentimento neutro estão na faixa entre 1, não incluso, e -1, não incluso. *Tweets* com um sentimento negativo estarão entre os *scores* de -1 à -3, não incluso. E por fim, os *tweets* com um sentimento muito negativo possuem um *score* de -3 ou menos. Esta faixa de valores representou de forma adequada os sentimentos dos *tweets* do conjunto de dados de acordo com várias observações empíricas.

O *dataset* completo com os *scores* da análise de sentimento para cada *tweet*, sem o pré-processamento que exclui algumas amostras, como explicado na seção 4.1, pode ser encontrado em (DATASET).

Figura 5.3: Gráfico da distribuição de sentimentos de *tweets* anti-vacina

Anti-Vacina

Sentimentos




Fonte: Elaborado pelo autor

Figura 5.4: Gráfico da distribuição de sentimentos de *tweets* pró-vacina

Pró-Vacina

Sentimentos



Fonte: Elaborado pelo autor

Tabela 5.1: Tabela da distribuição de sentimentos no conjunto de dados


	<i>Anti-vacina</i>	<i>Pró-vacina</i>
Muito Positivo	278	7644
Positivo	3038	19479
Neutro	6157	22219
Negativo	1702	8474
Muito Negativo	217	3387

Fonte: Elaborado pelo autor

A partir da análise do gráfico da figura 5.3 é possível notar que a maior concentração de sentimento é o sentimento neutro, com 6.157 amostras, totalizando 54% de todo o conjunto da classe anti-vacina. Esse é o geral comportamento de *tweets* que de certa forma expressam não ser favoráveis à vacinas mas também não expõem sentimentos de maneira perceptível com seu *tweet*. Um exemplo de *tweet* com sentimento neutro anti-vacina é “*Meu corpo minhas regras.*”, onde não consegue-se realmente obter nenhum dos outros sentimentos e seu respectivo *score* atribuído pelo modelo foi de 0.5188.

Segue-se então a observar, pela tabela 5.1, que existem mais *tweets* expressando sentimentos positivos do que *tweets* expressando sentimentos negativos em ambas as classes, anti-vacina e pró-vacina, demonstrando que apesar de opiniões contrárias, as pessoas de modo geral expressam-se mais de forma positiva que o contrário. Ao analisar a figura 5.4, nota-se que a soma das porcentagens de *tweets* da classe pró-vacina contendo algum sentimento positivo, isto é, tanto positivo quanto muito positivo, é maior em cerca de 15% do que quando comparamos com a classe anti-vacina da figura 5.3, mostrando que a proporção de usuários que expressam-se de forma positiva é maior. E não somente, mas também que o tipo de sentimento mais expresso pelos *tweets* de toda classe pró-vacina é o sentimento de caráter positivo, que somando-se tanto muito positivo com positivo, mostra-se que é de 44,3% ao total, superando inclusive a classe de sentimento neutro por 8% de diferença. Isso deve-se ao fato de que muitos *tweets* que são classificados como pró-vacina, expressam-se de forma positiva a respeito da chegada da vacina contra a COVID-19. Algo que foi tão esperado aqui no Brasil, pois foi a única solução encontrada pelos cientistas e agentes da saúde para combater a pandemia (PERES, 2021).

Figura 5.5: Vinte palavras-chave mais usadas por usuários da classe pró-vacina




Fonte: (HALLBERG, 2021)

Figura 5.6: Gráfico de sentimentos da classe pró-vacina sobre palavra vida

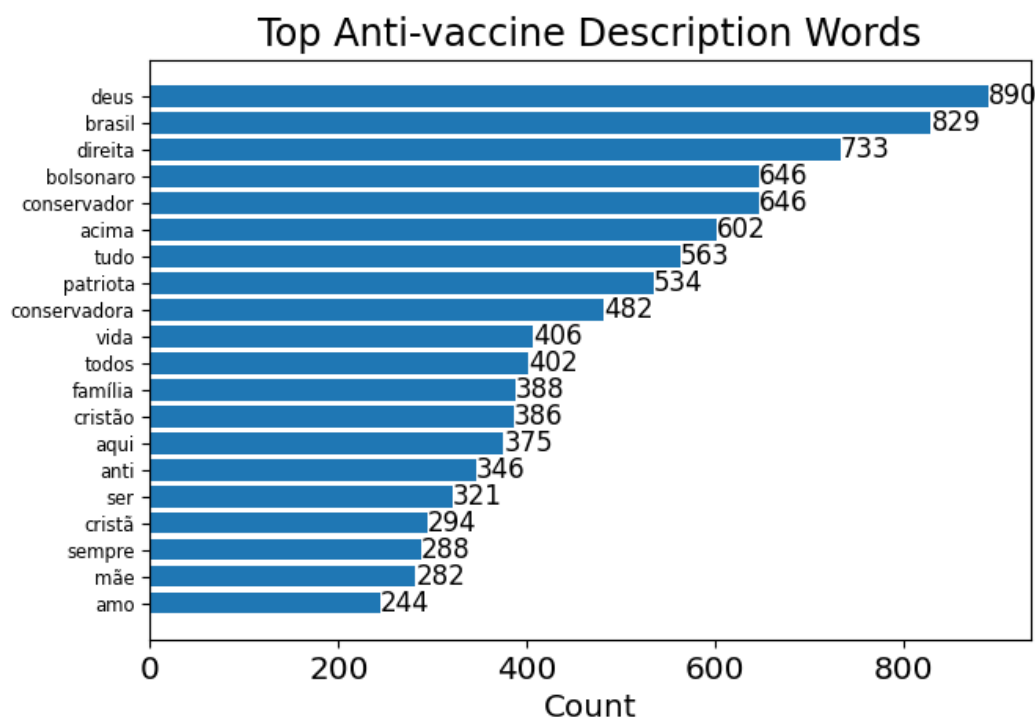
Sentimentos - Classe pró-vacina

Palavra-chave: Vida



Fonte: Elaborado pelo autor

Figura 5.7: Vinte palavras-chave mais usadas por usuários da classe anti-vacina



Fonte: (HALLBERG, 2021)

É notável também, que o tópico sobre política está diretamente associada ao tópico das vacinas e vacinação, assim como bem apontado pelo trabalho (HALLBERG, 2021), e que muitas pessoas estão insatisfeitas com as atitudes e ações do nosso atual presidente a respeito da pandemia de COVID-19 (DATAFOLHA, 2021). Sendo assim, existe uma grande quantidade de *tweets* no conjunto de dados que expressam sua indignação com as atitudes do governo Bolsonaro, e que acabam por “classificar” aqueles que o seguem fielmente com a expressão pejorativa de Bolsominion (BOLSOMINION).

Após várias observações empíricas sobre a classe pró-vacina do conjunto de dados, é possível notar que o sentimento negativo e o sentimento muito negativo são atribuídos a muitos *tweets* que expressam opiniões sobre o governo, e, ou, sobre o grupo de pessoas denominadas como Bolsominions, muitas vezes utilizando-se de expressões de baixo calão. E também, que vários dos sentimentos neutros dão-se a partir de dois sentimentos expressos no *tweet*, um sentimento positivo a favor das vacinas e ao início da campanha da vacinação contra a COVID-19 no Brasil, mas também acompanhados de um sentimento negativo a respeito do governo ou seus seguidores de extrema-direita, deixando então o *score* final do *tweet* com o sentimento neutro, como uma média dos dois sentimentos expressos.

Observando a figura 5.7 é possível notar que a palavra “*deus*” é a mais recorrente

nos *tweets* da classe anti-vacina, e isso demonstra um certo padrão no comportamento e crenças dos usuários deste grupo, onde podemos associar claramente usuários anti-vacina como apoiadores do governo Bolsonaro, e como desde sempre, o nosso presidente manteve um discurso de adesão a temas caros aos cristãos e evangélicos. (LEVINO, 2019). E sobretudo, o posicionamento, comportamento e estratégias de grupos religiosos e ultraconservadores com respeito às vacinas e a vacinação, que vão ao contrário dos estudos e da ciência. (AMANCIO; VELÁZQUEZ; CORREIA, 2020)


A partir da observação da figura 5.1 e da tabela 5.1, nota-se claramente que a quantidade de *tweets* da classe anti-vacina são muito menores do que quantidade de *tweets* da classe pró-vacina, algo que já era de se esperar, pois o Brasil possui um número muito maior de pessoas a favor das vacinas do que o contrário (SANCHES, 2021), e esta diferença mostra-se nos números de amostras dos *tweets* coletados.

Já ao observar a figura 5.5, a palavra mais recorrente é “*vida*”, representando o foco geral das vacinas e vacinações, que é a preservação da vida e da saúde. Vacinas essas que possuem eficácia e comprovação científica, diferentemente de outros tipos de tratamentos precoces ou com remediação comprovadamente não eficaz contra a COVID-19. A figura 5.6 mostra que o sentimento mais transmitido pelos *tweets* que contêm a palavra “*vida*” é o de caráter positivo, isto é, a soma tanto de sentimento positivo com sentimento muito positivo, totalizando 46,5% dos sentimentos relacionados a esta palavra-chave.

Figura 5.8: Gráfico da distribuição de sentimentos sobre o tópico: ano 2020

Sentimentos - Classe pró-vacina

Palavra-chave: 2020




Fonte: Elaborado pelo autor

Figura 5.9: Gráfico da distribuição de sentimentos sobre o tópico: ano 2021

Sentimentos - Classe pró-vacina

Palavra-chave: 2021



Fonte: Elaborado pelo autor

A análise de sentimentos também mostra como as pessoas categorizadas como pró-vacina, sentiam-se quando expressavam-se sobre o ano de 2020, que como observado na figura 5.8 possuía-se uma distribuição bem simétrica, porém infelizmente isso também mostra o quão negativo era a atmosfera sobre o assunto. No início da pandemia, ainda não sabíamos certamente como combater a COVID-19, e o fato de ser um vírus tão facilmente transmissível e além de tudo, muitas vezes letal, os sentimentos negativos acabaram sendo bem expressos como capturado nos *tweets* do conjunto de dados. Já o tópico ano 2021, com diversas vacinas para o coronavírus já desenvolvidas, nota-se um claro aumento de positividade na atmosfera dos sentimentos expressos pelos *tweets* com relação ao ano de 2021. Como observado na figura 5.9, os sentimentos positivo e muito positivo somam 51,7% do total de sentimentos, e já a soma de negativos e muito negativos caíram para 14,9%, o que demonstra a esperança e alegria em geral da classe pró-vacina com relação ao ano de 2021, com respeito a chegada das vacinas e o início da campanha de vacinação contra a COVID-19 no Brasil. (OPAS/OMS, 2021)

5.3 Análise sobre as métricas resultantes

Após a execução do segundo *script*, foi gerado inicialmente trinta conjuntos de métricas e realiza-se então uma média destes valores com o objetivo de avaliar-se o quão preciso foi o modelo de predição e classificação dos *tweets*. Este primeiro experimento, que não utiliza-se da *feature* da análise de sentimentos, chamado de *baseline*, apresentou os seguintes resultados:

Tabela 5.2: Métricas do experimento *baseline*

<i>TF-IDF</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Anti-vacina	0.8497(± 0.0075)	0.7990(± 0.0076)	0.8235(± 0.0058)
Pró-vacina	0.8103(± 0.0061)	0.8586(± 0.0081)	0.8337(± 0.0056)

Fonte: Elaborado pelo autor

As métricas utilizadas para verificar a qualidade da classificação do modelo são *precision*, *recall*, e *F1-score*.

$$Precision = \frac{VerdadeirosPositivos}{VerdadeirosPositivos + FalsosPositivos} \quad (5.1)$$

Precision, ou precisão, em resumo é, de todos os dados classificados como positivos pelo modelo, quantos são realmente positivos.

$$Recall = \frac{VerdadeirosPositivos}{VerdadeirosPositivos + FalsosNegativos} \quad (5.2)$$

Recall, ou revocação, em resumo é a porcentagem de dados classificados como positivos pelo modelo comparado com a quantidade real de positivos que existem na amostra. Ou em outras palavras, dentre todas as situações de classe positivo como valor esperado, quantas estão corretas.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision + Recall} \quad (5.3)$$

O *F1-score* é uma média harmônica entre as outras duas, sendo assim uma métrica que une os valores de *precision* e *recall* a fim de trazer um único número que determine a qualidade geral do modelo.

Sendo assim, ao observar-se a tabela 5.2, o modelo *baseline* utilizado para tentar prever a classe dos *tweets* no conjunto de dados em anti-vacina e pró-vacina possui *F1-score* de 82,35% e 83,37% respectivamente, com um desvio padrão de 0,58% e 0,56% respectivamente.

Tabela 5.3: Métricas do experimento com a análise de sentimentos

<i>TF-IDF+Sentiment</i>	<i>Precision</i>	<i>Recall</i>	<i>F1-score</i>
Anti-vacina	0.8483(± 0.0074)	0.8028(± 0.0087)	0.8249(± 0.0049)
Pró-vacina	0.8129(± 0.0062)	0.8563(± 0.0088)	0.8340(± 0.0047)

Fonte: Elaborado pelo autor

A tabela 5.3 mostra o resultado da média das métricas do modelo utilizando-se agora a nova *feature* dos *scores* da análise de sentimentos realizada no experimento. Embora o modelo tenha obtido um pequeno ganho em suas métricas, este não é de maneira expressiva. O *F1-score* observado é de 82,49% para a classe anti-vacina e 83,40% para a classe pró-vacina, com um desvio padrão um pouco menor, agora de 0,49% e 0,47% respectivamente.

O experimento como um todo, entretanto, reforça que o modelo estado da arte *Linear SVC*, utilizando-se de uma pontuação TF-IDF, possui grande eficácia em sua capacidade de classificação e rotulação de classes sobre um grande volume de dados, como o conjunto de *tweets* coletados.

5.4 Desafios da classificação de textos

Após a realização dos experimentos deste trabalho, nota-se que ainda existem certas dificuldades a serem superadas no área de classificação de textos. A maior dificuldade encontrada é realizar a classificação correta de um texto, neste caso um *tweet*, que contém ironia. Depois de várias observações empíricas sobre o conjunto de dados, é possível notar que *tweets* de caráter irônico geralmente estão classificados erroneamente, e isto se dá pelo fato de que o modelo irá analisar as palavras contidas na *string* do *tweet* e fazer a classificação como de costume, porém as palavras contidas no *tweet* naquele contexto querem expressar exatamente o oposto do que se está sendo escrito, e discernir este contexto de ironia ainda é um certo desafio para inteligências artificiais, algo que muitas vezes é complicado até para nós, seres humanos, de captar a ironia em um texto, pois esta geralmente requer sinais além do significado das palavras, mas indicações talvez como mudança no padrão da voz, gestos, expressões faciais ou até mesmo o contexto atual.

Um exemplo de *tweet* irônico seria “*Isso nao tomem mesmo, cuidado com os microchips*”, que foi classificado como anti-vacina pelo fato de parecer que o usuário está apoiando outros a não tomarem a vacina, mas na verdade é um *tweet* ironizando o fato de que muitas pessoas adeptas ao movimento anti-vacina realmente acreditam que as novas

vacinas contra a COVID-19 possuem microchips, ou algo semelhante, para rastreamento e monitoramento do indivíduo (OLIVEIRA, 2021). Como o modelo não “enxerga” estes sinais necessários, não era de se esperar que ele fosse capaz de inferir tal raciocínio lógico sobre o *tweets* contendo ironia. Entretanto, diversos outros *tweets* são de caráter irônico no conjunto de dados, pois as redes sociais são plataformas onde as pessoas adoram compartilhar os famosos *memes* (MEMES) da internet.

5.5 Limitações do trabalho

Os experimentos para avaliar as métricas do modelo de classificação estão atrelados às classes anti-vacina e pró-vacina previamente classificados pelo trabalho (HALLBERG, 2021), pois como já mencionado, a coleta e geração do conjunto de dados se dá a partir daquele trabalho. Sendo assim, quando utilizado neste trabalho e experimentos, o algoritmo que irá tentar avaliar e classificar os *tweets* como a favor ou contra a vacinação, utilizará como gabarito a classificação feita anteriormente por aquele trabalho, entretanto os desafios de classificação de texto com respeito ao contexto de ironia ainda se aplica, portanto não necessariamente todas as classes dos *tweets* estão devidamente classificadas, isto é, pode-se encontrar *tweets* onde a ironia o afeta, e portanto o modelo classifica-o como da classe oposta. Sendo assim, caso o modelo deste experimento o classifique de maneira correta, o gabarito do controle de teste iria acusar como estando na classe errada, e desta maneira acaba interferindo nas métricas de avaliação.

Os *tweets* do conjunto de dados que antes foram classificados a partir das *hashtags* incluídas nos mesmos, muitas vezes eram em resposta ao assunto em que se trava. Por exemplo, o *tweet* “o odio que eu tenho de quem ta na tag #EuNaoVouTomarVacina e que vao se beneficiar de quem tomou pela imunizacao de rebanho e vao dizer que estao imunes do nada”, como facilmente observável, o *tweet* deveria ser classificado como pertencente a classe pró-vacina, mas como a *hashtag* #EuNaoVouTomarVacina está presente no *tweet*, o trabalho (HALLBERG, 2021) o classifica como anti-vacina, por utilizar-se de um algoritmo que realiza a classificação a partir das *hashtags* inclusas no *tweet*. Neste experimento, o mesmo *tweet* após passar pela análise de sentimento, obteve um *score* de -1.2149, onde é de fato demonstrado um sentimento negativo, de ódio no caso. Entretanto, mesmo que o modelo utilizado neste trabalho classifique o *tweet* mencionado como pró-vacina, seu verdadeiro posicionamento, na parte de teste com *cross-validation* do algoritmo deste experimento, ele o acusaria de estar errado, pois não confere com o gabarito

do conjunto teste. Para contornar este problema, o conjunto de dados deveria possuir uma distribuição de classes avaliada e atribuída manualmente por um ser humano, e ainda assim revisada para que não contenha erros. Só assim, o gabarito estaria realmente correto em relação às classes anti-vacina e pró-vacina, porém uma tarefa manual desta maneira não seria viável para um conjunto de dados tão grande como o coletado.

Uma outra limitação que surgiu ao pesquisar-se para iniciar-se os experimentos do trabalho, foi o fato de que não encontrou-se nenhum modelo classificador para análise de sentimentos em português, treinando para o contexto do trabalho. E gerar e treinar um modelo capaz dessa tarefa seria um outro trabalho, tão grande ou talvez maior que o realizado aqui. Outros diversos estudos e trabalhos relacionados à análise de sentimentos, utilizaram-se de um tradutor automático de textos, para transformar textos de português para o inglês e vice-versa. Felizmente o modelo utilizado nos experimentos, como já mencionado, foi treinado com *tweets* em múltiplas línguas, onde o português estava contido.

6 CONCLUSÃO

O trabalho realizado utilizou-se de algoritmos de ML para classificar um grande conjunto de dados, *tweets* que falam a respeito do tópico de vacinas e, ou, vacinação, em classes chamadas de anti-vacina e pró-vacina. Em seguida realiza-se uma análise de sentimentos sobre o conjunto de dados, atribuindo-se um sentimento para cada *tweet*, dentre a semântica de sentimentos muito positivo, positivo, neutro, negativo e muito negativo. Realizou-se então uma segunda classificação com o modelo SVM sobre o conjunto de dados, agora com a *feature* extra do valor destes sentimentos de cada *tweet*, e gerou-se métricas para avaliar o desempenho de ambas as classificações, uma com e uma sem a análise de sentimentos. Em seguida, foi feita uma análise sobre o contexto e motivos dos sentimentos, mostrando-se como se distribuem os cinco sentimentos em ambas as classes anti-vacina e pró-vacina. Em especial, notou-se que a política está extremamente entrelaçada com o tópico de vacinas e vacinação. Que houve um aumento na positividade dos sentimentos em relação ao tópico ano 2021 quando comparado com o tópico ano 2020. Que o sentimento mais expressado pela classe pró-vacina é o positivo, já pela classe anti-vacina é o neutro. E que os usuários da rede social Twitter manifestam-se de diversas formas, expressando seus sentimentos, opiniões e crenças através dos *tweets*.

A partir dos experimentos realizados no trabalho, concluiu-se que a metodologia proposta em incorporar os *scores* da análise de sentimentos como uma das *features* em um modelo estado da arte *Linear SVC*, quando utilizando-se uma pontuação TF-IDF, não avança de forma significativa as suas classificações, entretanto demonstra a sua atual eficácia para o seu devido propósito.

Como trabalho futuro, seria interessante aplicar-se a metodologia de análise de sentimentos realizada, mas expandindo-se a outros conjuntos de dados com *tweets* de outras línguas e países. Comparando então como os usuários destes países comportam-se, expressam-se e sentem-se em relação ao tópico de vacinas e vacinação. Se aplicado aos principais e maiores países do mundo, teríamos uma análise de como comportam-se as pessoas de maneira global e como ou o quão diferente um certo país em específico encontra-se atualmente sobre este assunto.

REFERÊNCIAS

- AMANCIO, N. L.; VELÁZQUEZ, G. Z. K.; CORREIA, A. D. M. **Poderes impuros**. Publica, 2020. Available from Internet: <<https://apublica.org/2020/06/poderes-impuros/>>.
- ARNDT, G. J. et al. Quem é de direita toma cloroquina, quem é de esquerda toma... vacina. **Revista Psicologia Política**, scieloapsic, v. 21, p. 608 – 626, 08 2021. ISSN 1519-549X. Available from Internet: <http://pepsic.bvsalud.org/scielo.php?script=sci_arttext&pid=S1519-549X2021000200021>.
- BECHINI, A. et al. Stance analysis of twitter users: The case of the vaccination topic in italy. **IEEE Intelligent Systems**, v. 36, n. 5, p. 131–139, 2021.
- BERTASIUS, G.; WANG, H.; TORRESANI, L. **Is Space-Time Attention All You Need for Video Understanding?** arXiv, 2021. Available from Internet: <<https://arxiv.org/abs/2102.05095>>.
- BOLSOMINION. Available from Internet: <<https://pt.wikipedia.org/wiki/Bolsominion>>.
- DATAFOLHA. **Sobe reprovação ao trabalho de Bolsonaro na pandemia**. Datafolha Instituto de Pesquisas, 2021. Available from Internet: <<https://datafolha.folha.uol.com.br/opiniaopublica/2021/07/1989335-sobe-reprovacao-ao-trabalho-de-bolsonaro-na-pandemia.shtml>>.
- DATASET. Available from Internet: <https://docs.google.com/spreadsheets/d/1N19UEgjoAN8XE16mPv6gavz_2U7TdJpMlbA5WMV-g3E/>.
- GISMONDI, A. **Top 27 Social Media Apps for Your 2021 Strategy**. 2021. Available from Internet: <<https://www.kubbco.com/top-27-social-media-apps-for-your-2021-strategy/>>.
- GOMIDE, J. et al. Dengue surveillance based on a computational model of spatio-temporal locality of twitter. In: **Proceedings of the 3rd International Web Science Conference**. New York, NY, USA: Association for Computing Machinery, 2011. (WebSci '11). ISBN 9781450308557. Available from Internet: <<https://doi.org/10.1145/2527031.2527049>>.
- GRIFFIN, A.; HAUSER, J. The voice of the customer. **Marketing Science**, v. 12, 02 1991.
- HALLBERG, A. G. **Uma análise das opiniões de usuários do Twitter sobre vacinas utilizando técnicas de aprendizado de máquina**. 2021. Monografia (Bacharel em Engenharia da Computação), UFRGS (Universidade Federal do Rio Grande do Sul), Porto Alegre, Brasil.
- JURAFSKY, D.; MARTIN, J. H. **Speech and Language Processing: An Introduction to Natural Language Processing, Computational Linguistics and Speech Recognition (Prentice Hall Series in Artificial Intelligence)**. 1. ed. Prentice Hall, 2000. ISBN 0130950696. Available from Internet: <http://www.amazon.com/Speech-Language-Processing-Introduction-Computational/dp/0130950696%3FSubscriptionId%3D13CT5CVB80YFWJEPWS02%26tag%3Dws%26linkCode%3Dsm2&pf_rd_p%3D8c8c8c8c-8c8c-4c8c-8c8c-8c8c8c8c8c8c>.

26linkCode%3Dxm2%26camp%3D2025%26creative%3D165953%26creativeASIN%3D0130950696>.

LAMPERT, J.; LAMPERT, C. H. Overcoming rare-language discrimination in multi-lingual sentiment analysis. In: **IEEE International Conference on Big Data (BigData)**. [S.l.: s.n.], 2021. Special Session: Machine Learning on Big Data.

LARSSON, P. **COVID-19 anti-vaxxers use the same arguments from 135 years ago**. 2020. Available from Internet: <<https://theconversation.com/covid-19-anti-vaxxers-use-the-same-arguments-from-135-years-ago-145592>>.

LEVINO, R. **Bolsonaro e o Cristianismo enquanto slogan**. ÉPOCA, 2019. Available from Internet: <<https://oglobo.globo.com/epoca/bolsonaro-o-cristianismo-enquanto-slogan-23413498>>.

LINDSAY, G. W. Attention in psychology, neuroscience, and machine learning. **Frontiers in Computational Neuroscience**, v. 14, 2020. ISSN 1662-5188. Available from Internet: <<https://www.frontiersin.org/article/10.3389/fncom.2020.00029>>.

LUTKEVICH, B. **BERT Language Model**. 2020. Available from Internet: <<https://www.techtarget.com/searchenterpriseai/definition/BERT-language-model>>.

MEMES. Available from Internet: <[https://pt.wikipedia.org/wiki/Meme_\(Internet\)](https://pt.wikipedia.org/wiki/Meme_(Internet))>.

MIGUEL, R. dos S.; BARBOSA, Y. de A. M. **Uma ferramenta para análise de sentimentos de tweets em português**. 2019. Departamento de Ciências Exatas - Universidade Federal da Paraíba (UFPB). Available from Internet: <<https://si.dcx.ufpb.br/wp-content/uploads/2019/03/TCC-Rodrigo-dos-Santos.pdf>>.

NEVES, L. **O que é NLP: Guia sobre o processamento de linguagem natural**. 2018. Available from Internet: <<https://weni.ai/blog/processamento-de-linguagem-natural-o-que-e>>.

OLIVEIRA, P. I. de. **Vacina magnetizada? Microchips na injeção? Veja os fatos sobre vacinas**. Agência Brasil - Brasília, 2021. Available from Internet: <<https://agenciabrasil.ebc.com.br/saude/noticia/2021-07/vacina-magnetizada-microchips-na-injecao-veja-os-fatos-sobre-vacinas>>.

OPAS/OMS. **Brasil receberá as primeiras vacinas contra COVID-19 por meio do Mecanismo COVAX neste domingo**. 2021. Available from Internet: <<https://www.paho.org/pt/noticias/21-3-2021-brasil-recebera-primeiras-vacinas-contracovid-19-por-meio-do-mecanismo-covax>>.

PERES, L. F. S. A. C. **Vacina é a única solução**. 2021. Available from Internet: <<https://radis.ensp.fiocruz.br/index.php/home/entrevista/vacina-e-a-unica-solucao>>.

POLAKIEWICZ, R. **Vacinas de Covid-19: há uma esperança...** 2020. Available from Internet: <<https://pebmed.com.br/vacinas-de-covid-19-ha-uma-esperanca/>>.

PROCESSED-DATASET. Available from Internet: <https://docs.google.com/spreadsheets/d/1nDqazeUzB_IOTc2uAP0hHHwDEsjcq64Tu5vSejF5rxk/>.

RAY, S. **Understanding Support Vector Machine(SVM)**. 2017. Available from Internet: <<https://www.analyticsvidhya.com/blog/2017/09/understaing-support-vector-machine-example-code/>>.

SANCHES, M. **Brasil é país com menor rejeição à vacina na América Latina, diz Banco Mundial**. BBC News Brasil em Washington, 2021. Available from Internet: <<https://www.bbc.com/portuguese/brasil-59468300>>.

SCIKIT-LEARN. Available from Internet: <<https://scikit-learn.org/stable/index.html>>.

SUDHIR, P.; SURESH, V. D. Comparative study of various approaches, applications and classifiers for sentiment analysis. **Global Transitions Proceedings**, v. 2, n. 2, p. 205–211, 2021. ISSN 2666-285X. International Conference on Computing System and its Applications (ICCSA- 2021). Available from Internet: <<https://www.sciencedirect.com/science/article/pii/S2666285X21000327>>.

SUMMERS, E. et al. **DocNow/twarc: v2.10.3**. Zenodo, 2021. Available from Internet: <<https://doi.org/10.5281/zenodo.6474393>>.

TAIL. **Word Embeddings — Representação vetorial de textos para Machine Learning**. 2020. Available from Internet: <<https://tail-ufpb.medium.com/word-embeddings-representa%C3%A7%C3%A3o-vetorial-de-textos-para-machine-learning-74a227e18478>>.

TEAM, G. L. **An Introduction to Bag of Words (BoW) | What is Bag of Words?** 2020. Available from Internet: <<https://www.mygreatlearning.com/blog/bag-of-words/>>.

TORRES, B. A.; PIMENTA, D. A. C.; MORAES, L. C. D. **Um Estudo da Aceitação das Vacinas Contra a Covid-19 na Rede Social Twitter Utilizando Ferramentas de Análise Sentimental**. 2020. Faculdade de Tecnologia de Ribeirão Preto (Fatec). Available from Internet: <http://www.fatecrp.edu.br/WorkTec/edicoes/2020-2/trabalhos/II-Worktec-Beatriz_Souza_e_Larissa_Moraes.pdf>.

TRANSFORMERS. Available from Internet: <<https://huggingface.co/docs/transformers/index>>.

UNIDECODE. Available from Internet: <<https://pypi.org/project/Unidecode/>>.

VASWANI, A. et al. **Attention Is All You Need**. arXiv, 2017. Available from Internet: <<https://arxiv.org/abs/1706.03762>>.

WORD EMBEDDINGS. **Word embedding — Wikipedia, The Free Encyclopedia**. 2022. Available from Internet: <https://en.wikipedia.org/w/index.php?title=Word_embedding&oldid=1085884487>.

ZACHARIAS, C. **TWINT - Twitter Intelligence Tool**. [S.l.]: GitHub, 2018. <<https://github.com/twintproject/twint>>.