

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

PIETRA THAMY SOFIA DA FONSECA FREITAS

**Explorando os Limites da Análise de
Sentimentos como Ferramenta para
Inferência Automática de Eventos
Relacionados à Pandemia COVID-19 no
Brasil**

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

Orientador: Prof. Dr. Mariana Recamonde
Mendoza

Co-orientador: Prof. Dr. Bruno Castro da Silva

Porto Alegre
2021

UNIVERSIDADE FEDERAL DO RIO GRANDE DO SUL

Reitor: Prof. Carlos André Bulhões

Vice-Reitora: Prof^ª. Patricia Pranke

Pró-Reitora 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

“Meninos mimados não podem reger a nação.” —(CRIOLO, 2017)

AGRADECIMENTOS

Agradeço à minha mãe, Bernardina, por fazer o impossível para que, hoje, eu conquistasse o primeiro diploma de ensino superior da família. És uma mulher incrível e tenho muito orgulho de ser tua filha.

Agradeço ao meu orientador, Bruno, por ser um professor singular e inspirador. Por apoiar seus alunos e alunas não somente dentro da sala de aula, mas nas adversidades que surgem fora dela. E, principalmente, por nunca deixar o medo me vencer.

Agradeço à minha terapeuta, Elisa, que acompanha minha jornada há anos e conhece meus sonhos e medos mais profundos. A ela, dedico esse trabalho, para que ela saiba—mais uma vez—a importância que teve na minha luta contra os meus monstros.

Agradeço, também, à cada mulher que luta contra as estatísticas para entrar e se manter dentro da área de computação. Em especial, agradeço à minha orientadora, Mariana, por ser uma excelente professora e representar uma nova geração de mulheres lendárias da computação; à professora e pesquisadora Ana Bazzan, que é referência mundial na área; e, finalmente, à professora e pesquisadora Carla Freitas, primeira e única mulher na direção do Instituto de Informática da UFRGS. Que, agora, eu possa ser essa referência para outras mulheres.

Por fim, dedico este trabalho ao meu pai, Célio, que não teve a oportunidade de passar do ensino básico, mas que era um amante dos livros. Sempre me incentivou a estudar e manteve a casa rodeada de computadores; foi quem despertou, em mim, a paixão por computação. Seria um sonho te mostrar onde cheguei. Se tu és uma estrelhinha, hoje, essa estrelhinha brilha mais do que nunca.

RESUMO

Análise de sentimentos é uma das áreas de aprendizado de máquina que se destaca frente ao entendimento dos efeitos da pandemia COVID-19 na população. O presente trabalho se propõe a abordar as limitações da análise automática de sentimentos no que diz respeito à sua capacidade de inferir quando eventos de relevância para a pandemia ocorreram, com base na análise de opiniões políticas expressas no Twitter acerca da atuação do governo federal no contexto da pandemia no Brasil. Além disso, também discutimos possíveis correlações que possam existir entre o sentimento da população e outros dados relevantes sobre o governo federal, tal como sua taxa de aprovação e variações na taxa de mortes por COVID-19. A fim de executar tais análises, o presente trabalho irá analisar *tweets* coletados na região de Porto Alegre entre o dia 1o de janeiro de 2020 e o dia 11 de setembro de 2021. Serão analisados *tweets* cujos conteúdos possam indicar uma opinião (negativa ou não) a respeito da condução do governo federal durante a pandemia COVID-19. O objetivo deste trabalho é discutir diversas hipóteses acerca do que é possível (ou não) inferir com base na análise automática de sentimentos desses *tweets*. Iremos mostrar que, em vários casos, *é possível* utilizar modelos de análise de sentimentos para identificar alguns tipos de eventos relevantes. Por outro lado, iremos mostrar que *não é possível*, por exemplo, inferir—com base apenas na análise de sentimentos em *tweets*— variações temporais na taxa de aprovação do presidente. Concluimos, portanto, que a análise automática de dados de redes sociais pode refletir eventos relevantes pra a sociedade, mas que há limitações, e que tais análises (e suas interpretações) precisam ser feitas de forma cuidadosa.

Palavras-chave: Aprendizado de Máquina. Análise de Sentimentos. Redes Sociais.

Exploring the Possibilities and Limitations of Sentiment Analysis as a Tool for Automatically Inferring Relevant Events in the Context of the COVID-19 Pandemic in Brazil

ABSTRACT

Sentiment analysis is a machine learning area that has shown promise when it comes to understanding the impact of the COVID-19 pandemic on particular populations. In this work, we study the limitations of techniques for sentiment analysis regarding their capability of automatically inferring when relevant events (in the context of the pandemic) have happened in Brazil. Furthermore, we will also investigate possible correlations that may exist between sentiments expressed by a given population and a set of diverse metrics related to the Brazilian federal government, such as its approval rate and temporal variations in the number of deaths due to COVID-19. To perform these analyses, this work will analyze *tweets* made in the city of Porto Alegre between January 1, 2020, and September 11, 2021. We will analyze tweets whose contents may reflect opinions or sentiments (which might be negative or not) regarding the federal government's performance in dealing with the COVID-19 pandemic. The goal of this work is to discuss a series of hypotheses about what is possible (and what is not possible) to infer based solely on the automatic sentiment analysis of *tweets*. We will empirically show that, in some cases, *it is possible* for sentiment analysis models to identify particular types of relevant events. We will also show, by contrast, that sometimes *it is not possible* to infer, for example (based only on performing sentiment analysis of tweets) temporal variations to the president's approval rate. We conclude, as a result of our experiments, that the analysis of data from social media platforms (Twitter, in particular) might be used to identify relevant events automatically, but that these methods are also limited and that any resulting interpretations and conclusions need to be done carefully by machine learning practitioners.

Keywords: Machine Learning, Sentiment Analysis, Social Media.

LISTA DE FIGURAS

Figura 2.1 Ilustração de uma rede neural.....	16
Figura 2.2 Exemplo de um conjunto de dados de entrada para uma árvore de decisão..	17
Figura 2.3 Exemplo de uma árvore de decisão.	18
Figura 6.1 Avaliação do Governo Jair Bolsonaro vs. Quantidade de Tweets Negativos	43
Figura 6.2 Mortes Diárias por COVID-19 vs. Quantidade de Tweets Negativos	45
Figura 6.3 Derivadas: Mortes Diárias por COVID-19 vs. Quantidade de Tweets Negativos.....	46
Figura 6.4 Novos Casos de COVID-19 vs. Quantidade de Tweets Negativos.....	48
Figura 6.5 Quantidade de Tweets Negativos e Eventos Relevantes	52

LISTA DE TABELAS

Tabela 2.1	Tabela de Palavras Mais Similares à Palavra <i>France</i> Utilizando <i>word2vec</i> ..	21
Tabela 5.1	Tabela de Performance dos Algoritmos Recebendo TF-IDF como Entrada.	37
Tabela 5.2	Tabela de Performance dos Algoritmos Recebendo <i>word2vec</i> como Entrada	40
Tabela 6.1	Tabela de Cálculo do DTW entre Gráfico de Tweets Negativos e Outros Gráficos	47
Tabela 6.2	Descrição dos Eventos Destacados na Figura 6.5.	49

SUMÁRIO

1 INTRODUÇÃO	10
2 FUNDAMENTAÇÃO TEÓRICA	13
2.1 Aprendizado de Máquina para Problemas de Classificação	13
2.1.1 Regressão Logística	14
2.1.2 Redes Neurais	15
2.1.3 Florestas Aleatórias	16
2.2 Análise de Sentimentos	19
2.2.1 TF-IDF	19
2.2.2 Word2vec	20
3 TRABALHOS RELACIONADOS	22
4 METODOLOGIA EXPERIMENTAL	25
4.1 Coleta dos Dados	25
4.1.1 Conjunto de Dados de Treinamento e Teste	25
4.1.2 Conjunto de Dados para Análise das Hipóteses	26
4.2 Rotulação dos Dados	27
4.3 Pré-Processamentos dos Dados	29
4.4 Experimentos a Serem Conduzidos	29
4.5 Métricas de Avaliação de Hipóteses	30
4.6 Possíveis Limitações nas Análises Efetuadas	31
4.6.1 Rotulação dos Dados	32
4.6.2 Tradução dos Tweets para o Português	32
4.6.3 Filtragem na Coleta dos Tweets	33
4.6.4 Linha do Tempo de Coleta dos Dados	33
4.6.5 Definição de Eventos Relevantes	34
5 METODOLOGIA PROPOSTA	35
5.1 Modelo de Aprendizado de Máquina	35
5.2 Representação dos Dados	36
5.2.1 Representação de Tweets usando Formato TF-IDF	36
5.2.2 Representação de Tweets usando formato Word2vec	38
6 RESULTADOS	42
6.1 Hipótese 1: Correlação entre Reprovação do Governo Federal e Quantidade de Tweets Negativos	42
6.2 Hipótese 2: Correlação entre Taxa de Mortes Diária por COVID-19 e Quantidade de Tweets Negativos	44
6.3 Hipótese 3: Correlação entre Novos Casos Diários de COVID-19 e Quantidade de Tweets Negativos	47
6.4 Hipótese 4: Correlação entre Eventos Relevantes e Quantidade de Tweets Negativos	49
6.4.1 Eventos Relevantes Relacionados a Protestos Contra ou a Favor do Presidente	53
6.4.2 Eventos Relevantes Associados a Aliados do Presidente	53
6.4.3 Falas e Ações Polêmicas do Presidente Sobre a Pandemia	54
6.4.4 Eventos Relevantes na CPI da Pandemia	54
6.4.5 Eventos Relevantes Relacionados à Pandemia no Brasil	54
6.4.6 Eventos Relevantes Associados a Não Aliados do Presidente	54
7 CONCLUSÃO	56
REFERÊNCIAS	58

1 INTRODUÇÃO

Entre 2019 e 2021, uma doença comoveu populações inteiras e líderes ao redor do mundo. A pandemia COVID-19 matou, até a escrita deste trabalho, cinco milhões de pessoas no mundo inteiro (RITCHIE EDOUARD MATHIEU; ROSER, 2020). Com isso, diversas áreas de aprendizado de máquina se apresentaram como possíveis fontes de informação capazes de ajudar a sociedade a lidar com, e melhor compreender, os efeitos da COVID-19. Uma das direções importantes diz respeito à análise dos efeitos sociais da pandemia: como as pessoas reagem, no âmbito público, a ela, através das opiniões que compartilham em meios diversos; e também no que diz respeito ao impacto da pandemia em decisões políticas. Nesse contexto, uma área específica de aprendizado de máquina se destaca no que se refere à *análise automática de sentimentos* da população frente a esse cenário.

A análise de sentimentos automática, através do uso de algoritmos de Aprendizado de Máquina, pode auxiliar na avaliação da percepção da população, expressa em redes sociais, sobre um determinado assunto. Algumas empresas utilizam essa ferramenta, por exemplo, para analisar, em tempo real, a percepção dos consumidores sobre um determinado produto (RANJAN; SOOD; VERMA, 2018). A gama de assuntos que podem ser analisados através da análise de sentimentos automática é vasta: esportes, entretenimento, música, e, até mesmo, política. Durante um debate entre candidatos políticos, por exemplo, é possível analisar o sentimento da população nas redes sociais, automaticamente, acerca da posição de cada candidato, e ainda quem teria vencido o debate se considerássemos apenas o sentimento da população nessas redes (ANDRIOT et al., 2020).

Com o avanço no alcance das redes sociais, tornou-se possível aplicar análise de sentimentos sobre o conteúdo publicado em tempo real pela população em suas redes sociais. Esse conteúdo possui diversas vantagens para a análise de sentimentos. A primeira é em relação a ser um tipo de feedback imediato da população sobre um determinado tópico—possivelmente sendo uma opinião mais genuína. Além disso, é possível também analisar o sentimento de milhões de pessoas ao mesmo tempo, promovendo diversidade de pontos de vista.

Nesse sentido, uma das redes sociais mais populares no mundo é o Twitter. De acordo com um trabalho publicado em 2021 pela empresa hootsuite sobre o Twitter (NEWBERRY, 2021), a plataforma é o sexto aplicativo com mais usuários ativos mensalmente e é a rede social mais acessada no Japão. Cada postagem no Twitter possui 280

caracteres, é realizada por um usuário que precisa possuir uma conta ativa na plataforma, pode conter hashtags (etiquetas que possibilitam a identificação de conteúdos correlacionados), assim como data, hora e geolocalização (caso o usuário a informe).

Há limitações, no entanto, sobre o que pode se inferir utilizando-se dados de redes sociais. No Brasil, mesmo sendo o país com a segunda maior quantidade de usuários da rede social Twitter, existem cerca de 46 milhões de usuários brasileiros (ECMETRICS,), enquanto que a população do país é de cerca de 212 milhões de pessoas. Contudo, 46 milhões de brasileiros não tem acesso à internet (MELITO, 2020). Nesse sentido, teriam as redes sociais dados representativos para inferir a opinião de uma população sobre um determinado tema? Outro ponto de atenção está relacionado à influência das grandes mídias no posicionamento da população nas redes sociais. Atualmente, as mídias impressas e tradicionais não são mais as únicas fontes de formação de opinião. Com o advento das redes sociais, os chamados *influenciadores* também possuem um papel importante na formação de opinião da população (SHMARGAD, 2018). Portanto, teriam ainda as grandes mídias tradicionais impacto na percepção da população sobre eventos e personagens relevantes no contexto política?

O presente trabalho visa abordar as limitações da análise automática de sentimentos no contexto específico de eventos e opiniões políticas expressas por pessoas na cidade de Porto Alegre, no Twitter, a respeito da atuação do governo federal no contexto da pandemia COVID-19 no Brasil. Nele, será avaliado se é possível identificar automaticamente, através de algoritmos de análise de sentimentos, possíveis correlações entre eventos relevantes e o sentimento da população acerca da atuação do governo federal no contexto da pandemia. Além disso, também serão discutidas possíveis correlações entre o sentimento da população e outros dados relevantes sobre o governo federal, como sua taxa de aprovação, assim como variações na taxa de mortes por COVID-19. A fim de executar tais análises, o presente trabalho irá analisar tweets coletados na região de Porto Alegre entre o dia 1o de janeiro de 2020 e o dia 11 de setembro de 2021. Serão analisados tweets cujo conteúdo possa indicar a expressão (negativa ou não) a respeito da condução do governo federal durante a pandemia COVID-19. O objetivo deste trabalho, em particular, é discutir diversas hipóteses sobre o que é possível (ou não) inferir com base na análise automática de sentimentos desses tweets.

Ao contrário do que é proposto em análise de sentimentos clássica (SHELAR; HUANG, 2018) entretanto, neste trabalho não estamos interessados em verificar se o sentimento dos dados é positivo, negativo ou neutro. Para tanto, foi construído—especificamente

para este trabalho—um conjunto de dados em que o critério definido para classificar um tweet como negativo corresponde à verificação sobre se o texto nele contido expressa, em particular, um *sentimento negativo sobre o governo federal no contexto da pandemia*. Caso o tweet expressasse qualquer outro sentimento que não se encaixasse estritamente no critério descrito acima, o tweet era classificado com o sentimento denominado, pela autora, como pertencente à classe *outros*, e não possui relevância, no que diz respeito à análise de sentimentos no contexto deste trabalho. Um dos motivos para essa decisão metodológica é focar em expressões e opiniões *objetivas* sobre a condução do governo federal durante a pandemia COVID-19. Frequentemente, opiniões negativas apresentam desafios para técnicas de análise de sentimentos automática de dados, em virtude do formato de escrita e do uso de diferentes figuras de linguagem no texto, como ironia e sarcasmo (FARIAS; ROSSO, 2017).

Este trabalho está estruturado em sete capítulos. No Capítulo 2, será apresentada a revisão da fundamentação teórica de métodos e conceitos básicos necessários para que a leitora possa entender a metodologia e os resultados deste trabalho. No Capítulo 3, serão discutidos trabalhos relacionados, e suas semelhanças e diferenças em relação ao presente trabalho. No Capítulo 4, será apresentada a metodologia de experimentação relacionada à análise dos dados do Twitter. No Capítulo 5, serão apresentadas as diferentes estratégias, avaliadas pela autora, para construção de um método de análise de sentimentos efetivo no contexto do nosso objetivo. Serão discutidas também, decisões sobre a melhor forma de representação dos dados durante o desenvolvimento deste trabalho, quais foram escolhidas e por quê. No Capítulo 6, serão apresentados os resultados e discutidas as hipóteses que foram ou não comprovadas por este trabalho. No Capítulo 7, serão, por fim, apresentados os desafios e benefícios do método proposto neste trabalho, além de futuras extensões do mesmo.

2 FUNDAMENTAÇÃO TEÓRICA

Neste capítulo, iremos discorrer sobre as principais técnicas de aprendizado de máquina utilizadas, neste trabalho, para a criação do analisador automático de sentimentos efetivo no contexto sendo analisado. Nesse sentido, iremos discutir algoritmos de aprendizado de máquina para problemas de classificação, assim como técnicas para análise de sentimentos aplicada a redes sociais.

As técnicas de aprendizado de máquina (MEDHAT; HASSAN; KORASHY, 2014) e representação de dados (LILLEBERG; ZHU; ZHANG, 2015) que serão apresentadas a seguir são estado-da-arte no que diz respeito à técnicas utilizadas para análise automática de sentimentos.

2.1 Aprendizado de Máquina para Problemas de Classificação

Existem diversas subáreas do campo conhecido como aprendizado de máquina. Esse campo é, de forma geral, dividido em três grandes áreas.

A primeira área é *Aprendizado supervisionado* corresponde ao problema de aprender a prever à qual *classe* uma determinada instância (representada por um conjunto de *features*) pertence. Esse tipo de método é conhecido como um método de classificação. Outro tipo de aprendizado supervisionado diz respeito a algoritmos de regressão. Nesses, o objetivo não é prever uma classe, e sim um valor numérico contínuo. Em aprendizado supervisionado, existe um conjunto de treinamento com dados na forma: (x_i, y_i) . Onde, $x_i \in R^d$ é um vetor com d *features* descrevendo uma instância, e y_i é a sua classe correspondente. O objetivo é aprender um modelo de predição $f : X \rightarrow Y$ capaz de fazer predições corretas.

A segunda área da aprendizado de máquina é conhecida como *aprendizado não-supervisionado*. Aqui, o objetivo é encontrar padrões nos dados, tais como grupos de instâncias similares de acordo com seus atributos. Por fim, existe também uma área conhecida como *aprendizado por reforço*, na qual o objetivo é construir um sistema de recompensas para um agente com punições e recompensas, de forma a permitir com que o agente aprenda automaticamente ações que sejam mais adequadas em cada contexto/estado. Neste trabalho, iremos focar em algoritmos de aprendizado supervisionado para classificação, visto que nosso objetivo é utilizar tais métodos para classificar tweets de acordo com o tipo de expressão política ou opinião expressa pelo seu criador.

Para resolução de problemas de aprendizado de máquina do tipo supervisionado ou não-supervisionado, precisamos ter à disposição um conjunto de dados de treinamento, os quais correspondem a um conjunto de instâncias descritas por um conjunto de *features*. Essas *features* podem ser contínuas, discretas ou binárias (KOTSIANTIS, 2007). Quando falamos de aprendizado por reforço (SUTTON; BARTO, 2018), temos um agente que tem como objetivo aprender—por repetição—qual sequência de ações gera a maior soma total de recompensas. Já quando falamos de aprendizado não-supervisionado (JAIN; MURTY; FLYNN, 1999), nos referimos a problemas em que as instâncias não estão sendo mapeadas para classes. O objetivo do algoritmo, ao invés disso, é identificar grupos de similaridade entre as instâncias. Neste trabalho, como previamente mencionado, iremos focar em técnicas de aprendizado supervisionado, nas quais temos um conjunto de dados com instâncias e suas respostas/classes esperadas, e onde o objetivo do algoritmo é generalizar os dados de treinamento para descobrir qual o padrão que produz respostas corretas para novas instâncias.

No caso específico de algoritmos de classificação, conforme mencionado anteriormente, queremos identificar à qual classe uma determinada instância pertence (KOTSIANTIS, 2007). Diversos algoritmos se propõem a resolver esse tipo de problema. Neste capítulo, iremos focar nas técnicas de regressão logística, redes neurais, e florestas aleatórias, visto que elas frequentemente consistem no estado-da-arte no que diz respeito a aplicações práticas/reais de aprendizado de máquina. Após discutir esses algoritmos (nas seções seguintes), iremos, nos capítulos que seguem, avaliar diferentes variantes desses algoritmos no contexto específico de nossa aplicação de interesse, a fim de identificar a maneira mais eficaz de construir um modelo de análise de sentimentos que nos permita efetuar as análises de interesse.

2.1.1 Regressão Logística

Regressão logística é um modelo estatístico que calcula a probabilidade de um evento ocorrer dadas informações de entrada descrevendo uma determinada situação ou contexto; por exemplo, prever a classe de um tweet dadas as palavras que o compõem (CRAMER, 2002).

Cada instância de treinamento é um par (x_i, y_i) , onde x_i é um vetor representando as *features* da instância i de treinamento: $x_i = [x_1, x_2, \dots, x_d]$, onde $d \in \mathbb{R}^d$ é o número de atributos da instância, e onde y_i é a saída desejada. O algoritmo aprende pesos w

através de técnicas de gradiente descendente, a qual ajusta os pesos iterativamente de forma a otimizar uma função objetivo (tipicamente *entropia cruzada*) que, dados pesos w , retorna a performance da regressão logística—ou seja, a acurácia do algoritmo resultante do uso dos pesos w . A probabilidade estimada pelo modelo é calculada da seguinte forma. Primeiro, calculamos $t = w_0 + w_1x_1 + w_2x_2 + \dots + w_dx_d$. O modelo de predição, então, se baseia no uso de uma função logística/sigmoide, a qual recebe como entrada t e produz como saída um valor entre 0 e 1, expressando a probabilidade da instancia $x = [x_1, \dots, x_d]$ pertencer à classe positiva. A equação logística, responsável por prever a probabilidade da classe, é dada por:

$$\sigma(t) = 1 / (1 + e^{-t}) \quad (2.1)$$

No contexto de aprendizado de máquina, quando aplicado a um conjunto de dados, esse tipo modelo é capaz de prever a probabilidade de uma dada instância pertencer a uma determinada classe—ou até mesmo a várias delas.

2.1.2 Redes Neurais

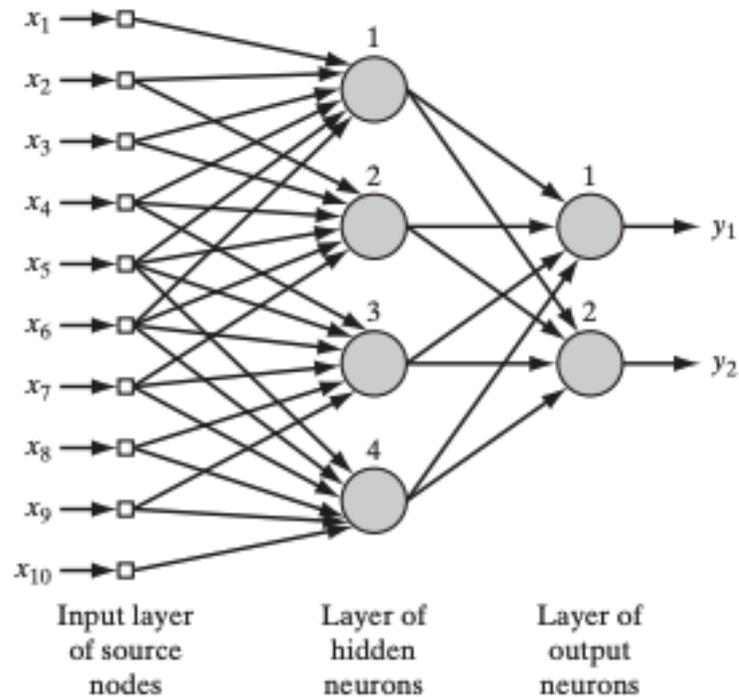
Uma rede neural artificial é um algoritmo de aprendizado de máquina inspirado no nas comunicações entre neurônios do cérebro humano (MCCULLOCH; PITTS, 1943). Sua representação se dá através de um grafo direcionado, onde os neurônios representam os nodos e as conexões entre nodos representam as sinapses.

Como entrada, o algoritmo recebe um conjunto de dados (*features*), e então realiza o processo de propagação da entrada para os neurônios das camadas ocultas. Cada sinapse de um neurônio possui um peso. Para calcular a saída de um neurônio, é aplicada uma função de ativação que consiste na soma dos produtos entre o pesos das sinapses daquele neurônio com as saídas dos neurônios conectados ao neurônio em questão.

Por se tratar de um algoritmo de aprendizado de máquina do tipo supervisionado, a rede neural realiza um treinamento dado um conjunto de dados rotulados a fim de encontrar os melhores pesos para as sinapses, e generalizar suas predições de forma a prever com alta acurácia a classe associada à novos dados (instâncias) fornecidas como entrada. Na Figura 2.1, apresentamos uma representação de uma rede neural com 10 entradas, 1 camada escondida com 4 neurônios, e 2 neurônios na camada de saída.

Redes neurais podem ser vistas como uma generalização de modelos de regressão

Figura 2.1 – Ilustração de uma rede neural.



Fonte: (HAYKIN, 2009)

logística, visto que cada neurônio pode (dependendo da função de ativação) representar um modelo logístico. Os pesos de uma rede neural são ajustados através de um algoritmo chamado *backpropagation*. Os detalhes matemáticos desse processo de treinamento não são relevantes para compreensão deste trabalho, mas a leitora interessada pode encontrá-los em Haykin (2009).

2.1.3 Florestas Aleatórias

Um *árvore de decisão* é um algoritmo de aprendizado de máquina que recebe como entrada um conjunto de dados e realiza divisões nesses dados, com base em testes e comparações nos valores de suas *features*. As divisões são feitas de acordo com critérios que tentam identificar o menor número de testes até que a classe de uma dada instância possa ser determinada. O critério mais comum para divisão dos dados é o *ganho de informação*. O algoritmo de treinamento, a cada momento, determina qual o atributo que auxilia a forma máxima a reduzir a incerteza do modelo acerca da classe da instância.

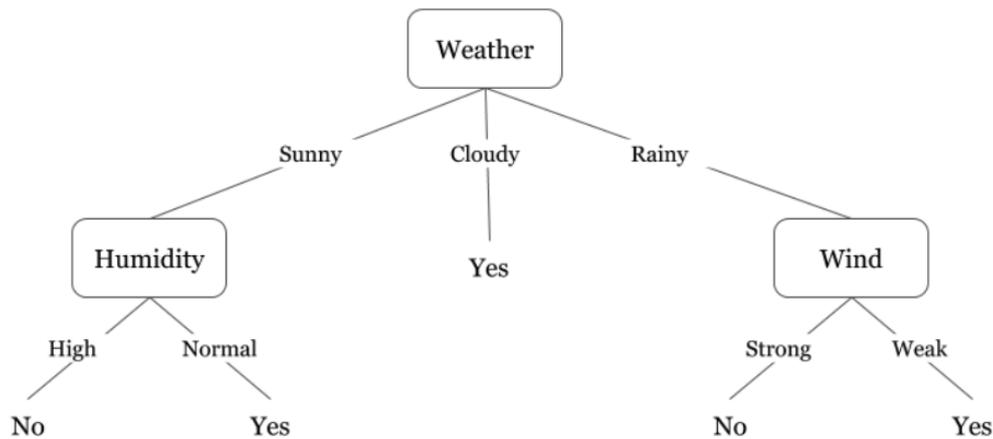
Na Figura 2.2, apresentamos um exemplo de conjunto de dados no qual a classe

Figura 2.2 – Exemplo de um conjunto de dados de entrada para uma árvore de decisão.

Day	Weather	Temperature	Humidity	Wind	Play?
1	Sunny	Hot	High	Weak	No
2	Cloudy	Hot	High	Weak	Yes
3	Sunny	Mild	Normal	Strong	Yes
4	Cloudy	Mild	High	Strong	Yes
5	Rainy	Mild	High	Strong	No
6	Rainy	Cool	Normal	Strong	No
7	Rainy	Mild	High	Weak	Yes
8	Sunny	Hot	High	Strong	No
9	Cloudy	Hot	Normal	Weak	Yes
10	Rainy	Mild	High	Strong	No

Fonte: <<https://www.hackerearth.com/practice/machine-learning/machine-learning-algorithms/ml-decision-tree/tutorial/>>

Figura 2.3 – Exemplo de uma árvore de decisão.



Fonte: <<https://www.hackerearth.com/practice/machine-learning/machine-learning-algorithms/ml-decision-tree/tutorial/>>

(correspondendo à previsão sobre se uma pessoa vai jogar tênis ou não) é feita com base em quatro atributos descrevendo o dia em questão. Esse conjunto de dados poderia ser fornecido como entrada para o treinamento de uma árvore de decisão. Já na Figura 2.3, apresentamos uma possível árvore de decisão treinada sobre os dados da Figura 2.2.

Embora seja possível treinar uma única árvore de decisão, esse tipo de modelo, frequentemente, não generaliza bem quando apresentado a dados novos de teste. Nesse caso, podemos construir uma *floresta de árvores*. Uma *floresta aleatória* é um algoritmo que constrói suas previsões através da combinação das previsões de diferentes árvores de decisão (BREIMAN, 2001). A intuição que motiva esse modelo consiste na ideia de que é possível obter melhores previsões se combinarmos árvores de decisão treinadas com base em diferentes subconjuntos dos dados de treinamento.

Florestas aleatórias têm uma vantagem importante em relação a outros modelos estatísticos, tais como redes neurais, visto que seus modelos são interpretáveis e, portanto, se torna mais fácil para usuárias do algoritmo entenderem por quê determinadas classificações estão sendo feitas. Além disso, florestas aleatórias são frequentemente o estado-da-arte em vários problemas reais desafiadores (GOLDSTEIN et al., 2010).

2.2 Análise de Sentimentos

Análise de sentimentos é um campo de estudo que busca analisar a opinião e o sentimento de um usuário em relação a um determinado tópico, com base em um texto escrito por esse usuário. Esse campo de estudo é uma intersecção entre diversos outros campos de pesquisa, tais como processamento de linguagem natural, computação linguística, aprendizado de máquina e mineração de dados (YUE et al., 2019).

Recentemente, técnicas de aprendizado de máquina começaram a ser utilizadas para automatizar o processo de análise de sentimentos. Em particular, foram propostas diferentes formas de se utilizar algoritmos de classificação para atingir tal objetivo. Essas técnicas vêm sendo aplicadas a um grande leque de problemas reais relevantes.

Para a criação/treinamento de um classificador automático de sentimentos, podem ser utilizadas diversas técnicas de aprendizado de máquina. Na Seção 2.1, foram apresentados diversos algoritmos de aprendizado supervisionados para classificação. Tais algoritmos são frequentemente utilizados para se construir/treinar modelos de análise de sentimentos.

No contexto de análise de sentimentos, precisamos conseguir fornecer *textos* como entrada para os algoritmos previamente citados. Por esse motivo, é necessário encontrar uma forma de representação eficiente para que os texto de entrada fornecidos a um algoritmo possam ser processados pela técnicas de aprendizado de máquina correspondentes—visto que a maior parte dessas técnicas se baseiam em entradas numéricas, não em entradas do tipo “string”. A seguir, iremos descrever os formatos de representação *TF-IDF* e *word2vec*, os quais permitem mapear textos para representações numéricas passíveis de análise por parte de métodos clássicos de aprendizado de máquina. Ambas essas técnicas foram utilizados no desenvolvimento deste trabalho.

2.2.1 TF-IDF

Term Frequency Inverse Document Frequency (TF-IDF) é uma forma de representação de dados que associa valores à cada palavra de um documento, de forma que tal valor é inversamente proporcional à frequência da palavra em um documento, em relação à porcentagem de documentos em que ela aparece (RAMOS et al., 2003). Ou seja, um alto valor de *TF-IDF* indica que uma palavra está fortemente relacionada ao documento em particular no qual ela aparece, visto que ela não aparece tão frequentemente em outros

documentos. Abaixo, apresentamos a fórmula utilizada para o cálculo da representação *TF-IDF* de uma palavra t e um documento individual d , o qual pertence a um conjunto de documentos D :

$$\text{tf-idf}(t, d) = \text{tf}(t, d) \times \text{idf}(t), \quad (2.2)$$

onde idf é computado como:

$$\text{idf}(t) = \log \left(\frac{n}{\text{df}(t)} + 1 \right), \quad (2.3)$$

e onde n é o número total de documentos no conjunto de documentos em D e $\text{df}(t)$ é a *frequência* do termo t . A frequência de um termo é associada ao número de documentos em D que contêm o termo t .

2.2.2 Word2vec

Word2vec é uma forma de representação alternativa de dados para uso por parte dos algoritmos de aprendizado de máquina, a qual considera as *distâncias* entre as palavras através de medidas de similaridade. O algoritmo recebe como entrada um texto e produz, como saída, um vetor de números reais associados a cada palavra. O primeiro passo de treinamento desse algoritmo consiste na construção do vocabulário. Após, o algoritmo aprende a representação vetorial das palavras (MIKOLOV et al., 2013) de forma que a distância euclidiana entre os vetores de palavras semanticamente próximas seja pequena. Isso é uma propriedade importante, pois algoritmos de aprendizado de máquina que lidam com entradas numéricas, tais como redes neurais, podem, então, de forma mais natural, processar e classificar instâncias que consistem, originalmente, não em números, mas em palavras.

Na Tabela 2.1, apresentamos um exemplo em que estão descritas as palavras similares à palavra *France*, de acordo com a distância entre o vetor associado à palavra *France* e vetores associados a cada uma das palavras da tabela. Note que as palavras que o *word2vec* considerou semanticamente próximas à *France*, de acordo com os documentos analisados, possuem uma distância menor. Por fim, note também que nesse caso em particular *Spain* foi considerada mais próxima de *France* do que *Belgium*. Isso não reflete necessariamente que em todos os contextos possíveis *France* e *Spain* são mais semelhantes. Ao invés disso, a Tabela 2.1 indica relações semânticas de alto nível; no

caso, a descoberta automática de que todas essas palavras são semelhantes, devido ao fato, provavelmente, de que todas correspondem a países na Europa ou geograficamente próximos.

Tabela 2.1 – Tabela de Palavras Mais Similares à Palavra *France* Utilizando *word2vec*.

<i>Palavra</i>	<i>Word Cosine Distance</i>
spain	0.678515
belgium	0.665923
netherlands	0.652428
italy	0.633130
switzerland	0.622323
luxembourg	0.610033
portugal	0.577154
russia	0.571507
germany	0.563291
catalonia	0.534176

Fonte: <code.google.com/archive/p/word2vec>

3 TRABALHOS RELACIONADOS

Diversos pesquisadores estudaram a aplicação de análise de sentimentos com o intuito de prever a opinião, o sentimento, ou a avaliação de um grupo de pessoas sobre um determinado tópico. Neste capítulo, iremos discutir alguns trabalhos relacionados ao nosso, isto é, que também se propuseram a criar um analisador automático de sentimentos baseado nos dados da plataforma Twitter. Ressaltamos que, enquanto que nós classificamos tweets em relação ao nosso próprio sistema de classes, definido para categorizar as formas de reação de usuários do twitter em relação à condução do governo no contexto da pandemia, os autores dos artigos a seguir apresentados utilizam ferramentas, como a ferramenta *VADER* (HUTTO; GILBERT, 2014), para categorização de tweets, as quais fazem uso das classes comumente utilizadas por técnicas padrão para análise de sentimentos (isto é, classes "positiva", "negativa", e "neutra")

No artigo proposto por Melo and Figueiredo (2021), os autores têm como objetivo analisar a correlação entre os tópicos descritos, no que diz respeito à pandemia de COVID-19 no Brasil em publicações de usuários do Twitter e em publicações de mídias tradicionais de notícias. Nesse trabalho, os autores utilizaram técnicas de *Topic Modeling*, em particular, *Namely Entity Recognition* (MOHIT, 2014) e análise de sentimentos, através da ferramenta *VADER* (HUTTO; GILBERT, 2014), a fim de comparar o conteúdo de postagens no Twitter e notícias relacionadas à pandemia de COVID-19. Esse trabalho se relaciona ao presente trabalho no que diz respeito à análise de sentimentos de tweets relacionados à pandemia de COVID-19 em português, e também à análise da relação entre postagens de usuários do Twitter e notícias em mídias tradicionais. No entanto, os trabalhos se diferem em seus objetivos: enquanto que nós queremos investigar possíveis correlações entre tweets relacionados à pandemia de COVID-19 e a atuação do governo federal com eventos de grande relevância relacionados à pandemia, os autores Melo and Figueiredo (2021) se propõem a relacionar o conteúdo das postagens dos usuários do Twitter com as notícias publicadas em mídias tradicionais. Além disso, os trabalhos diferem nas técnicas utilizadas: enquanto que nós desenvolvemos nosso próprio analisador automático de sentimentos, baseado em classes definidas por nós mesmos, os autores Melo and Figueiredo (2021) utilizam uma ferramenta já existente para análise de sentimentos, a qual classifica o sentimento do tweet entre positivo e negativo, *VADER* (HUTTO; GILBERT, 2014).

Já no trabalho proposto por Yaqub (2020), o autor analisa o sentimento do tweets

publicados pelo ex-presidente dos Estados Unidos da América, Donald Trump, durante o início da pandemia COVID-19. Para realizar a análise de sentimentos desses tweets, o autor utilizou—assim como no trabalho citado anteriormente—uma ferramenta proposta por Hutto and Gilbert (2014) para desenvolver seu analisador automático de sentimentos. Tal pesquisa está relacionada ao presente trabalho no que se refere à análise de sentimentos de tweets relacionados à pandemia COVID-19. Contudo, difere-se em seus objetivos: enquanto nós queremos correlacionar tweets relacionados à pandemia de COVID-19 à atuação do governo federal no que diz respeito a eventos de grande relevância relacionados à pandemia, o autor Yaqub (2020) se propõe a fazer uma análise de sentimentos dos tweets do ex-presidente dos Estados Unidos da América, Donald Trump, em relação à pandemia de COVID-19. Além disso, nas ferramentas utilizadas: enquanto nós desenvolvemos o próprio analisador automático de sentimentos baseado em definições de classes propostas por nós mesmos, o autor Yaqub (2020) utilizou a ferramenta já existente *VADER* (HUTTO; GILBERT, 2014) para análise de sentimentos, a qual classifica o sentimento do tweet entre positivo e negativo.

No artigo proposto por Prastyo et al. (2020), os autores analisam o sentimento de usuários do Twitter, através de tweets, em relação à forma como a pandemia COVID-19 foi gerenciada pelo governo indonésio. Esse trabalho está relacionado ao presente trabalho no que se refere à análise de sentimentos de tweets relacionados à pandemia COVID-19 e à atuação de governos no gerenciamento da pandemia em seus respectivos países. Em contrapartida, difere-se em seus objetivos: enquanto nós queremos correlacionar tweets sobre a pandemia de COVID-19 à atuação do governo brasileiro com eventos de grande relevância relacionados à pandemia, os autores daquele trabalho se propõem a analisar a opinião da população em relação à atuação do governo indonésio no contexto da pandemia. Além disso, os trabalhos se diferem nos métodos utilizados: enquanto que nós desenvolvemos nosso próprio analisador automático de sentimentos, baseado em classes definidas por nós mesmos, os autores Prastyo et al. (2020) desenvolveram um analisador de sentimentos com as classes negativo e positivo e utilizando uma técnica diferente, baseada em *Support Vector Machine* (SUTHAHARAN, 2016).

Assim como os trabalhos citados acima, diversos outros se propuseram a analisar o sentimento de usuários do Twitter em relação à pandemia do COVID-19 através da análise de tweets, como em os trabalhos propostos por Rajput, Grover and Rathi (2020), Manguri, Ramadhan and Amin (2020), Machuca, Gallardo and Toasa (2021), Pokharel (2020), Pastor (2020) e Garcia and Berton (2021). Entretanto, o presente trabalho se

difere dos anteriormente citados nos seguintes quesitos:

- A análise de sentimentos do presente trabalho visa avaliar, em particular, a atuação do governo brasileiro no que diz respeito à sua atuação durante a pandemia de COVID-19.
- Como mencionado no início deste Capítulo, construímos nosso próprio classificador, baseado em classes definidas por nós mesmos, as quais diferem das classes geralmente, utilizadas em analisadores de sentimentos (i.e., positivo, negativo e neutro).
- A combinação específica de representação de dados usada neste trabalho, *word2vec*; o algoritmo de aprendizado de máquina, redes neurais; e a definição de classes, "negativo" e "outros", não foi explorada nos trabalhos anteriormente citados, a fim de construir o analisador automático de sentimentos.
- Nosso objetivo, neste trabalho, é, em particular, investigar possíveis correlações entre diferentes métricas relacionadas à pandemia e ao governo federal, e o sentimento dos tweets analisados.

Com isso, ao contrário dos trabalhos relacionados discutidos neste capítulo, nós propomos um objetivo mais amplo: investigar até que ponto é possível correlacionar eventos relevantes no contexto da pandemia com o sentimento da população (expresso no Twitter) sobre a atuação do governo federal no contexto da pandemia. Além disso, também tentaremos correlacionar o sentimento da população com outros dados relevantes sobre o governo federal e sobre a pandemia.

4 METODOLOGIA EXPERIMENTAL

Neste capítulo, iremos apresentar como serão realizadas, no contexto deste trabalho, a coleta, a rotulação, e o pré-processamentos de dados, assim como quais hipóteses e correlações (entre sentimentos expressos no Twitter e eventos relacionados à pandemia no Brasil) serão analisadas. Discutiremos, também, como essas hipóteses e possíveis correlações serão avaliadas, e, por fim, quais ferramentas computacionais serão utilizadas

4.1 Coleta dos Dados

Serão coletados dados do Twitter para o treinamento do algoritmo de aprendizado de máquina responsável pela análise automática de sentimentos e, também, para a avaliação das hipóteses que serão apresentadas mais à frente neste trabalho.

Para tanto, foram definidos parâmetros de filtragem para a captura desses dados. A escolha da geolocalização foi a cidade de Porto Alegre, devido à restrição do escopo de análise deste trabalho. Optamos por escolher apenas uma cidade, sobre a qual pudéssemos analisar, de forma mais profunda, a linha do tempo de notícias—particularmente aquelas relacionadas ao governo federal e à pandemia—em mídias locais tradicionais. Já as palavras-chave escolhidas para busca de tweets, que serão apresentadas a seguir, estão relacionadas à presença de alguma menção ao governo federal e/ou à pandemia. Dessa forma, evitaremos a captura de tweets que não tenham qualquer relação com o tópico deste trabalho. Finalmente, a escolha das datas determinadas para captura dos tweets está relacionada ao início da pandemia e ao momento da finalização deste trabalho.

4.1.1 Conjunto de Dados de Treinamento e Teste

Após uma análise preliminar a respeito da existência de dados de treinamento já rotulados, os quais pudessem ser utilizados neste trabalho, observamos que nenhum conjunto de dados possuía as características necessárias a este trabalho. Após várias tentativas com conjuntos de dados encontrados na internet, percebemos que esses conjuntos de dados já disponíveis não resultavam em classificações de alta performance quando avaliados no contexto do nosso trabalho. Por exemplo, tweets por nós coletados com a palavra "morte" ou "medo", eram, frequentemente, classificados como neutros ou posi-

vos. A autora não tem certeza do motivo pelo qual diversos algoritmos cometiam esse erro, mas possivelmente isso reflete problemas na rotulação dos dados de conjuntos de dados disponíveis na internet.

Tendo isso em vista, decidimos construir nosso próprio conjunto de dados para o treinamento e teste do algoritmo. *Foram coletados e classificados 831 tweets com filtros que serão apresentados a seguir.* A coleta desses tweets foi realizada através do uso da biblioteca, para *Python*, *Twint* (TWINTPROJECT, 2018). Os parâmetros utilizados na captura de tweets foram os seguintes:

- Tweets feitos por usuários próximos à cidade de Porto Alegre. Ou seja, tweets que se encaixassem no filtro avançado do Twitter utilizado. Para o parâmetro "near", foi utilizado o valor "Porto Alegre", com um limite de 22 quilômetros.
- Tweets que contivessem, pelo menos, uma das seguintes palavras: *presidente, governo, bolsonaro, bozo, biroliro, bostonaro, mito, bolsonaro2022, genocida, jair-bolsonaro, bolsominion, pandemia, covid, coronavírus*. Essas palavras foram selecionadas empiricamente para maximizar a chance de coletarmos tweets relacionados à pandemia e que falassem positivamente ou negativamente sobre o governo federal.
- Tweets em Português.

Houve também a tentativa de geração artificial de dados, a fim de obter um conjunto de dados mais expressivo. Inicialmente, realizamos a rotulação de apenas cem tweets, dado o esforço e tempo necessários para essa classificação manual. A partir desses cem tweets, foram gerados—artificialmente—outros 5000 tweets através da randomização de palavras amostradas de dos tweets já classificados. No entanto, essa abordagem não obteve resultado satisfatório na performance dos algoritmos. Após o treinamento, não observamos melhorias em sua acurácia e F1-Score, e decidimos então realizar a classificação de mais tweets manualmente, criando então um conjunto de treinamento de 831 tweets (capturados em 2021) classificados pela autora.

4.1.2 Conjunto de Dados para Análise das Hipóteses

A metodologia utilizada, neste trabalho, envolve, em primeiro momento, a criação de um conjunto de dados (rotulados) para servir de base para o desenvolvimento e ajuste do método que iremos propor para efetuar análise de sentimentos. Isso será feito

com base nos dados de treinamento mencionados na Seção 4.1.1. Após, iremos utilizar nosso modelo treinado de análise de sentimentos para avaliar um conjunto muito maior de tweets, não rotulados, a fim de utilizar nosso modelo para gerar previsões sobre variação temporal de sentimentos de usuários do Twitter a respeito da condução do governo federal no contexto da pandemia. Nesta seção, descrevemos como iremos construir esse segundo conjunto de dados.

Durante o desenvolvimento do trabalho, a biblioteca citada anteriormente para captura de tweets tornou-se inutilizável, pois a API oficial do Twitter que era utilizada por essa biblioteca foi descontinuada. Passou a ser utilizada, então, a ferramenta *snsrape* (JUSTANOTHERARCHIVIST, 2018), também para *Python*, a qual permite a captura de tweets utilizando filtros padrão do Twitter. O conjunto de dados construído conta com 79943, os quais serão considerados para a avaliação das hipóteses de correlação. Tais tweets foram capturados segundo os seguintes parâmetros:

- Tweets feitos por usuários próximos à cidade de Porto Alegre. Ou seja, tweets que se encaixassem no filtro avançado do Twitter utilizado. Para o parâmetro "near", foi utilizado o valor "Porto Alegre", com um limite de 22 quilômetros.
- Tweets que contivessem, pelo menos, uma das seguintes palavras: *presidente, governo, bolsonaro, bozo, biroliro, bostonaro, mito, bolsonaro2022, genocida, jair-bolsonaro, bolsominion, pandemia, covid, coronavírus*. Essas palavras foram selecionadas empiricamente para maximizar a chance de coletarmos tweets relacionados à pandemia e que falassem positivamente ou negativamente sobre o governo federal.
- Tweets em Português.
- Tweets com data entre primeiro de janeiro de 2020 e onze de setembro de 2021.

4.2 Rotulação dos Dados

Primeiramente, gostaríamos de apontar que, após um estudo preliminar, fizemos diversas tentativas de rotulagem manual dos dados citados na sessão anterior, utilizando a forma clássica de análise de sentimentos (SHELAR; HUANG, 2018), com três possíveis classes: positivo, negativo ou neutro. No entanto, iremos apresentar, a seguir, alguns exemplos de tweets que representam desafios caso tenham que ser classificados através de técnicas padrão de análise de sentimentos; são desafiadores, especificamente, devido

à existência de, e.g, sarcasmo e ironia. Esses dados são importantes, pois é com base neles que faremos a investigação sobre diversas hipóteses relativas aos limites da análise de sentimentos como ferramenta para inferência automática de eventos relacionados à pandemia no Brasil.

- Tweet 1: *"o melo, prefeito de porto alegre, não deu multa pro bolsonaro por não usar máscara pq ele resolve as coisas no diálogo, não com punição. grande prefeito que temos. *ironia*"*
- Tweet 2: *"@gzhdigital Restaurantes para curtir a dois durante uma pandemia. Nada está acontecendo. Porto Alegre está em plena normalidade. A matéria só pode vir de repórter que cagou pra qualquer medida de isolamento desde que tudo começou, não é? Irresponsáveis."*
- Tweet 3: *"Puxa vida, era disso que Porto Alegre precisava mesmo!!!! Saúde um caos, segurança um caos, tudo liberado, pandemia então, acabou em Porto Alegre. E o prefeito tirando placas de poste, aí maravilhosooooooooo <https://t.co/pqE595ZFFk>"*
- Tweet 4: *"Eu tentando ser uma pessoa mais positiva, cheia de sentimentos bons, esperançosa, alegre e calma: Lembrei que o Bolsonaro é o presidente do meu país: ImpeachmentBolsonaroUrgente"*
- Tweet 5: *"Bolsonaro ta em Porto Alegre para a inauguração da ponte nova, e eu só penso que ele podia inaugurar pulando dela"*

Nos exemplos acima, é possível notar ironia e sarcasmo dos autores, duas figuras de linguagem que representam desafios para análise automática de sentimentos (FARIAS; ROSSO, 2017). Além disso, também existem desafios relacionados à polarização dos sentimentos (HUSSEIN, 2018). Isto é, a autora de um tweet pode estar expressando diferentes sentimentos dentro da uma mesma frase. Por exemplo, ao avaliar um produto, a cliente pode avaliar o preço como algo negativo, por ser um produto caro, mas pode avaliar a usabilidade como positiva, por ser um produto fácil de utilizar.

Em virtude dos desafios complexos envolvendo análise automática de sentimentos no contexto da presença de tweets contendo ironia, sarcasmo e sentimentos conflitantes, buscamos propor um sistema alternativo para rotulação dos dados, removendo subjetividades. Para tanto, no escopo deste trabalho, definimos apenas duas classes: "negativo" e "outros". Para que o tweet fosse considerado negativo, era necessário que ele se encaixasse, necessariamente, em dois critérios:

- Expressasse um sentimento negativo.

- Contivesse referência (1) à atuação do governo federal; (2) em particular, no contexto da pandemia do COVID-19.

Quaisquer outros sentimentos expressos, figuras de linguagem utilizadas, ou subjetividades expressas em um no tweet resultaram na classificação do tweet como sendo da classe "outros".

4.3 Pré-Processamentos dos Dados

Serão efetuados diferentes processos de pré-processamentos de dados, a fim de evitar ruídos que possam atrapalhar no processamentos dos tweets. Serão removidas *URLs* do Twitter, símbolos que não sejam letras, e *hashtags*. Além disso, o conteúdo dos tweets será inteiramente transformado para letras minúsculas.

Ademais, todos os tweets foram traduzidos previamente para inglês, com o intuito de poder fazer uso de modelos (MIKOLOV et al., 2013) parcialmente pré-treinados, além de expandir os seus conjuntos de treinamento originais com dados relativos ao domínio sendo estudado no contexto deste trabalho. A biblioteca utilizada para tradução foi a biblioteca (implementada em *Python*) *deep-translator* (NIDHALOFF, 2020). A decisão da escolha da estrutura de representação de dados, através de técnicas de, *word2vec* será explicada e motivada no Capítulo 5.

4.4 Experimentos a Serem Conduzidos

Neste trabalho, iremos analisar algumas hipóteses relacionadas aos sentimentos expressos em tweets, com relação à atuação do governo federal no contexto da pandemia. Iremos em particular, focar em tweets que o modelo acredita pertencer à classe "negativo". Com base na análise da variação temporal desses tweets, iremos estudar diversas hipóteses relativas à capacidade de métodos de análise de sentimentos de inferirem automaticamente a ocorrência de eventos relevantes no contexto da pandemia de COVID-19.

A primeira hipótese que avaliaremos diz respeito à existência de uma correlação entre a tendência de crescimento da quantidade de tweets negativos e a taxa de reprovação do governo federal pela população brasileira ao longo do tempo (XP/INESPE,), durante o período da pandemia. Em outras palavras: é possível visualizar a tendência de reprovação do governo com base na análise automática de sentimentos dos dados do Twitter?

A segunda e terceira hipóteses a serem avaliadas dizem respeito à existência de uma correlação entre a tendência de crescimento de tweets negativos e a taxa diária de mortes e de casos de COVID-19, tanto no Brasil quanto no Rio Grande do Sul, durante o período da pandemia (COVID19, 2020). Isto é: será que o crescimento no número de mortes e de casos de COVID-19, no Brasil e no Rio Grande do Sul, se reflete nos sentimentos da população gaúcha, expressos no Twitter?

Como quarta hipótese, iremos avaliar correlações entre dias nos quais houve um número acima da média de tweets negativos, e eventos relevantes divulgados nas mídias tradicionais (impressas ou não), como Zero Hora, Correio do Povo, El País, Folha de São Paulo, entre outras. Ou seja: a existência de eventos relevantes a respeito da pandemia, e/ou do governo federal, se reflete no sentimento da população gaúcha no Twitter? Será possível inferir que um evento relevante, no contexto da atuação do governo federal no contexto da pandemia, ocorreu apenas avaliando-se a tendência de crescimento de sentimentos negativos no Twitter?

Ainda no que diz respeito a eventos relevantes a respeito da pandemia e/ou ao governo federal, iremos analisar se existem benefícios em analisarmos tweets que se encaixam, em particular na classe "negativo", em oposição a analisarmos o número total de tweets que se encaixam nos parâmetros utilizados para a captura de tweets. Em outros termos: estudaremos se é possível inferir a existência de eventos relevantes sobre a pandemia e/ou o governo federal apenas analisando-se a tendência de crescimento de tweets negativos, ou se existem vantagens em tentarmos inferir eventos com base na tendência de crescimento de tweets filtrados pelo nosso processo de coleta de dados, isto é, tweets que mencionam a pandemia e/ou o governo federal, mas que podem expressar sentimentos positivos ou negativos. Em outras palavras, a frequência de tweets sobre a pandemia e o governo federal já constitui informação suficiente para inferir a ocorrência de eventos relevantes ou a taxa de tweets *negativos* fornece informações úteis adicionais?

4.5 Métricas de Avaliação de Hipóteses

A fim de que seja possível mensurar e, portanto, comprovar ou refutar as hipóteses descritas acima, iremos definir o seguinte critério de avaliação.

Iremos, inicialmente, identificar picos nos histogramas que representam a quantidade de tweets (negativos, outros, ou total) por dia. Esses picos serão detectados utilizando-se a função *find peaks* da biblioteca, para *Python, Scipy* (SCIPY, 2006). Essa função per-

mite a identificação de máximos locais dado um vetor de valores e que é robusta a dados ruidosos.

Dada a identificação dos picos onde existe a tendência de crescimento de tweets de determinada categoria, e o gráfico de tendência dos histogramas de tweets negativos por dia, iremos comparar, empiricamente e através de algoritmos de análise de correlação entre séries temporais, tais picos e gráficos de tendência com os gráficos correspondentes às hipóteses citadas anteriormente. Por exemplo, iremos realizar a comparação do gráfico de reprovação do governo federal ao longo da pandemia com o gráfico de tendência de tweets negativos ao longo da pandemia.

Inicialmente, iríamos automatizar a detecção e quantificação de possíveis correlações entre os histogramas e picos/taxas de tweets, com diferentes gráficos representando quantidades de interesse refletindo eventos diversos relativos à condução do governo federal no contexto da pandemia. Isso seria feito através de algoritmos para cálculos de correlações entre séries temporais, tal como o algoritmo *Dynamic Time Warping* (SALVADOR; CHAN, 2004). Entretanto, a correlação (ou não) entre os dados providos pela análise de sentimentos e as diferentes hipóteses mencionadas anteriormente pode ser facilmente feita através de inspeção visual. Mais detalhes serão discutidos no Capítulo 6.

4.6 Possíveis Limitações nas Análises Efetuadas

Conforme mencionado anteriormente, iremos investigar diferentes hipóteses—e.g., se há correlação entre a taxa de aprovação do presidente e o número de tweets negativos. A qualidade de nossas análises, e suas respectivas conclusões, pode ser influenciada devido a diversos fatores—alguns relacionados aos dados que temos disponíveis, mas também devido a possíveis vieses intrínsecos nos dados oriundos de plataformas de mídia social. Tais limitações, portanto, não são resultado de problemas metodológicas de nosso trabalho, e sim devido a características dos dados que iremos analisar e dos modelos de predição construídos com base em tais dados. A seguir, acentuamos alguns fatores que podem afetar a qualidade das conclusões e inferências que iremos fazer, com base nos dados por nós coletados e com base na análise das predições feitas pelo nosso modelo de análise de sentimentos.

4.6.1 Rotulação dos Dados

As instâncias para criação do conjunto de dados de treinamento do algoritmo de aprendizado de máquina foram rotuladas pela autora, de acordo com a sua avaliação de se o *tweet* se encaixa na classe "outros" ou na classe "negativo". O critério objetivo para um *tweet* ser classificado como "negativo", conforme descrito anteriormente, é se ele discute o governo federal do Brasil no contexto da pandemia de COVID-19. Embora a autora tenha tentado ser o mais objetiva na rotulação dos dados, de acordo com tal critério, a rotulação por ela efetuada pode, devido a subjetividade intrínseca na interpretação do texto de cada *tweet*, introduzir um viés no que diz respeito ao treinamento do algoritmo de aprendizado de máquina.

4.6.2 Tradução dos Tweets para o Português

Como mencionado na Seção 5.2, para o treinamento do modelo *word2vec*, além do conjunto de dados coletados pela autora, foi utilizado o conjunto de dados proposto por Vijay et al. (2020), o qual contém documentos em inglês. A fim de poder fazer uso desse importante conjunto de dados de treinamento adicional, os tweets coletadas pela autora foram traduzidos automaticamente para inglês—tanto os tweets utilizados no treinamento do algoritmo de aprendizado de máquina, quanto os tweets utilizados pra análise das hipóteses. A tradução para o inglês também facilita tarefas de pré-processamento de dados, visto, por exemplo, que as funções fornecidas pela biblioteca *Scikit-learn* (LEARN, 2010) para remoção de *stop words* recebem palavras em inglês.

A tradução dos tweets pode introduzir ruído em virtude de possíveis traduções de baixa acurácia, as quais podem ocorrer por diversos motivos: a não existência de uma palavra em inglês com mesmo significado da palavra original, em português; a erros de gramática no tweet em português; ao uso de uma abreviação ou gíria que impede a tradução direta; ou até mesmo a limitações da ferramenta de tradução automática propriamente dita.

4.6.3 Filtragem na Coleta dos Tweets

Para a coleta dos dados, foram utilizados quatro filtros, os quais dizem respeito: (i) à localização geográfica da pessoa que criou o tweet; (ii) à presença de palavras que mencionassem o governo federal e/ou a pandemia; (iii) à data na qual o tweet foi feito; e (iv) à língua do tweet.

Em relação à localização, a autora fez uso o filtro do tipo "near" no sistema de busca avançada do Twitter. Através desse filtro, foi utilizado o valor "Porto Alegre", diz respeito a latitude e longitude $-30.0277, -51.2287$ ". Essa localização corresponde ao centro da cidade de Porto Alegre, imediatamente em frente ao Mercado Público da cidade. Considerando a extensão de 44 quilômetros entre o norte da cidade (Arena do Grêmio) e sul da cidade (Lami), a metade de tal distância corresponde a 22km. Por base nisso, definimos 22km como sendo a máxima distância entre o centro da cidade e a distância em que um tweet pode ter ser feito, para que (para fins de nossa análise) ele fosse considerado como um tweet feito em Porto Alegre. Ainda em relação à localização, assumindo que a pessoa que fez o tweet possui uma dispositivo que transmite a sua localização. Isso pode estar introduzindo um viés socioeconômico, visto que apenas dados de usuárias que possuem dispositivos com tal capacidade estão sendo consideradas em nossa pesquisa.

A respeito das palavras-chave utilizadas para a filtragem, foram selecionadas palavras que são geralmente utilizadas tanto por apoiadores quanto por não apoiadores do presidente. Ainda assim, podem existir diversas outras formas de se referir ao presidente e/ou ao governo federal, as quais não foram incluídas na lista definida. Isto é, podem existir tweets que não foram coletados por nosso sistema por não conterem nenhuma palavra do filtro proposto pela autora, mas que deveriam ter sido coletados pois, estritamente falando, correspondem a tweets mencionando o governo federal e/ou a pandemia de COVID-19.

4.6.4 Linha do Tempo de Coleta dos Dados

Os tweets coletados para o *treinamento* do algoritmo de aprendizado de máquina são correspondentes ao ano de 2021. No entanto, para a *análise* de sentimentos ao longo da pandemia, os dados utilizados estão entre janeiro de 2020 e setembro de 2021. Essa decisão se deu em virtude do fato de que diversas bibliotecas de coleta de tweets se tornaram *deprecated* (não mais disponíveis) **durante** o desenvolvimento do trabalho, devido à

desativação do *endpoint* do Twitter utilizado por tais bibliotecas. Esse fato tornou a coleta de dados mais desafiadora. Nesse sentido, pode haver viés no que diz respeito às palavras-chave que o algoritmo aprendeu ao analisar dados do ano de 2021, as quais podem não aparecer em 2020. Isso pode fazer com o que o algoritmo possivelmente não reconheça que tais palavras que podem ser decisivas para a correta classificação de tweets durante a análise de sentimentos.

4.6.5 Definição de Eventos Relevantes

A autora precisou definir e identificar, manualmente, *eventos relevantes* associados à condução do governo federal no contexto da pandemia, a fim de poder explorar a Hipótese 4. Todos os eventos analisados pela autora foram publicados em mídias tradicionais (impressas ou não), tais como o jornal Zero Hora, Correio do Povo, El País, Folha de São Paulo, entre outros. No entanto, pode haver um viés relacionado à definição do que é um evento relevante. Tais eventos foram definidos e identificados pela autora com base no seu entendimento de quais notícias dizem respeito a eventos relacionados à pandemia e/ou ao governo federal, e que tenham sido publicadas com destaque na mídia tradicional em questão. Por essa razão, e também devido à extensa análise manual feita pela autora para identificação de tais eventos, pode ter sido introduzido um viés associado à interpretação própria da autora no que diz respeito à análise de tais notícias apresentadas em destaque nas mídias tradicionais.

5 METODOLOGIA PROPOSTA

Neste capítulo, iremos descrever o processo de construção e de treinamento do modelo de aprendizado de máquina, que será base do nosso analisador automático de sentimentos. Iremos também descrever a maneira com que iremos avaliar as diferentes possibilidades de representação de dados, a fim de identificar a mais eficiente.

5.1 Modelo de Aprendizado de Máquina

A fim de construir um modelo de análise de sentimentos efetivo no contexto deste trabalho, serão considerados os seguintes algoritmos de aprendizado de máquina: redes neurais, regressão logística e florestas aleatórias¹. Para a escolha do algoritmo que produz o melhor analisador automático de sentimentos, será avaliado o seu F1 Score, e—principalmente—sua acurácia nos dados de teste. O foco na acurácia se deve ao motivo a seguir. Previamente, neste trabalho, discutimos a definição da classe "negativo", como a classe que expressa sentimentos negativos do autor em relação à atuação do governo federal no contexto da pandemia. Em contrapartida, a definição do rótulo "outros", diz respeito à classe que abrange quaisquer outros sentimentos. Nosso objetivo principal, neste trabalho, é avaliar a *acurácia* do algoritmo sobre a classe "negativo". Queremos, em particular, ter certeza de que, se existe uma manifestação de sentimentos negativos nas redes sociais em determinada data, ela é identificada de forma acurada pelo nosso modelo. Em outras palavras, gostaríamos de evitar muitos falsos negativos, a fim de podermos executar a avaliação das hipóteses propostas. Em contrapartida, temos ciência de que—por termos uma definição da classe "negativo" relativamente restrita—é possível que estejamos ignorando tweets que possam apresentar sentimentos negativos, mas que fogem da nossa definição estrita. Em nossos experimentos, isso se manifestaria na forma de histogramas com menores amplitudes, mas características relevantes, tais como datas de picos de tweets de determinada categoria, iriam ser preservadas.

¹Para o desenvolvimento do algoritmo de aprendizado de máquina para análise automática de sentimentos, foi utilizada a linguagem de programação *Python* (PYTHON, 1993), em virtude de sua vasta gama de bibliotecas de suporte para aprendizado de máquina e estatística. A ferramenta para desenvolvimento do código, para *Python*, foi a *Jupyter Notebook* (JUPYTER, 2015). Foram utilizadas, para estatística e geração dos gráficos, as bibliotecas, para *Python*, *Numpy* (NUMPY, 2002), *Matplotlib* (MATPLOTLIB, 2008), *tslearn* (TEAM, 2017) e *Scipy* (SCIPY, 2006). Para a manipulação do grande volume de dados, foi utilizada a biblioteca, para *Python*, *Pandas* (DEV, 2011). Para a representação dos dados, foi utilizada a biblioteca, para *Python*, *Gensim* (RARE-TECHNOLOGIES, 2011). Finalmente, para desenvolvimento dos modelos de aprendizado de máquina, foi utilizada a biblioteca, para *Python*, *Scikit-learn* (LEARN, 2010).

Nas próximas seções, serão apresentadas as performances dos três algoritmos citados anteriormente, quando combinados com dois tipos possíveis de representação de dados.

5.2 Representação dos Dados

A fim de que seja possível fornecer os dados de um tweet como entrada para o treinamento de um algoritmo de aprendizado de máquina, que implementará o analisador automático de sentimentos, é necessário transformar os tweets (strings) para um formato que o algoritmo possa naturalmente processar, e.g., transformando a *string* de um tweets em uma representação numérica para uso em um conjunto com uma rede neural. Foram testados dois tipos de representação dos dados como entrada para o algoritmo de aprendizado de máquina: *TF-IDF* e *word2vec*, ambos discutidos no Capítulo 2 deste trabalho.

5.2.1 Representação de Tweets usando Formato TF-IDF

Inicialmente, avaliamos diversos algoritmos de aprendizado de máquina para construção de nosso modelo quando acoplados ao formato *TF-IDF* para representação de dados de treinamento (tweets). A transformação de dados para o formato *TF-IDF* será feita utilizando a implementação correspondente na biblioteca *sklearn* (LEARN, 2010).

Durante a transformação dos dados de treinamento para esse formato, foi criado um vetor de palavras que compõem o vocabulário do modelo, o qual contém todas as palavras encontradas em todos os tweets capturados. Após, para cada tweet, foi criado um vetor com o mesmo tamanho do vocabulário tendo em cada posição o número de vezes em que a palavra correspondente àquele índice no vocabulário aparecia no tweet em questão.

Por exemplo, considere o seguinte vocabulário:

[banana, amo, não],

e os seguintes tweets:

Tweet 1: "banana? amo banana."

Tweet 2: "banana? não amo banana."

Nesse caso, a saída da transformação citada anteriormente (ignorando sinais de pontuação) seria:

Tweet 1: [2, 1, 0]

Tweet 2: [2, 1, 1]

Tendo essa representação intermediária, o último passo para finalizar a transformação de um tweet para o formato *TF-IDF*, é converter, para cada tweet, o seu vetor de frequência de palavras para um vetor de *TF-IDF* associados à cada palavra no respectivo documento/tweet.

Após realizarmos as transformações dos tweets para o formato *TF-IDF*, realizamos uma série de testes comparando a performance de diferentes algoritmos de aprendizado de máquina, ao receber a representação de tweets como entrada. Esses experimentos foram executados usando os dados coletados através do processo descrito na Seção 4.1.1.

Primeiramente, foi feita a validação de performance via validação cruzada dos dados, utilizando 80 por cento dos 831 tweets previamente rotulados para treinamento, e 20 por cento para teste. Abaixo, são apresentadas as respectivas acurácias e F1 Scores de cada algoritmo citado anteriormente, ao serem treinados como modelos de análise de sentimentos operando sobre uma representação *TF-IDF*. Cada valor apresentado na Tabela 5.1 corresponde a uma média entre três execuções de treinamento do respectivo algoritmo. O modelo de rede neural utilizado para a análise de performance, ainda na Tabela 5.1, possuía uma camada de ativação logística e duas camadas internas com oito neurônios cada. Já o algoritmo de floresta aleatória possuía cem árvores especificando que cada árvore poderia ter profundidade máxima de dez níveis. Esses valores foram identificados de forma empírica, ao longo dos nossos experimentos². O terceiro algoritmo avaliado corresponde a um modelo clássico de regressão logística. Aqui, utilizamos fator de regularização ajustado manualmente.

Tabela 5.1 – Tabela de Performance dos Algoritmos Recebendo TF-IDF como Entrada

<i>Algoritmo</i>	<i>Acurácia</i>	<i>F1 Score</i>
Rede Neural	0.71	0.60
Regressão Logística	0.66	0.39
Floresta Aleatória	0.66	0.39

Fonte: A Autora

Não satisfeitos com os resultados acima, decidimos testar outro formato de representação para os dados de treinamento, a fim de verificar se seria possível obter um modelo de análise de sentimentos mais eficaz.

²Foram realizados testes alterando (aumentando e diminuindo) o número de camadas e neurônios da rede neural, até que se chegasse em valores que maximizassem a performance do algoritmo. Também foram realizados testes com o mesmo propósito referentes à profundidade das árvores da floresta aleatória.

5.2.2 Representação de Tweets usando formato Word2vec

Decidimos testar o formato de representação dos dados *word2vec* utilizando funções implementadas na biblioteca *Gensim* (RARE-TECHNOLOGIES, 2011). Abaixo, demonstramos um exemplo de declaração da classe *Word2vec*:

```
Word2Vec (
    list(w2v_data.tweet),
    vector_size=350,
    window=10,
    min_count=1,
    epochs=20
)
```

O primeiro parâmetro da classe acima consiste na lista de tweets. O segundo (*vector size*) diz respeito à dimensionalidade dos vetores para os quais cada palavra será mapeada. Já o terceiro parâmetro (*window*) corresponde à distância máxima entre quaisquer duas palavras no tweet. O quarto parâmetro (*mincount*) especifica o número mínimo de vezes que a palavra precisa aparecer nos tweets. Por fim, o quinto parâmetro (*epochs*) define o número de iterações do processo de treinamento.

Como saída, o objeto instanciado é um modelo *word2vec* treinado capaz de identificar palavras com alguma similaridade semântica. Abaixo, apresentamos um exemplo de relações que o algoritmo *word2vec* treinado é capaz de identificar. A seguinte chamada de função sobre o objeto *word2vec* previamente instanciado corresponde a uma "query" a respeito de quais palavras o modelo *word2vec* considera mais próximas semanticamente da palavra "government":

```
w2v.wv.most_similar(['government'])
```

A saída resultante é uma lista de palavras com maior similaridade em relação à palavra passada como parâmetro. Nesse caso, em particular, a saída é:

```
[('governments', 0.7180959582328796),
 ('gov', 0.543052077293396),
 ('disgovernment', 0.49903786182403564),
 ('administration', 0.49236080050468445),
```

```
( 'probrazil', 0.4816300570964813),
( 'privatization', 0.4611150622367859),
( 'bolsonaro', 0.45776644349098206),
( 'budget', 0.4295063614845276),
( 'management', 0.4275958240032196),
( 'audited', 0.424883633852005) ]
```

Pode-se perceber que o modelo treinado foi capaz de encontrar representações numéricas para palavras em seu dicionário, de forma que palavras semanticamente similares são mapeadas para valores próximos; por exemplo, o modelo *word2vec* identificou a relação entre as palavras "governo", "privatização" e "administração". Desenvolvemos, também, uma função que retorna, dadas as palavras de um tweet como entrada, o vetor médio associado às palavras daquele tweet. Segue, abaixo, a definição desta função abaixo:

```
def document_vector(words):
    doc = [word for word in words \
           if word in w2v.wv.key_to_index]
    return np.mean(w2v.wv[doc], axis=0)
```

Calcular o vetor médio relativo aos vetores associados com cada palavra de um tweet é importante para que sejamos capazes de representar tweets com diferentes números de palavras através de um, vetor de tamanho fixo e pré-definido. Dessa forma, cada tweet é efetivamente representado pelo "vetor central" dentre os vetores associados à semântica de cada palavras naquele tweet. Uma possível entrada dessa função poderia ser um vetor contendo todas as palavras de um tweet qualquer:

```
[ 'dr', 'luana', 'saying', 'secretariat', 'aimed',
  'streamline', 'pass', 'information', 'pandemic', 'needs',
  'said', 'eh', 'professional', 'room', 'professionals',
  'gospel', 'militia', 'misgovernance', 'lilinacpi' ]
```

Nesse caso, a saída da função seria:

```
[2.59686857e-01, 8.62923637e-02, ..., -3.19239050e-01]
```

em particular, um vetor, de tamanho 350, correspondendo ao mapeamento das palavras do tweet para um ponto em um espaço com 350 dimensões.

Para que fosse possível construir um modelo *word2vec* com um dicionário significativo de palavras, o modelo *word2vec* foi treinado utilizando-se todos os tweets dos conjuntos de dados de treinamento, de teste, e de validação de hipóteses. Também foi utilizado, adicionalmente, um conjunto de dados encontrado na internet com tweets relacionados à pandemia de COVID-19 (VIJAY et al., 2020). Antes de iniciar o treinamento do modelo de *word2vec*, efetuamos a remoção automática de *stop words* em inglês já contidas em sua implementação através da função *remove stopwords*.

Após o treinamento do modelo de *word2vec* para representação numérica dos nossos tweets de interesse, foi realizada a validação de performance via validação cruzada dos dados, utilizando 80 por cento dos 831 tweets previamente rotulados para treinamento, e 20 por cento para teste. Abaixo, são apresentadas as respectivas acurácias e F1 Scores de cada algoritmo candidato. Cada valor apresentado, na Tabela 5.2, corresponde a uma média entre três execuções de treinamento do algoritmo. A rede neural utilizada para a análise de performance, na Tabela 5.2, possuía uma camada de ativação logística e duas camadas internas de oito neurônios cada. Já a floresta aleatória possuía árvores com parâmetro dez de profundidade. Esses também valores foram identificados de forma empírica, ao longo dos nossos experimentos³. Para o algoritmo de regressão logística, utilizamos fator de regularização ajustado manualmente.

Tabela 5.2 – Tabela de Performance dos Algoritmos Recebendo *word2vec* como Entrada

<i>Algoritmo</i>	<i>Acurácia</i>	<i>F1 Score</i>
Rede Neural	0.79	0.76
Regressão Logística	0.75	0.70
Floresta Aleatória	0.73	0.63

Fonte: A Autora

Nas Tabela 5.2, note que existem valores de performance próximos entre os algoritmos, e é possível que não necessariamente exista uma diferença estatisticamente significativa entre, por exemplo, a acurácia de redes neurais e regressão logística. Entretanto, verificamos que empiricamente a rede neural, que tem a acurácia predita maior, tende a ter uma performance melhor quando testada na prática no cenário deste trabalho.

Ainda é possível visualizar, na Tabela 5.2, que o algoritmo com melhor performance e—que foi escolhido para analisar automaticamente os sentimentos dos demais tweets—foi o algoritmo Rede Neural, e a representação foi o modelo *word2vec*, que teve melhor performance com relação ao modelo *TF-IDF*.

³Foram realizados testes alterando (aumentando e diminuindo) o número de camadas e neurônios da rede neural, até que se chegasse em valores que maximizassem a performance do algoritmo. Também foram realizados testes com o mesmo propósito referentes à profundidade das árvores da floresta aleatória.

Com base nas análises acima, podemos concluir que a arquitetura de melhor performance para construção de um modelo de análise de sentimentos para o nosso problema, corresponde a uma rede neural operando sobre representação de dados *word2vec*. No capítulo 6, iremos utilizar esse modelo, portanto, para analisar os dados descritos na Seção 4.1.2, a fim de iniciarmos nossa análise a respeito das diferentes hipóteses por nós levantadas, a respeito das capacidades e limitações de algoritmos de análise de sentimentos como maneira de automaticamente inferir que eventos relevantes à pandemia ocorreram.

6 RESULTADOS

Em cada seção deste capítulo, iremos apresentar os resultados relacionados a cada uma das hipóteses definidas no Capítulo 4. Note que, aqui, utilizamos o termo hipótese no sentido de que são possibilidades que gostaríamos de verificar empiricamente se podem ser confirmada ou não de acordo com as previsões feitas pelo nosso modelo. Por exemplo, é possível confirmar empiricamente, com a saída do nosso modelo, que a taxa de aprovação do presidente se correlaciona com a quantidade de tweets negativos ao longo do tempo? Essa é uma hipótese que será avaliada. Note que estamos utilizando o termo hipótese de forma diferente do uso do termo hipótese no contexto estatístico.

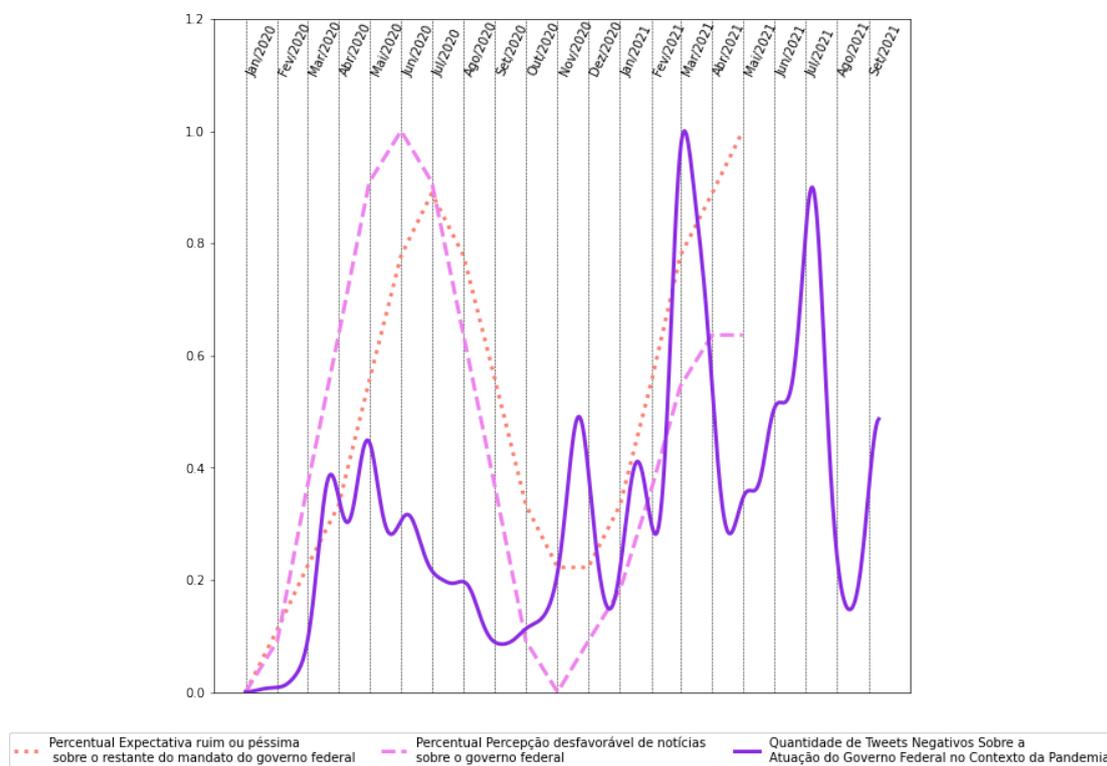
Em todas as figuras apresentadas nas próximas seções, a taxa de crescimento de tweets negativos relacionados ao governo federal, no contexto da pandemia, foi suavizada aplicando-se um filtro gaussiano (MARR; HILDRETH, 1980) —um filtro capaz de reduzir o nível de ruído em um sinal de entrada ou série temporal. Já os dados relacionados às taxas de mortes e aos novos casos de COVID-19 registrados diariamente, foram obtidos no repositório inf-covid19 (COVID19, 2020). Esse repositório está atrelado a uma ferramenta desenvolvida—majoritariamente—por pesquisadores do Instituto de Informática da Universidade Federal do Rio Grande do Sul. Dessa ferramenta, foi possível extrair, então, os dados diários de casos e mortes por COVID-19 do RS e do Brasil entre janeiro de 2020 e setembro de 2021. Com esses dados em mão, realizamos o cálculo de novas taxas baseadas em médias móveis de três dias, a fim de suavizar as curvas e capturar as tendências gerais. Além disso, *os gráficos foram suavizados* através da aplicação de um filtro gaussiano (MARR; HILDRETH, 1980) para remoção de ruídos, e *também normalizados* entre 0 e 1 para que possamos avaliar as métricas proporcionalmente.

6.1 Hipótese 1: Correlação entre Reprovação do Governo Federal e Quantidade de Tweets Negativos

Nesta seção, iremos apresentar dados relacionados à tendência de reprovação do governo Jair Bolsonaro e a distribuição, ao longo do tempo, de tweets negativos relacionados ao governo federal no contexto da pandemia.

Na Figura 6.1, apresentamos uma comparação entre a taxa de crescimento de tweets negativos relacionados ao governo federal, no contexto da pandemia, e (i) a expectativa "ruim ou péssima" sobre o restante do mandato do governo federal; e (ii) a percepção des-

Figura 6.1 – Avaliação do Governo Jair Bolsonaro vs. Quantidade de Tweets Negativos



Fonte: A Autora

favorável de notícias sobre o governo federal. Os dados relacionados às avaliações da expectativa do mandato do governo federal e da percepção de notícias sobre o governo federal foram obtidos através da pesquisa XP/Ipespe da XP Investimentos (XP/INESPE,), a qual visa apresentar dados relacionados à avaliação do governo Jair Bolsonaro entre maio de 2018 e maio de 2021. Infelizmente, essa pesquisa só possui dados até maio de 2021, portanto é possível notar que as curvas terminam nesse mês. Os dados relacionados a essa pesquisa correspondem a consultas realizadas mensalmente com a população. Após a obtenção dos dados, *eles foram suavizados através da aplicação de um filtro gaussiano (MARR; HILDRETH, 1980), a fim de remover ruído.*

Na Figura 6.1, ainda é possível perceber o crescimento, entre os meses de janeiro e setembro de 2020, das três métricas, possivelmente remetendo ao início da pandemia e à percepção negativa sobre as ações tomadas, no contexto da pandemia, pelo governo durante esse período. Entre os meses de janeiro de 2021 e março de 2021, novamente, percebemos a tendência de crescimento das três métricas, período de agravamento da pandemia no Brasil e no Rio Grande do Sul.

Portanto, embora qualitativamente *possa* haver uma correlação entre esses even-

tos, tal correlação *não* é óbvia e/ou estatisticamente significativa. Tendo dito isso, parece haver uma associação fraca entre a tendência geral de aumento de tweets negativos e a percepção da população sobre o governo. Nesse contexto podemos concluir que a análise de sentimentos informa algo sobre a tendência de aprovação do governo federal, mas não de forma estatisticamente forte a ponto de que possamos automatizar o processo de detecção/inferência da ocorrência de eventos relevantes à pandemia (ao menos no contexto da pesquisa de taxa de aprovação do governo federal). Essa conclusão pode estar relacionada à suposição de que a mudança de opinião da população sobre a atuação do presidente não se altera de forma tão frequente, isto é, de um dia para o outro, pessoas aprovam e/ou deixam de aprovar a atuação do governo federal. Além disso, é possível que as limitações nas análises a serem efetuadas, discutidas na Seção 4.6, podem influenciar para a não correlação entre essas métricas.

6.2 Hipótese 2: Correlação entre Taxa de Mortes Diária por COVID-19 e Quantidade de Tweets Negativos

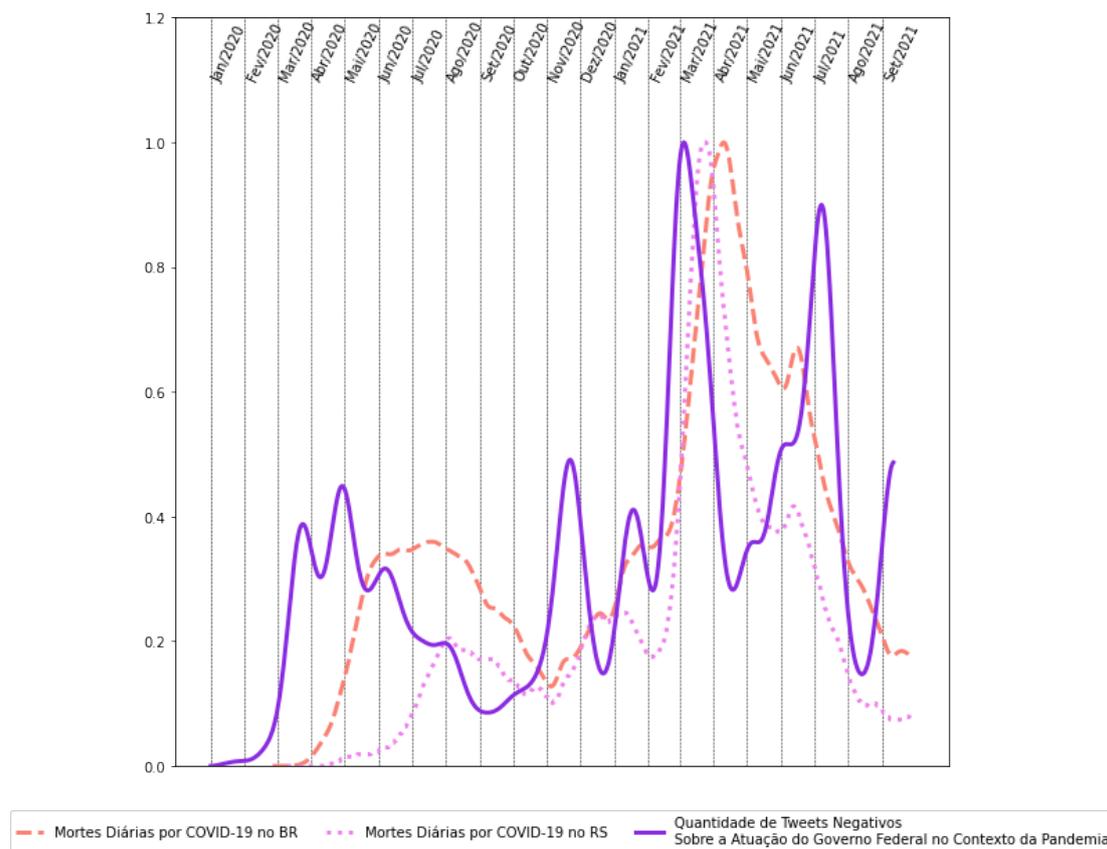
Nesta seção, iremos apresentar dados relacionados à taxa de mortes diária por COVID-19 no Brasil e no Rio Grande do Sul, e a quantidade de tweets negativos ao longo da pandemia.

Na Figura 6.2, apresentamos a taxa de crescimento de tweets negativos relacionados ao governo federal no contexto da pandemia, e (i) a taxa de mortes diárias por COVID-19 no Brasil; e (ii) a taxa de mortes diárias por COVID-19 no Rio Grande do Sul.

Na Figura 6.2, é possível perceber a nítida correlação entre as métricas. Dentre os meses de março de 2020 e setembro de 2020, início da pandemia no Brasil, é possível notar o crescimento e a diminuição simultâneos, e de forma proporcional, das três métricas. Porém, a métrica de tweets negativos aumenta e decai com um deslocamento à esquerda em relação às outras duas métricas. Acreditamos que esse deslocamento tenha relação com a avaliação da população em relação às ações tomadas pelo governo federal sobre a pandemia antes do aumento da curva de mortes por COVID-19, como se a população estivesse acompanhando a tendência do aumento no número de mortes e reagindo de forma proporcional na rede social; e que, enquanto a tendência no número de mortes se mantinha, também se mantinha de forma sincronizada e proporcional, a taxa de reações negativas no Twitter.

Já a partir do mês de novembro de 2020 até julho de 2021, as métricas têm ten-

Figura 6.2 – Mortes Diárias por COVID-19 vs. Quantidade de Tweets Negativos

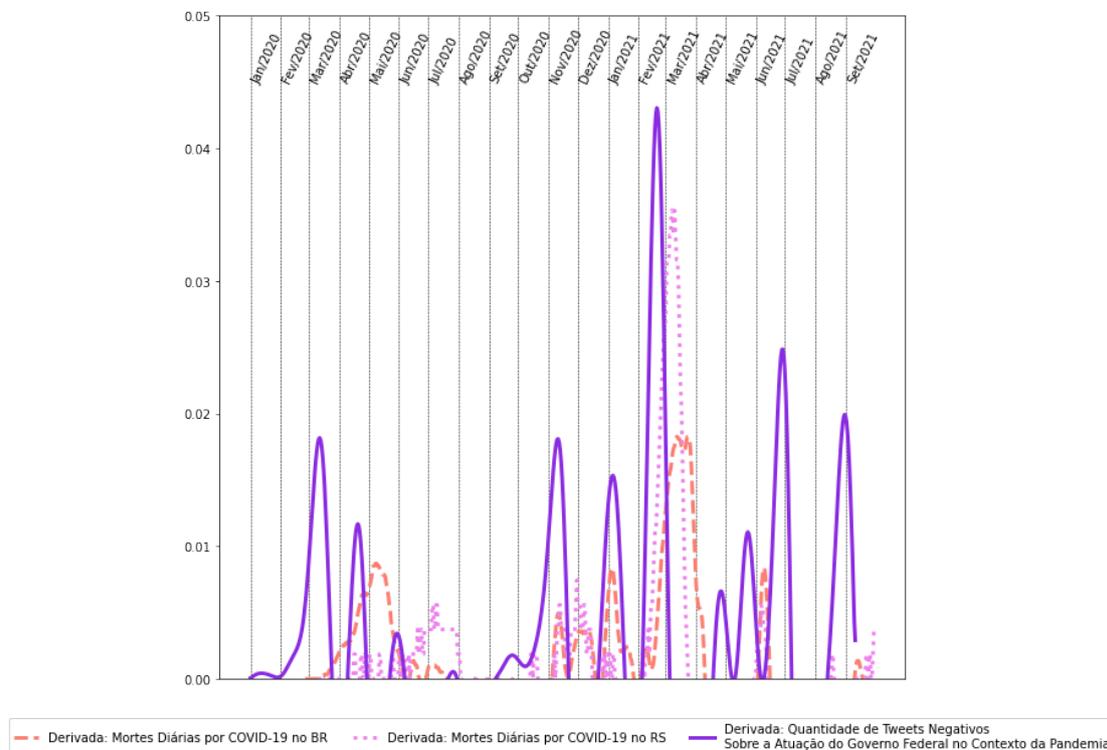


Fonte: A Autora

dência de crescimento e diminuição parecidas, mas com um deslocamento à esquerda das métricas de tweets negativos e de mortes diárias por COVID-19 no Rio Grande do Sul. Acreditamos que, nesse caso, o deslocamento tem relação com a *região* em que os tweets avaliados foram coletados. Eles são relativos à região de Porto Alegre, e—durante o período citado—houve o colapso e recuperação do sistema de saúde da região, antes de que esse evento se espalhasse para o resto do país. Em 3 de março de 2021, houve o colapso do sistema de saúde da cidade; em 27 de março de 2021, o jornal *The New York Times* declarou Porto Alegre como o epicentro da pandemia. Isso ocorreu *antes* da curva de mortes diárias por COVID-19 no Brasil ter seu ápice. Portanto, durante esse período, acreditamos que a população gaúcha já estava expressando seu sentimento negativo em relação à atuação do governo federal no contexto da pandemia (na forma como ela se manifestou no estado do RS) ao perceber que a taxa de casos e de mortes estava crescendo exponencialmente antes mesmo que isso ocorresse no restante do país. Ou seja, a expressão de sentimentos negativos no Twitter se refletiu primeiramente em função da piora da pandemia no estado do RS, visto que, naquele momento, o estado do RS estava

apresentando taxas de piora superiores às do restante do país.

Figura 6.3 – Derivadas: Mortes Diárias por COVID-19 vs. Quantidade de Tweets Negativos



Fonte: A Autora

Na Figura 6.3, também são apresentadas as derivadas das métricas anteriormente discutidas. Nessa figura, é possível perceber—mais uma vez—que o crescimento e declínio das métricas ocorre em períodos similares. Ou seja, não apenas a taxa de mortes e a quantidade de tweets se correlacionam, mas tal correlação também se reflete na maneira como tais métricas mudam ao longo do tempo: locais onde a derivada do número de mortes é negativa (indicando decaimento do número de mortes) se correlacionam com locais onde a derivada do número de tweets é negativa (indicando uma diminuição na proporção de reações negativas na mídia social). O fato de que tanto as métricas quanto as suas derivadas terem correlações evidentes reforça nossa hipótese de que, especificamente, no que diz respeito aos efeitos da pandemia no número de mortes, análise de sentimentos pode ser utilizada de forma bem sucedida para identificar eventos e pontos de inflexão; por exemplo, momentos em que a pandemia melhora momentaneamente.

Na Tabela 6.1, foi calculada a métrica *Dynamic Time Wrapping* (DTW^1) entre essas

¹O algoritmo *DTW* mede a distância entre séries temporais que podem não estar totalmente alinhadas, ou seja, podem não estar alinhadas em velocidade. Um exemplo clássico do uso desse algoritmo é reconhecimento automático de voz, para detectar diferentes velocidades de fala.

Tabela 6.1 – Tabela de Cálculo do DTW entre Gráfico de Tweets Negativos e Outros Gráficos

<i>Gráfico</i>	<i>DTW</i>
Mortes por COVID-19 no BR	1.43
Mortes por COVID-19 no RS	1.77
Casos de COVID-19 no BR	2.35
Casos de COVID-19 no RS	2.05

Fonte: A Autora

séries temporais. Para isso, foi utilizada a implementação do algoritmo *DTW* disponível na biblioteca *Scikit Learn* (LEARN, 2010). Esse algoritmo recebe foi originalmente proposto para análises no contexto de reconhecimento de fala, mas atualmente é utilizado em aplicações diversas envolvendo a necessidade de comparação de séries temporais—as quais não necessariamente precisam estar alinhadas no tempo. Nela, é possível perceber que a tendência de tweets negativos é mais diretamente similar aos seguintes eventos, respectivamente e em ordem: (i) Mortes no Brasil; (ii) Mortes no RS; (iii) Casos no Brasil; e (iv) Casos no RS.

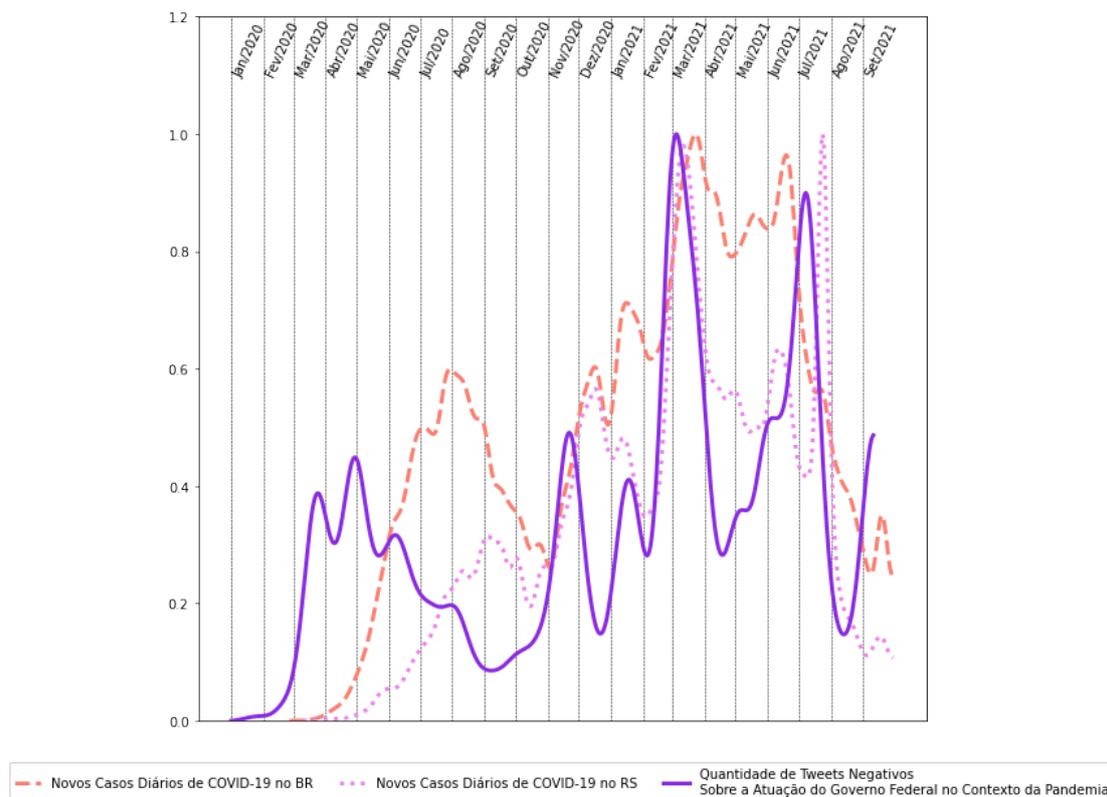
Portanto, é possível obter evidências de que existe uma correlação entre a taxa de crescimento de tweets negativos relacionados ao governo federal no contexto da pandemia, a taxa de mortes diárias por COVID-19 no Brasil e a taxa de mortes diárias por COVID-19 no Rio Grande do Sul.

6.3 Hipótese 3: Correlação entre Novos Casos Diários de COVID-19 e Quantidade de Tweets Negativos

Nesta seção, iremos apresentar dados relacionados à taxa diária de novos casos de COVID-19 no Brasil e no Rio Grande do Sul e a quantidade de tweets negativos ao longo da pandemia. Na Figura 6.4, apresentamos a taxa de crescimento de tweets negativos relacionados ao governo federal no contexto da pandemia, a taxa de novos casos diários de COVID-19 no Brasil e a taxa de novos casos diários de COVID-19 no Rio Grande do Sul.

Na Figura 6.4, é possível perceber—ao menos através de inspeção visual—que há, em alguns momentos ao longo do período de tempo analisado, correlação entre as métricas. Em particular, no período de março de 2020. Do período entre março de 2020 e outubro de 2020, existe uma taxa de crescimento e decaimento similar entre as métricas. E, a partir de fevereiro de 2021 até o ápice em março de 2021, as três métricas crescem juntas, correlacionando o pico na taxa de tweets negativos com o momento de maior

Figura 6.4 – Novos Casos de COVID-19 vs. Quantidade de Tweets Negativos



Fonte: A Autora

número de casos da pandemia no Brasil e no RS. Note, entretanto, que embora a Figura 6.4 sugira que tais correlações existem, de forma geral, as séries temporais não estão fortemente correlacionadas em *todos* os meses sendo analisados.

Já a partir do mês de novembro de 2020 até julho de 2021, as métricas de casos de COVID-19 no Brasil e tendência de tweets negativos têm momentos de similaridade entre crescimento e queda. Em comparação, as métricas de casos de COVID-19 no Rio Grande do Sul e tendência de tweets negativos sobem e descem de forma muito similar. Mais uma vez, citamos que os tweets avaliados são relativos à região de Porto Alegre, que teve—no período citado—seu ápice e declínio de casos de COVID-19. Por isso, acreditamos que a tendência de tweets negativos se aproxima muito mais da *taxa de novos casos diária* no Rio Grande do Sul do que no Brasil.

Portanto, também é possível, através dessa análise, demonstrar que existe uma correlação entre a taxa de crescimento de tweets negativos relacionados ao governo federal no contexto da pandemia, a taxa de novos casos diária no Brasil e a taxa de novos casos diário no Rio Grande do Sul.

6.4 Hipótese 4: Correlação entre Eventos Relevantes e Quantidade de Tweets Negativos

Nas subseções que seguem, iremos investigar diversas possíveis correlações entre picos de tweets negativos ao longo do tempo, e a ocorrência de eventos relacionados à pandemia e ao governo federal, tendo eles sido divulgados pelas mídias tradicionais (como Zero Hora, Correio do Povo, El País, Folha de São Paulo, entre outros) ou não. Para isso, apresentamos na Figura 6.5, apresentamos (i) a curva suavizada de tweets negativos ao longo do tempo, dentre janeiro de 2020 e setembro de 2021; e também (ii) destacamos os dias ocorreu há algum evento relevante no contexto deste trabalho, ou seja, eventos relacionados à atuação do governo federal brasileiro durante a pandemia COVID-19. O propósito de suavizar tal curva é remover ruídos, e variações naturais/estatísticas no número de tweets negativos a cada dia. Tal suavização auxilia na análise de nossas hipóteses; em particular, de que há correlação entre picos na curva de quantidade de tweets negativos ao longo do tempo e a ocorrência de eventos relevantes.

Tabela 6.2 – Descrição dos Eventos Destacados na Figura 6.5.

<i>Data</i>	<i>Notícia/Manchete</i>	<i>Fonte</i>
25/03/2020	"Bolsonaro contraria todas as orientações de especialistas e pede fim do isolamento social contra o coronavírus."	(G1, 2020c)
29/03/2020	"Após provocar aglomeração durante passeio em Brasília, Bolsonaro volta a se posicionar contra o isolamento social."	(G1, 2020b)
06/04/2020	"Coronavírus: vereador e família usam redes sociais para zombar de vítimas."	(Correio Braziliense, 2020)
19/04/2020	"Bolsonaro endossa ato pró-intervenção militar e provoca reação de Maia, STF e governadores."	(El País, 2020b)
30/04/2020	"O presidente Bolsonaro descumpra ordem judicial, não entrega exames de Covid-19 e diz em entrevista que 'talvez já tenha pegado esse vírus'."	(G1, 2020f)

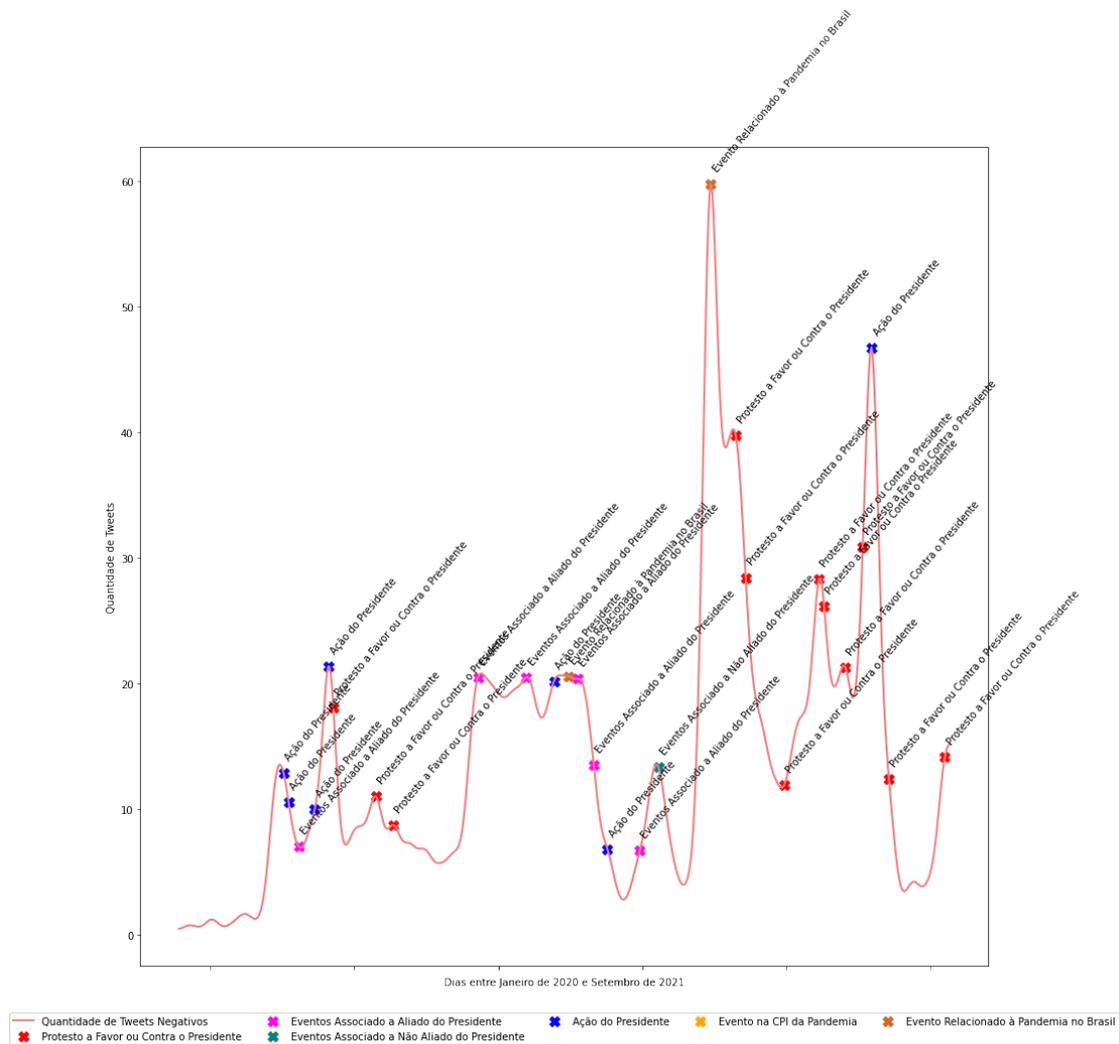
04/05/2020	"A semana começa com tensão entre Jair Bolsonaro, o Congresso e o STF depois que, mais uma vez, o presidente participou de atos antidemocráticos."	(G1, 2020a)
07/06/2020	"Protestos contra o Governo Bolsonaro se espalham por dezenas de cidades e ignoram orientação de evitar aglomeração social. 'Tenho mais medo do racismo que da pandemia'."	(El País, 2020c)
21/06/2020	"Brasília tem Esplanada dividida entre protestos pró e contra Bolsonaro".	(G1, 2020d)
28/08/2020	"Em meio à pandemia, o governador do Rio, Wilson Witzel, é afastado do cargo por suspeita de corrupção na saúde."	(G1, 2020e)
06/10/2020	"Trump se entrega ao negacionismo da covid-19 na reta final da campanha."	(El País, 2020d)
28/10/2020	"SUS: Bolsonaro revoga decreto sobre privatização de unidades básicas de saúde."	(G1, 2020h)
09/11/2020	"Anvisa alega 'evento adverso grave' para suspender estudos da Coronovac, embora incidente não seja relacionado à vacina."	(El País, 2020a)
16/11/2020	"Resultado do 1o Turno das Eleições para Prefeitura."	(G1, 2020g)
29/11/2020	"Eleições municipais 2020: os resultados do segundo turno nas capitais do Brasil."	(BBC, 2020)
12/10/2020	"Bolsonaro em dezembro: 'Pandemia está no finalzinho'."	(Estado de Minas, 2020)
05/01/2021	"'Dar uma emparelhada', diz Melo sobre novo decreto que deve equiparar medidas de Porto Alegre com regras estaduais de combate à Covid-19"	(G1, 2021e)
21/01/2021	"Dia histórico: Joe Biden toma posse como 46º presidente dos Estados Unidos."	(G1, 2021f)
03/03/2021	"Saúde em Colapso."	(Zero Hora, 2021)

23/03/2021	"Cidades brasileiras registram panelaço contra Bolsonaro nesta terça-feira."	(G1, 2021d)
31/03/2021	"Em Porto Alegre, grupos fazem atos em referência a 31 de março. Mobilizações contra e a favor ocorreram no centro da cidade."	(Correio do Povo, 2021)
01/05/2021	"Feriado do Dia do Trabalho tem manifestações em cidades do RS."	(G1, 2021)
05/05/2021	"O ex-ministro da Saúde Nelson Teich depõe na CPI da Covid e diz que a cloroquina foi o estopim de sua saída do governo."	(G1, 2021b)
11/05/2021	"Antonio Barra Torres, presidente da Anvisa, depõe na CPI da Covid, diverge de Bolsonaro e condena aglomerações e cloroquina."	(G1, 2021b)
29/05/2021	"Todos os estados e o Distrito Federal registram manifestações contra governo Bolsonaro."	(G1, 2021c)
02/06/2021	"Cidades brasileiras registram panelaço contra Bolsonaro nesta quarta-feira."	(G1, 2021c)
19/06/2020	"Os atos contra Bolsonaro na avenida Paulista."	(El País, 2021)
03/07/2021	"Protestos por impeachment de Bolsonaro são registrados em 25 capitais."	(CNN, 2021)
10/07/2021	"Em motociata, Bolsonaro volta a atacar Barroso: 'Não devia estar no STF'."	(Uol Noticias, 2021)
24/07/2021	"Manifestantes fazem atos contra Bolsonaro e a favor da vacina nos 26 estados e no DF."	(G1, 2021a)
07/09/2021	"7 de Setembro tem protestos a favor e contra o governo Bolsonaro."	(G1, 2021a)

Fonte: A Autora

É possível notar, na Figura 6.5, que *todos* os dias em que há picos de tweets negativos correspondem a dias em que ocorreram eventos relevantes no contexto deste trabalho. Portanto, podemos observar que sempre (ou quase sempre; com probabilidade alta) a ocorrência de um pico de tweets negativos implica a ocorrência de um evento relevante.

Figura 6.5 – Quantidade de Tweets Negativos e Eventos Relevantes



Fonte: A Autora

Contudo, *nem todos eventos relevantes estão em picos*. Nosso objetivo, neste trabalho, é garantir *alta acurácia de nossas inferências*, isto é, sempre que o nosso sistema sugerir que houve algo relevante (no caso, por ter detectado um pico negativo), ele está, com alta probabilidade, correto. Podemos observar ainda, na Figura 6.5, que este é caso: sempre que nosso modelo prevê a ocorrência de um número anormal de tweets negativos (isto é, um pico na série temporal), há um evento relevante na data correspondente. Note, por outro lado, que há eventos relevantes fora dos picos, o que indica uma possível limitação do método de análise de sentimentos em termos de *recall*, no contexto desse trabalho. Em outras palavras, a tentativa de inferir eventos relevantes através de análise de sentimentos pode resultar em algoritmo com alta acurácia, mas *recall* sub-ótimo: eventos identificados como relevantes quase sempre são verdadeiros-positivos, mas há eventos que podem não

ser preditos com base apenas na análise de dados de redes sociais.

6.4.1 Eventos Relevantes Relacionados a Protestos Contra ou a Favor do Presidente

Dentre o período de janeiro de 2020 até setembro de 2021, diversos protestos foram realizados contra e a favor do presidente. Esses protestos foram realizados em diferentes formatos, como manifestações nas ruas das cidades brasileiras ou como os famosos "panelaços" realizados das janelas das residências brasileiras.

Na Figura 6.5, é possível notar que para diversos desses eventos correspondem a picos de tweets negativos; ou seja, análise de sentimentos, nesse contexto, permite identificar que algo relevante estava acontecendo naquele data. Além disso, é interessante salientar que tais tweets eram publicados em tempo real, ou seja, enquanto os protestos estão ocorrendo. Sendo assim, a identificação de que um evento importante está acontecendo pode, através de análises tais como a proposta nesse trabalho, ocorrer de maneira mais rápida do que estratégias alternativas que tivessem que aguardar até que as mídias tradicionais divulgassem o acontecimento daquele evento.

6.4.2 Eventos Relevantes Associados a Aliados do Presidente

É possível notar, também na Figura 6.5, a existência de picos de tweets negativos quando uma figura pública que é explicitamente apoiadora do presidente Jair Bolsonaro toma alguma ação em relação à pandemia. Foi o caso, por exemplo, do atual prefeito de Porto Alegre, Sebastião Melo, que apoiou a campanha do presidente Jair Bolsonaro. Diversas das ações tomadas pelo prefeito de Porto Alegre no contexto da pandemia fizeram com que as usuárias do Twitter publicassem postagens relacionadas às ações do prefeito, correlacionando as suas ações com a atuação do presidente Jair Bolsonaro no contexto da pandemia. Além disso, houve também um pico de tweets negativos durante os dois turnos da eleições para prefeito de 2020, na qual o prefeito de Porto Alegre Sebastião Melo foi eleito, em derrota à candidata a prefeita Manuela D'Ávila.

Outro caso relevante, por fim, diz respeito ao evento da divulgação de um vídeo de um vereador gaúcho (apoiador do presidente) satirizando a pandemia, em abril de 2020. Nesse caso, as usuárias do twitter fizeram publicações relacionadas ao vídeo, e nos quais relacionaram a ação do vereador com o presidente Jair Bolsonaro.

6.4.3 Falas e Ações Polêmicas do Presidente Sobre a Pandemia

Diversas falas e ações do presidente da república, relacionadas à pandemia, viralizaram na plataforma Twitter, gerando picos de tweets negativos. Em 25 de março de 2020, por exemplo, o presidente Jair Bolsonaro fez um discurso contrário às medidas de proteção contra a COVID-19. Em 29 de março de 2020, o presidente provocou aglomeração durante passeio em Brasília e voltou a se posicionar contra o isolamento social. Em 19 de abril de 2020, o presidente participou de um protesto pró-intervenção militar. Em todos esses casos, nosso modelo foi capaz de prever a ocorrência de tais eventos relevantes, com base na análise e predição de picos de tweets negativos nas datas correspondentes.

6.4.4 Eventos Relevantes na CPI da Pandemia

A CPI da pandemia é uma comissão parlamentar de inquérito atualmente em andamento no Brasil, a qual busca investigar omissões e irregularidades na atuação do governo federal no contexto da pandemia de COVID-19 no Brasil. É possível notar, em diversas datas, na Figura 6.5, a existência de picos de tweets negativos nas datas em que houve o depoimento de figuras relevantes para a CPI. Alguns exemplos são os depoimentos do ex-ministro da saúde, Nelson Teich, e do presidente da Anvisa, Antonio Barra Torres, os quais ocorreram, respectivamente, nas datas 5 de maio de 2021 e 11 de maio de 2021.

6.4.5 Eventos Relevantes Relacionados à Pandemia no Brasil

O pico mais alto/expressivo de tweets negativos, na Figura 6.5, diz respeito a um dos casos de ocorrência de eventos relevantes, *diretamente*, relacionados à pandemia no Brasil. Esse pico consiste, em particular, ao momento de ápice da pandemia no país e, especialmente, no colapso do sistema de saúde de Porto Alegre, em 3 de março de 2020, divulgado pelo Jornal Zero Hora (Zero Hora, 2021).

6.4.6 Eventos Relevantes Associados a Não Aliados do Presidente

Assim como em eventos relacionados a figuras publicamente aliadas ao Presidente Jair Bolsonaro, também há picos de tweets negativos, conforme predito por nosso modelo,

em dias de eventos relacionados a figuras publicamente não simpatizantes do Presidente Jair Bolsonaro, como é o caso do atual presidente dos Estados Unidos da América, Joe Biden. Sua posse, no dia 20 de janeiro de 2021, foi corretamente identificada por nossa análise e refletida em um pico desse tipo de evento.

7 CONCLUSÃO

Devido à evolução da internet e à popularização das redes sociais, que disponibilizam de maneira pública, constante e imediata a opinião de milhões de usuários, entende-se que é possível coletar opiniões e *feedbacks* de usuários em tempo real sobre praticamente quaisquer tópicos. Nesse sentido, diversos autores relatam os benefícios potenciais do uso de análise automática de sentimentos (FELDMAN, 2013).

No entanto, há desafios relacionados à coleta e à representatividade de tais dados e análises. Existem, por exemplo, limitações relacionadas ao alcance das redes e à diversidade dos grupos de pessoas que as utilizam. Quando consultamos opiniões nas redes sociais, estamos consumindo informações apenas dos grupos de pessoas que as utilizam e que têm acesso a elas, o que introduz um viés em nossas conclusões, visto que 40 milhões de brasileiros ainda não têm acesso à internet.

Neste trabalho, visamos avaliar até que ponto as opiniões de usuários do Twitter—relacionadas à atuação do governo federal no contexto da pandemia COVID-19—permitem inferir possíveis correlações de tais opiniões com a divulgação de notícias ou eventos relevantes nas grandes mídias tradicionais, ou com a ocorrência de eventos significativos no contexto da pandemia.

Nesse sentido, pudemos observar as capacidades e as limitações que técnicas de análise automática de sentimentos têm no que diz respeito à inferência de ocorrência de eventos relevantes no contexto da pandemia. Em particular, observamos que *não* é possível encontrar tais correlações quando analisamos a ocorrência de variações temporais de tweets negativos, e, por exemplo, a taxa de aprovação do presidente. Por outro lado, pudemos também observar que em vários casos *é possível* utilizar ferramentas de análise de sentimentos para identificar eventos relevantes. Por exemplo, pudemos mostrar tanto qualitativamente (através de gráficos) quanto quantitativamente (através de tabelas mensurando o nível de correlação entre diferentes séries temporais), que há correlações nítidas, por exemplo, entre picos e tendências de crescimento de tweets negativos com alterações importantes nos números de mortes e de casos de COVID-19, tanto em nível local/estadual, quanto em nível nacional. Isso reforça nossa intuição e hipóteses originais de que análise automática de dados de redes sociais *podem* refletir eventos relevantes para a sociedade, mas que há limitações, e que tais análises (e suas interpretações) precisam ser feitas de forma cuidadosa.

Como evolução do presente trabalho, entendemos que a definição de classes de

sentimentos por nós proposta foi bastante restrita, e que poderia ser estendida em um trabalho futuro de forma a englobar mais tipos de sentimentos—tais como sentimentos (positivos, negativos, ou neutros) expressos através de figuras de linguagem tais como ironia e sarcasmo. A análise automática de opiniões expressas dessa forma é, atualmente, um grande desafio no campo de análise de sentimentos através de técnicas de aprendizado de máquina.

REFERÊNCIAS

ANDRIOT, J. et al. Sentiment analysis of democratic presidential primaries debate tweets using machine learning models. In: _____. [S.l.: s.n.], 2020. p. 339–349. ISBN 978-981-15-4028-8.

BBC. Eleições municipais 2020: os resultados do segundo turno nas capitais do Brasil. Acessado em: 2021-11-15. 2020. Available from Internet: <<https://www.bbc.com/portuguese/brasil-55125331>>.

BREIMAN, L. Random forests. **Machine Learning**, v. 45, p. 5–32, 10 2001.

CNN. Protestos por impeachment de Bolsonaro são registrados em 25 capitais. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://www.cnnbrasil.com.br/politica/manifestacoes-contra-bolsonaro-3-de-julho-de-2021/>>.

Correio Braziliense. **Coronavírus: vereador e família usam redes sociais para zombar de vítimas** Acessado em: 2021-11-15. 2020. Available from Internet: <https://www.correiobraziliense.com.br/app/noticia/politica/2020/04/06/interna_politica,842753/coronavir-us-vereador-e-familia-usam-redes-sociais-para-zombar-de-viti.shtml>.

Correio do Povo. **Em Porto Alegre, grupos fazem atos em referência a 31 de março. Mobilizações contra e a favor ocorreram no centro da cidade. Acessado em: 2021-11-15.** 2021. Available from Internet: <<https://www.correiodopovo.com.br/not%C3%ADcias/pol%C3%ADtica/em-porto-alegre-grupos-fazem-atos-em-refer%C3%A2ncia-a-31-de-mar%C3%A7o-1.596163>>.

COVID19 inf. **inf-covid19**. [S.l.]: GitHub, 2020. <<https://github.com/inf-covid19>>.

CRAMER, J. The origins of logistic regression. **Tinbergen Institute, Tinbergen Institute Discussion Papers**, 01 2002.

DEV pandas. **pandas**. [S.l.]: GitHub, 2011. <<https://github.com/pandas-dev/pandas>>.

ECMETRICS. **<http://ecmetrics.com/pt/o-brasil-e-o-segundo-colocado-em-numero-de-usuarios-do-twitter/> Acessado em: 2021-11-02.**

El País. **Anvisa alega “evento adverso grave” para suspender estudos da Coronavac, embora incidente não seja relacionado à vacina. Acessado em: 2021-11-15.** 2020. Available from Internet: <<https://brasil.elpais.com/brasil/2020-11-10/anvisa-alega-evento-adverso-grave-para-suspender-estudos-da-coronavac-embora-incidente-nao-seja-relacionado-a-vacina.html>>.

El País. **Bolsonaro endossa ato pró-intervenção militar e provoca reação de Maia, STF e governadores** Acessado em: 2021-11-15. 2020. Available from Internet: <<https://brasil.elpais.com/politica/2020-04-19/bolsonaro-endossa-ato-pro-intervencao-militar-e-provoca-reacao-de-maia-stf-e-governadores.html>>.

El País. **Protestos contra o Governo Bolsonaro se espalham por dezenas de cidades e ignoram orientação de evitar aglomeração social. "Tenho mais medo do racismo que da pandemia".** Acessado em: 2021-11-15. 2020. Available from Internet: <<https://brasil.elpais.com/brasil/2020-06-08/atos-pela-democracia-elevam-tom-contra-o-racismo-no-brasil.html>>.

El País. **Trump se entrega ao negacionismo da covid-19 na reta final da campanha.** Acessado em: **2021-11-15**. 2020. Available from Internet: <<https://brasil.elpais.com/internacional/2020-10-06/trump-se-entrega-ao-negacionismo-da-covid-19-na-reta-final-da-campanha.html>>.

El País. **Os atos contra Bolsonaro na avenida Paulista.** Acessado em: **2021-11-15**. 2021. Available from Internet: <<https://brasil.elpais.com/brasil/2021-06-20/os-atos-contra-bolsonaro-na-avenida-paulista.html>>.

Estado de Minas. **Bolsonaro em dezembro: 'Pandemia está no finalzinho'.** Acessado em: **2021-11-15**. 2020. Available from Internet: <https://www.em.com.br/app/noticia/politica/2021/03/16/interna_politica,1247470/bolsonaro-em-dezembro-pandemia-esta-no-finalzinho.shtml>.

FARIAS, D. H.; ROSSO, P. Chapter 7 - irony, sarcasm, and sentiment analysis. In: POZZI, F. A. et al. (Ed.). **Sentiment Analysis in Social Networks**. Boston: Morgan Kaufmann, 2017. p. 113–128. ISBN 978-0-12-804412-4. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/B9780128044124000073>>.

FELDMAN, R. Techniques and applications for sentiment analysis. **Commun. ACM**, Association for Computing Machinery, New York, NY, USA, v. 56, n. 4, p. 82–89, abr. 2013. ISSN 0001-0782. Available from Internet: <<https://doi.org/10.1145/2436256.2436274>>.

G1. **A semana começa com tensão entre Jair Bolsonaro, o Congresso e o STF depois que, mais uma vez, o presidente participou de atos antidemocráticos.** Acessado em: **2021-11-15**. 2020. Available from Internet: <<https://g1.globo.com/agenda-do-dia/noticia/2020/05/04/4-de-maio-segunda-feira.ghtml>>.

G1. **Após provocar aglomeração durante passeio em Brasília, Bolsonaro volta a se posicionar contra o isolamento social** Acessado em: **2021-11-15**. 2020. Available from Internet: <<https://g1.globo.com/politica/noticia/2020/03/29/apos-provocar-aglomeracao-durante-passeio-em-brasilia-bolsonaro-volta-a-se-posicionar-contr-o-isolamento-social.ghtml>>.

G1. **Bolsonaro contraria todas as orientações de especialistas e pede fim do isolamento social contra o coronavírus.** Acessado em: **2021-11-15**. 2020. Available from Internet: <<https://g1.globo.com/agenda-do-dia/noticia/2020/03/25/25-de-marco-quarta-feira.ghtml>>.

G1. **Brasília tem Esplanada dividida entre protestos pró e contra Bolsonaro.** Acessado em: **2021-11-15**. 2020. Available from Internet: <<https://www1.folha.uol.com.br/poder/2020/06/brasilia-tem-esplanada-dividida-entre-protestos-pro-e-contr-bolsonaro.shtml>>.

G1. **Em meio à pandemia, o governador do Rio, Wilson Witzel, é afastado do cargo por suspeita de corrupção na saúde.** Acessado em: **2021-11-15**. 2020. Available from Internet: <<https://g1.globo.com/resumo-do-dia/noticia/2020/08/28/sexta-feira-28-de-agosto.ghtml>>.

G1. O presidente Bolsonaro descumpre ordem judicial, não entrega exames de Covid-19 e diz em entrevista que "talvez já tenha pegado esse vírus". Acessado em: 2021-11-15. 2020. Available from Internet: <<https://g1.globo.com/resumo-do-dia/noticia/2020/04/30/quinta-feira-30-de-abril.ghtml>>.

G1. Resultado do 1o Turno das Eleições para Prefeitura. Acessado em: 2021-11-15. 2020. Available from Internet: <<https://g1.globo.com/agenda-do-dia/noticia/2020/11/16/16-de-novembro-segunda-feira.ghtml>>.

G1. SUS: Bolsonaro revoga decreto sobre privatização de unidades básicas de saúde. Acessado em: 2021-11-15. 2020. Available from Internet: <<https://g1.globo.com/politica/noticia/2020/10/28/bolsonaro-anuncia-revogacao-de-decreto-sobre-privatizacao-de-postos-de-saude-do-sus.ghtml>>.

G1. 7 de Setembro tem protestos a favor e contra o governo Bolsonaro. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/politica/noticia/2021/09/07/7-de-setembro-tem-protestos-a-favor-e-contra-o-governo-bolsonaro.ghtml>>.

G1. Antonio Barra Torres, presidente da Anvisa, depõe na CPI da Covid, diverge de Bolsonaro e condena aglomerações e cloroquina. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/resumo-do-dia/noticia/2021/05/11/terca-feira-11-de-maio.ghtml>>.

G1. Cidades brasileiras registram panelaço contra Bolsonaro nesta quarta-feira. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/politica/noticia/2021/06/02/cidades-brasileiras-registram-panelaco-contra-bolsonaro-nesta-quarta-feira.ghtml>>.

G1. Cidades brasileiras registram panelaço contra Bolsonaro nesta terça-feira. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/politica/noticia/2021/03/23/cidades-brasileiras-registram-panelaco-contra-bolsonaro-nesta-terca-feira.ghtml>>.

G1. 'Dar uma emparelhada', diz Melo sobre novo decreto que deve equiparar medidas de Porto Alegre com regras estaduais de combate à Covid-19. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/rs/rio-grande-do-sul/noticia/2021/01/04/melo-afirma-que-vai-publicar-novo-decreto-sobre-a-pandemia-nesta-segunda-em-porto-alegre.ghtml>>.

G1. Dia histórico: Joe Biden toma posse como 46º presidente dos Estados Unidos. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/resumo-do-dia/noticia/2021/01/20/quarta-feira-20-de-janeiro.ghtml>>.

G1. Feriado do Dia do Trabalho tem manifestações em cidades do RS. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/rs/rio-grande-do-sul/noticia/2021/05/01/feriado-do-dia-do-trabalho-tem-manifestacoes-em-cidades-do-rs.ghtml>>.

G1. Manifestantes fazem atos contra Bolsonaro e a favor da vacina nos 26 estados e no DF. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/politica/noticia/2021/07/24/protestos-sabado.ghtml>>.

G1. **O ex-ministro da Saúde Nelson Teich depõe na CPI da Covid e diz que a cloroquina foi o estopim de sua saída do governo.** Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/resumo-do-dia/noticia/2021/05/05/quarta-feira-5-de-maio.ghtml>>.

G1. **Todos os estados e o Distrito Federal registram manifestações contra governo Bolsonaro.** Acessado em: 2021-11-15. 2021. Available from Internet: <<https://g1.globo.com/politica/noticia/2021/05/29/cidades-registram-manifestacoes-contra-governo-bolsonaro.ghtml>>.

GARCIA, K.; BERTON, L. Topic detection and sentiment analysis in twitter content related to covid-19 from brazil and the usa. **Applied Soft Computing**, v. 101, p. 107057, 03 2021.

GOLDSTEIN, B. A. et al. An application of random forests to a genome-wide association dataset: methodological considerations & new findings. **BMC genetics**, BioMed Central, v. 11, n. 1, p. 1–13, 2010.

HAYKIN, S. **Neural Networks: A Comprehensive Foundation**. 3rd. ed. USA: Prentice Hall PTR, 2009. ISBN 0023527617.

HUSSEIN, D. M. E.-D. M. A survey on sentiment analysis challenges. **Journal of King Saud University - Engineering Sciences**, v. 30, n. 4, p. 330–338, 2018. ISSN 1018-3639. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/S1018363916300071>>.

HUTTO, C.; GILBERT, E. Vader: A parsimonious rule-based model for sentiment analysis of social media text. **Proceedings of the International AAAI Conference on Web and Social Media**, v. 8, n. 1, p. 216–225, May 2014. Available from Internet: <<https://ojs.aaai.org/index.php/ICWSM/article/view/14550>>.

JAIN, A. K.; MURTY, M. N.; FLYNN, P. J. Data clustering: A review. **ACM Comput. Surv.**, Association for Computing Machinery, New York, NY, USA, v. 31, n. 3, p. 264–323, sep. 1999. ISSN 0360-0300. Available from Internet: <<https://doi.org/10.1145/331499.331504>>.

JUPYTER. **notebook**. [S.l.]: GitHub, 2015. <<https://github.com/jupyter/notebook>>.

JUSTANOTHERARCHIVIST. **snacrape**. [S.l.]: GitHub, 2018. <<https://github.com/JustAnotherArchivist/snscrape>>.

KOTSIANTIS, S. B. Supervised machine learning: A review of classification techniques. In: **Proceedings of the 2007 Conference on Emerging Artificial Intelligence Applications in Computer Engineering: Real World AI Systems with Applications in EHealth, HCI, Information Retrieval and Pervasive Technologies**. NLD: IOS Press, 2007. p. 3–24. ISBN 9781586037802.

LEARN scikit. **scikit-learn**. [S.l.]: GitHub, 2010. <<https://github.com/scikit-learn/scikit-learn>>.

LILLEBERG, J.; ZHU, Y.; ZHANG, Y. Support vector machines and word2vec for text classification with semantic features. In: **2015 IEEE 14th International Conference on Cognitive Informatics Cognitive Computing (ICCI*CC)**. [S.l.: s.n.], 2015. p. 136–140.

MACHUCA, C. R.; GALLARDO, C.; TOASA, R. M. Twitter sentiment analysis on coronavirus: Machine learning approach. **Journal of Physics: Conference Series**, IOP Publishing, v. 1828, n. 1, p. 012104, feb 2021. Available from Internet: <<https://doi.org/10.1088/1742-6596/1828/1/012104>>.

MANGURI, K. H.; RAMADHAN, R. N.; AMIN, P. R. M. Twitter sentiment analysis on worldwide covid-19 outbreaks. In: . [S.l.: s.n.], 2020.

MARR, D.; HILDRETH, E. Theory of edge detection. **Proceedings of the Royal Society of London Series B**, v. 207, p. 187–217, 1980.

MATPLOTLIB. **matplotlib**. [S.l.]: GitHub, 2008. <<https://github.com/matplotlib/matplotlib>>.

MCCULLOCH, W. S.; PITTS, W. A logical calculus of the ideas immanent in nervous activity. **The bulletin of mathematical biophysics**, Springer, v. 5, n. 4, p. 115–133, 1943.

MEDHAT, W.; HASSAN, A.; KORASHY, H. Sentiment analysis algorithms and applications: A survey. **Ain Shams Engineering Journal**, v. 5, n. 4, p. 1093–1113, 2014. ISSN 2090-4479. Available from Internet: <<https://www.sciencedirect.com/science/article/pii/S2090447914000550>>.

MELITO, L. **Quem são as pessoas que não têm acesso à internet no Brasil? Acessado em: 2021-11-02**. 2020. Available from Internet: <<https://www.brasildefato.com.br/2020/08/10/quem-sao-as-pessoas-que-nao-tem-acesso-a-internet-no-brasil>>.

MELO, T. de; FIGUEIREDO, C. M. S. Comparing news articles and tweets about covid-19 in brazil: Sentiment analysis and topic modeling approach. **JMIR Public Health Surveill**, v. 7, n. 2, p. e24585, Feb 2021. ISSN 2369-2960. Available from Internet: <<http://publichealth.jmir.org/2021/2/e24585/>>.

MIKOLOV, T. et al. Efficient estimation of word representations in vector space. **Proceedings of Workshop at ICLR**, v. 2013, 01 2013.

MOHIT, B. Named entity recognition. In: _____. **Natural Language Processing of Semi-tic Languages**. Berlin, Heidelberg: Springer Berlin Heidelberg, 2014. p. 221–245. ISBN 978-3-642-45358-8. Available from Internet: <https://doi.org/10.1007/978-3-642-45358-8-8_7>.

NEWBERRY, C. **36 Twitter Stats All Marketers Need to Know in 2021 Acessado em: 2021-10-17**. 2021. Available from Internet: <<https://blog.hootsuite.com/twitter-statistic/s/>>.

NIDHALOFF. **deep-translator**. [S.l.]: GitHub, 2020. <<https://github.com/nidhaloff/deep-translator>>.

NUMPY. **Numpy**. [S.l.]: GitHub, 2002. <<https://github.com/numpy/numpy>>.

PASTOR, C. K. L. Sentiment analysis of filipinos and effects of extreme community quarantine due to coronavirus (covid-19) pandemic. **Emerging Markets Economics: Environmental & Social Aspects eJournal**, 2020.

POKHAREL, B. P. Twitter sentiment analysis during covid-19 outbreak in nepal. **Social Science Research Network**, 2020.

PRASTYO, P. H. et al. Tweets responding to the indonesian government's handling of covid-19: Sentiment analysis using svm with normalized poly kernel. **Journal of Information Systems Engineering and Business Intelligence**, v. 6, p. 112–122, 2020.

PYTHON. **cpython**. [S.l.]: GitHub, 1993. <<https://github.com/python/cpython>>.

RAJPUT, N. K.; GROVER, B. A.; RATHI, V. K. Word frequency and sentiment analysis of twitter messages during coronavirus pandemic. **arXiv preprint arXiv:2004.03925**, 2020.

RAMOS, J. et al. Using tf-idf to determine word relevance in document queries. In: CITE-SEER. **Proceedings of the first instructional conference on machine learning**. [S.l.], 2003. v. 242, n. 1, p. 29–48.

RANJAN, S.; SOOD, S.; VERMA, V. Twitter sentiment analysis of real-time customer experience feedback for predicting growth of indian telecom companies. In: **2018 4th International Conference on Computing Sciences (ICCS)**. [S.l.: s.n.], 2018. p. 166–174.

RARE-TECHNOLOGIES. **gensim**. [S.l.]: GitHub, 2011. <<https://github.com/RaRe-Tech/gensim>>.

RITCHIE EDOUARD MATHIEU, L. R.-G. C. A. C. G. E. O.-O. J. H. B. M. D. B. H.; ROSER, M. Coronavirus pandemic (covid-19). **Our World in Data**, 2020. <https://ourworldindata.org/coronavirus>.

SALVADOR, S.; CHAN, P. Toward accurate dynamic time warping in linear time and space. In: . [S.l.: s.n.], 2004. v. 11, p. 70–80.

SCIPY. **scipy**. [S.l.]: GitHub, 2006. <<https://github.com/scipy/scipy>>.

SHELAR, A.; HUANG, C.-Y. Sentiment analysis of twitter data. In: **2018 International Conference on Computational Science and Computational Intelligence (CSCI)**. [S.l.: s.n.], 2018. p. 1301–1302.

SHMARGAD, Y. Twitter influencers in the 2016us congressional races. **Journal of Political Marketing**, Routledge, v. 0, n. 0, p. 1–18, 2018. Available from Internet: <<https://doi.org/10.1080/15377857.2018.1513385>>.

SUTHAHARAN, S. Support vector machine. In: _____. **Machine Learning Models and Algorithms for Big Data Classification: Thinking with Examples for Effective Learning**. Boston, MA: Springer US, 2016. p. 207–235. ISBN 978-1-4899-7641-3. Available from Internet: <https://doi.org/10.1007/978-1-4899-7641-3_9>.

SUTTON, R. S.; BARTO, A. G. **Reinforcement Learning: An Introduction**. Cambridge, MA, USA: A Bradford Book, 2018. ISBN 0262039249.

TEAM tslearn. **tslearn**. [S.l.]: GitHub, 2017. <<https://github.com/tslearn-team/tslearn>>.

TWINTPROJECT. **Twint**. [S.l.]: GitHub, 2018. <<https://github.com/twintproject/twint>>.

Uol Notícias. **Em motociata, Bolsonaro volta a atacar Barroso: 'Não devia estar no STF'**. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://noticias.uol.com.br/politica/ultimas-noticias/2021/07/10/motociata---porto-alegre---bolsonaro.htm>>.

VIJAY, T. et al. Sentiment analysis on covid-19 twitter data. In: **2020 5th IEEE International Conference on Recent Advances and Innovations in Engineering (ICRAIE)**. [S.l.: s.n.], 2020. p. 1–7.

XP/INESPE. **Pesquisa XP/Ipespe: 29 a 31 de março de 2021** Acessado em: 2021-11-13. Available from Internet: <https://conteudos.xpi.com.br/wp-content/uploads/2021/04/Pesquisa-XP_-2021_04.pdf>.

YAQUB, U. Tweeting during the covid-19 pandemic: Sentiment analysis of twitter messages by president trump. **Digit. Gov.: Res. Pract.**, Association for Computing Machinery, New York, NY, USA, v. 2, n. 1, nov. 2020. ISSN 2691-199X. Available from Internet: <<https://doi.org/10.1145/3428090>>.

YUE, L. et al. A survey of sentiment analysis in social media. **Knowl. Inf. Syst.**, Springer-Verlag, Berlin, Heidelberg, v. 60, n. 2, p. 617–663, aug. 2019. ISSN 0219-1377. Available from Internet: <<https://doi.org/10.1007/s10115-018-1236-4>>.

Zero Hora. **Saúde em Colapso**. Acessado em: 2021-11-15. 2021. Available from Internet: <<https://www.vercapas.com.br/edicao/capa/zero-hora/2021-03-03/>>.