



UNIVERSIDADE FEDERAL DO ESTADO DO RIO DE JANEIRO
CENTRO DE CIÊNCIAS EXATAS E TECNOLOGIA
PROGRAMA DE PÓS-GRADUAÇÃO EM INFORMÁTICA

O IMPACTO DOS CASOS DE COVID-19 E A MUDANÇA DE PERCEPÇÃO DOS
USUÁRIOS DO TWITTER SOBRE O GOVERNO BRASILEIRO

Celso de Oliveira Pacheco Junior

Orientador

Prof. Dr. Sean Wolfgang Matsui Siqueira

RIO DE JANEIRO, RJ - BRASIL
FEVEREIRO, 2023

O IMPACTO DOS CASOS DE COVID-19 E A MUDANÇA DE PERCEPÇÃO DOS
USUÁRIOS DO TWITTER SOBRE O GOVERNO BRASILEIRO

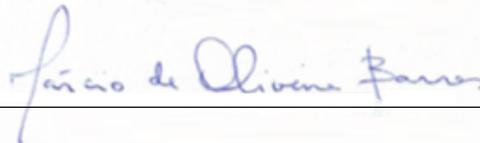
Celso de Oliveira Pacheco Junior

DISSERTAÇÃO APRESENTADA COMO REQUISITO PARCIAL PARA OBTENÇÃO
DO TÍTULO DE MESTRE PELO PROGRAMA DE PÓS-GRADUAÇÃO EM INFOR-
MÁTICA DA UNIVERSIDADE FEDERAL DO ESTADO DO RIO DE JANEIRO (UNI-
RIO). APROVADA PELA COMISSÃO EXAMINADORA ABAIXO ASSINADA.

Aprovada por:



Prof. Dr. Sean Wolfgang Matsui Siqueira (orientador) — UNIRIO



Prof. Dr. Márcio de Oliveira Barros — UNIRIO



Prof^ª. Dr^ª. Juliana Baptista dos Santos França — UFRJ

RIO DE JANEIRO, RJ - BRASIL

FEVEREIRO, 2023.

Pacheco Junior, Celso de Oliveira
d95 O IMPACTO DOS CASOS DE COVID-19 E A MUDANÇA DE
PERCEPÇÃO DOS USUÁRIOS DO TWITTER SOBRE O GOVERNO
BRASILEIRO / Celso de Oliveira Pacheco Junior – Rio de Janeiro, 2023.
128 f.

Orientador: Sean Wolfgang Matsui Siqueira.
Dissertação (Mestrado) - Universidade Federal do
Estado do Rio de Janeiro, Programa de Pós-Graduação
em Informática, 2023.

1. Sistemas de Informação. 2. Covid-19. 3. pandemia. 4. governo.
5. Twitter. I. Wolfgang Matsui Siqueira, Sean, orient. II. Título.

Dedico este trabalho à Deus, a minha família, aos meus pais e aos amigos fraternos.

*“Viva como se fosse morrer amanhã.
Aprenda como se fosse viver pra sempre.”
(Mahatma Gandhi)*

Agradecimentos

Agradeço, primeiramente, a Deus por me dar forças para cumprir meus objetivos e realizar meus sonhos;

A todos os professores pelos ensinamentos durante o curso. Em especial ao meu professor orientador, Sean, pelo incentivo constante, tempo dedicado em nossos encontros e principalmente por acreditar no meu potencial.

Ao amigo doutorando e parceiro de estudos Marcelo Soares Loutfi, aos meus colegas de curso e a todos aqueles que de certa forma contribuíram para a elaboração deste trabalho.

Agradeço a minha família, amigos, minha querida esposa Ramona Halley e meu amado filho Miguel, que de certa forma foram privados de minha companhia durante esta jornada.

Finalmente, agradeço aos membros da infraestrutura administrativa e acadêmica do PPGI, da secretaria às coordenações diversas, agradeço a seriedade e retidão no pronto atendimento de todas as necessidades colocadas.

PACHECO JUNIOR, Celso de Oliveira. **O Impacto dos Casos da Covid-19 e a Mudança de Percepção dos Usuários do Twitter Sobre o Governo Brasileiro.** UNIRIO, 2023. 128 páginas. Dissertação de Mestrado. Departamento de Informática Aplicada, UNIRIO.

RESUMO

Nos anos 2020 e 2021 o Brasil vivenciou uma das maiores crises sanitárias de sua história causada pela pandemia da Covid-19, resultando em milhares de óbitos. Nesse período, o governo federal defendeu tratamentos contestados pelas autoridades em saúde para o controle da doença. A grande comoção social provocada pelo número crescente de infectados e óbitos contribuíram para que se deflagraissem debates nas Redes Sociais envolvendo ao menos dois temas: i) A atuação do governo no combate à pandemia e; ii) Os relatos dos dramas vividos pelas pessoas impactadas pela pandemia. O Twitter foi um dos palcos onde esse cenário político-social se refletiu. Neste contexto, uma análise de sentimentos sobre esses tweets nos permitiria entender se os dramas familiares vividos provocados pela Covid-19 alteraram a percepção dessas pessoas em relação ao governo. No presente estudo, objetivamos desenhar e executar um processo capaz de verificar mudanças nas percepções das pessoas em relação ao governo Jair Bolsonaro, com base em seus tweets contendo relatos sobre dramas familiares causados pela Covid-19. Realizamos dois experimentos baseados na abordagem metodológica quantitativa. Em cada experimento, coletamos tweets publicados que continham relatos de dramas familiares causados pela Covid-19. Utilizamos estes tweets como um marcador temporal individualizado para cada um dos usuários identificados, então coletamos outros tweets, sobre o governo Jair Bolsonaro, publicados por estes mesmos usuários, antes e depois de terem relatado sobre seus dramas familiares causados pela Covid-19. Buscamos identificar se houve mudança na percepção destas pessoas em relação ao governo Jair Bolsonaro utilizando um conjunto de métricas como: percentual das intensidades dos sentimentos, contagem de tweets e frequência de palavras, que nos permitiram comparar os sentimentos das pessoas antes e após elas terem publicado seus dramas familiares causados pela Covid-19. Utilizamos os analisadores léxicos VADER, Textblob e Polyglot para extrair os

sentimentos dos tweets. Analisamos 447 usuários em nosso primeiro experimento, entre março e junho/2021 (72 dias) e 4.918 usuários, entre janeiro e dezembro/2021 (365 dias) no segundo experimento. Descobrimos que o sentimento geral das pessoas em relação ao governo Jair Bolsonaro não variou de maneira significativa. Consequentemente, existe a possibilidade de uma parte dos usuários analisados por esta pesquisa, não associarem seus dramas familiares vividos à forma como governo Jair Bolsonaro conduziu a pandemia. Não sendo portanto, para estas pessoas, um drama familiar causado pela Covid-19 um fator de mudança de opinião sobre o governo.

Palavras-chave: Covid-19, pandemia, governo, Brasil, brasileiro, Bolsonaro, análise de sentimentos, Twitter, percepção dos usuários.

ABSTRACT

In the 2020s and 2021s, Brazil experienced one of the biggest health crises in its history caused by the Covid-19 pandemic, resulting in thousands of deaths. During this period, the federal government defended treatments contested by health authorities to control the disease. The great social commotion caused by the growing number of infected people and deaths contributed to the outbreak of debates on Social Media involving at least two topics: i) The government's role in combating the pandemic and; ii) Reports of the dramas experienced by people impacted by the pandemic. Twitter was one of the stages where this social-political scenario was reflected. In this context, an analysis of sentiments on these tweets would allow us to understand whether the family dramas caused by Covid-19 altered these people's perception of the government. In the present study, we aimed to design and execute a process capable of verifying changes in people's perceptions of the Jair Bolsonaro government, based on their tweets containing reports about family dramas caused by Covid-19. We performed two experiments based on the quantitative methodological approach. In each experiment, we collected published tweets that contained reports of family dramas caused by Covid-19. We used these tweets as an individualized time marker for each of the identified users, then we collected other tweets, about the Jair Bolsonaro government, published by these same users, before and after they had reported on their family dramas caused by Covid-19. We sought to identify whether there was a change in these people's perception of the Jair Bolsonaro government using a set of metrics such as: percentage of sentiment intensities, tweet count and word frequency, which allowed us to compare people's feelings before and after they published their family dra-

mas caused by Covid-19. We used the VADER, Textblob and Polyglot lexical analyzers to extract the sentiments of the tweets. We analyzed 447 users in our first experiment, between March and June/2021 (72 days) and 4,918 users, between January and December/2021 (365 days) in the second experiment. We found that people's general sentiment towards the Jair Bolsonaro government did not vary significantly. Consequently, there is a possibility that some of the users analyzed by this research do not associate their family dramas with the way in which the Jair Bolsonaro government handled the pandemic. Therefore, for these people, a family drama caused by Covid-19 is not a factor in changing their opinion about the government.

Keywords: Covid-19, pandemic, government, Brazil, brazilian, Bolsonaro, sentiment analysis, Twitter, users' perception.

Sumário

1	Introdução	1
1.1	Contextualização	1
1.2	Motivação	3
1.3	Problema	4
1.4	Questões de pesquisa	4
1.5	Hipótese	5
1.6	Objetivos	6
1.7	Organização da pesquisa	6
2	Fundamentação e Trabalhos Relacionados	7
2.1	Análise de conteúdo em redes sociais	7
2.2	Emoções e sentimentos	9
2.3	Análise de sentimentos	9
2.4	Trabalhos relacionados	10
2.5	Conclusão da fundamentação	13
3	Abordagem Epistemológica-Metodológica de Pesquisa	14
3.1	Epistemologia positivista	14
3.2	Metodologia	14

3.3	Considerações finais sobre a abordagem metodológica	18
4	Experimento 1	19
4.1	Coleta de dados	19
4.2	Processamento de dados	22
4.2.1	Tradução para língua inglesa	22
4.2.2	Classificação automática de sentimentos	23
4.2.3	Classificação manual de sentimentos	23
4.3	Análises	26
4.3.1	Intensidades dos sentimentos	26
4.3.2	Quantidade de tweets e intensidade dos sentimentos por usuário .	28
4.3.3	Nuvens de palavras	30
4.3.4	Avaliação manual	31
4.4	Considerações finais sobre o Experimento 1	32
5	Experimento 2	34
5.1	Coleta de dados	35
5.2	Processamento de dados	38
5.2.1	Tradução para língua inglesa	39
5.2.2	Classificação automática de sentimentos	39
5.2.3	Classificação manual de sentimentos	40
5.3	Análises	42
5.3.1	Intensidades dos sentimentos	42
5.3.2	Quantidade de tweets e intensidade dos sentimentos por usuário .	46
5.3.3	Nuvens de palavras	51
5.3.4	Polaridade média dos sentimentos no período	57

5.3.5	Análise da subjetividade média no período	60
5.3.6	Relação dos sentimentos e número de casos e mortes provocados pela Covid-19	64
5.3.7	Análise das emoções	67
5.3.8	Análise das emoções presentes entre os sentimentos negativos, positivos e neutros	69
5.3.9	Intensidade dos sentimentos entre os diferentes graus de gravidade relatados	72
5.3.10	Intensidade dos sentimentos entre os diferentes graus de parentesco	75
5.3.11	Avaliação manual	78
5.4	Considerações finais sobre o Experimento 2	79
6	Discussão	80
6.1	Sobre a intensidade dos sentimentos	81
6.2	Sobre as nuvens de palavras	83
6.3	Sobre a polaridade média dos sentimentos no período	85
6.4	Sobre a subjetividade média no período	89
6.5	Sobre a relação dos sentimentos e número de casos e mortes provocados pela Covid-19	92
6.6	Sobre as intensidades das emoções	95
6.7	Sobre as emoções presentes entre os sentimentos negativos e positivos	96
6.8	Sobre a intensidade dos sentimentos entre os diferentes graus de gravidade relatados	97
6.9	Sobre a intensidade dos sentimentos entre os diferentes graus de parentesco	98
6.10	Sobre as avaliações manuais	99
7	Conclusão	108

7.1	Limitações do estudo	109
7.2	Trabalhos futuros	110
	Referências Bibliográficas	112
A	Apêndices	118
A.1	Experimento 1 - Número de tweets avaliados	118
A.2	Experimento 1 - Resultados dos testes de Wilcoxon e Vargha & Delaney's realizado na análise de Intensidades dos Sentimentos	118
A.3	Experimento 2 - Resultados dos testes de Wilcoxon e Vargha & Delaney's	119
A.4	Experimento 2 - Resultados dos testes de Wilcoxon e Vargha & Delaney's realizado na análise de intensidade dos sentimentos entre os diferentes graus de gravidade relatados	121
A.5	Experimento 2 - Resultados dos testes de Wilcoxon e Vargha & Delaney's realizado na análise de intensidade dos sentimentos entre os diferentes graus de parentesco	122
A.6	Experimento 2 - E-mail convite enviado aos participantes da pesquisa para classificação manual dos tweets	124
A.7	Experimento 2 - TCLE disponibilizado aos participantes da pesquisa para classificação manual dos tweets	125
A.8	Experimento 2 - Número de tweets avaliados	126
A.9	Experimento 2 - Cálculo para extrair a quantidade de subjetividade presente nas mensagens	126
A.10	Experimento 2 - Cálculo para extrair as emoções presentes nas mensagens	127
A.11	Experimentos 1 e 2 - Datasets e códigos-fontes	128

Lista de Figuras

1.1	Tweet publicado pelo presidente com mensagem de resistência ao isolamento social.	2
1.2	Tweet publicado pelo presidente com mensagem de resistência ao isolamento social.	2
1.3	Tweet publicado pela OMS orientando sobre as medidas de isolamento social.	3
1.4	Tweet publicado pela OMS orientando sobre as medidas de isolamento social.	3
2.1	Arquitetura geral de um sistema de análise de sentimento genérico.	10
3.1	Processo de coleta e análise de tweets	15
3.2	Escala com os intervalos utilizados para categorização dos sentimentos a partir da polaridade calculada para cada tweet.	17
3.3	Tweets base e os grupos pré e pós tweet base de cada usuário	18
4.1	Período de coleta dos tweets base e o período de coleta dos tweets dos grupos pré e pós tweet base	21
4.2	Etapa de processamento dos dados.	22
4.3	Método utilizado para categorização dos sentimentos a partir da polaridade calculada.	23
4.4	Artefato desenvolvido para classificação manual dos tweets.	25

4.5	Intensidade dos sentimentos antes e após o tweet base	28
4.6	Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base	29
4.7	Palavras negativas, neutras e positivas, antes e depois do tweet base (VA- DER)	31
5.1	Período de coleta dos dados analisados no experimento 2	38
5.2	Etapa de processamento dos dados	38
5.3	Artefato utilizado pelo Experimento 2 para classificação manual dos tweets.	41
5.4	Intensidade dos sentimentos antes e depois do tweet base (VADER)	44
5.5	Intensidade dos sentimentos antes e depois do tweet base (Textblob)	44
5.6	Intensidade dos sentimentos antes e depois do tweet base (Polyglot - texto em inglês)	45
5.7	Intensidade dos sentimentos antes e depois do tweet base (Polyglot - texto em português)	45
5.8	Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base (VADER)	48
5.9	Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base (Textblob)	49
5.10	Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base (Polyglot - texto em inglês)	50
5.11	Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base (Polyglot - texto em português)	51
5.12	Palavras negativas, neutras e positivas, antes e depois do tweet base (VA- DER)	54
5.13	Palavras negativas, neutras e positivas, antes e depois do tweet base (Text- blob)	55
5.14	Palavras negativas, neutras e positivas, antes e depois do tweet base (Poly- glot - texto em inglês)	56

5.15	Palavras negativas, neutras e positivas, antes e depois do tweet base (Polyglot - texto em português)	57
5.16	Polaridade média dos sentimentos no período (VADER)	58
5.17	Polaridade média dos sentimentos no período (Textblob)	59
5.18	Polaridade média dos sentimentos no período (Polyglot - texto em inglês)	59
5.19	Polaridade média dos sentimentos no período (Polyglot - texto em português)	60
5.20	Subjetividade média no período	61
5.21	Método utilizado para categorização da subjetividade calculada.	62
5.22	Intensidade dos sentimentos dos tweets classificados com subjetividade forte antes e depois do tweet base (VADER)	62
5.23	Intensidade dos sentimentos dos tweets classificados com subjetividade forte antes e depois do tweet base (Textblob)	63
5.24	Intensidade dos sentimentos dos tweets classificados com subjetividade forte antes e depois do tweet base (Polyglot - texto em inglês)	63
5.25	Intensidade dos sentimentos dos tweets classificados com subjetividade forte antes e depois do tweet base (Polyglot - texto em português)	64
5.26	Polaridade média dos sentimentos (VADER) e números de novos casos de Covid-19 por mês	66
5.27	Polaridade média dos sentimentos (VADER) e números de óbitos causados pela Covid-19 por mês	66
5.28	Exemplo de chamada à função get_nrc_sentiment do pacote Syuzhet	68
5.29	Emoções presentes nos grupos antes e depois do tweet base	69
5.30	Emoções presentes nos grupos antes e depois do tweet base (Syuzhet Inglês - VADER)	70
5.31	Emoções presentes nos grupos antes e depois do tweet base (Syuzhet Português - Polyglot)	71

5.32	Exemplo de tweet base contendo palavras comuns ao conjunto de palavras de diferentes graus de gravidade.	73
5.33	Intensidade dos sentimentos dos tweets x grau de gravidade baixo	74
5.34	Intensidade dos sentimentos dos tweets x grau de gravidade médio	74
5.35	Intensidade dos sentimentos dos tweets x grau de gravidade alto	75
5.36	Exemplo de tweet base contendo relato sobre diferentes entes familiares. .	77
5.37	Intensidade dos sentimentos dos tweets x avô ou avó	77
5.38	Intensidade dos sentimentos dos tweets x pai ou mãe	78
5.39	Intensidade dos sentimentos dos tweets x filho ou filha	78
6.1	Momentos em que ocorreram mudanças de tendências no gráfico de polaridade média dos sentimentos no período (VADER)	86
6.2	Polaridade média dos sentimentos (VADER) e números de novos casos de Covid-19 por mês	94
6.3	Polaridade média dos sentimentos (VADER) e números de óbitos causados pela Covid-19 por mês	94
6.4	Correspondência entre as classificações automáticas e manuais	105
6.5	Correspondência entre as classificações dos sentimentos realizadas por cada uma das ferramentas e também entre as classificações manuais. . . .	106
A.1	E-mail convite enviado aos participantes	124
A.2	TCLE disponibilizado aos participantes da pesquisa para classificação manual dos tweets	125
A.3	Exemplo do cálculo de subjetividade presente no texto	126
A.4	Exemplo do processamento do cálculo da emoção presente em uma sentença na língua inglesa	127
A.5	Exemplo do processamento do cálculo da emoção presente em uma sentença em português	128

Lista de Tabelas

2.1	Comparação entre estudos sobre análise de sentimentos dos usuários do Twitter no contexto da pandemia da Covid-19	12
4.1	Descrição dos grupos finais de tweets antes e depois dos tweets base	21
4.2	Quantidades de tweets avaliados em cada grupo	24
4.3	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets negativos	26
4.4	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets neutros	27
4.5	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets positivos	27
4.6	Quantidade de tweets classificados manualmente	32
5.1	Termos de busca com grau de parentesco além da família biológica e tweets retornados	36
5.2	Descrição dos grupos finais de tweets antes e depois dos tweets base	37
5.3	Percentuais das intensidades dos sentimentos calculados.	46
5.4	Classificação dos tweets dos grupos antes e depois do tweet base de acordo com a subjetividade.	61
5.5	Percentuais das intensidades dos sentimentos calculados a partir dos tweets classificados com subjetividade forte.	64

5.6	Polaridade dos sentimentos calculados e números de novos casos e novos óbitos provocados pela pandemia da Covid-19.	67
5.7	Média das emoções calculadas	69
5.8	Média das emoções calculadas para cada sentimento	71
5.9	Percentuais das intensidades dos sentimentos calculados para cada grau de gravidade.	73
5.10	Percentuais das intensidades dos sentimentos calculados para cada grau de gravidade.	77
5.11	Quantidade de tweets classificados manualmente	79
6.1	Exemplos de tweets categorizados de acordo com a subjetividade calculada.	91
6.2	Quantidade de tweets para cada um dos termos de difícil compreensão considerados na amostra para classificação se sentimentos manual	100
6.3	Exemplos de tweets cujos sentimentos calculados de forma automática não corresponderam com a avaliação manual	101
6.4	Quantidade de tweets em que houve correspondência entre as classificações automáticas e manual realizada em nosso segundo experimento. . . .	104
A.1	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets	118
A.2	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER)	119
A.3	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (Textblob)	119
A.4	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (Polyglot - EN)	120
A.5	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (Polyglot - PT)	120

A.6	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Grau de gravidade: baixo)	121
A.7	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Grau de gravidade: Médio)	121
A.8	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Grau de gravidade: Alto)	122
A.9	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Parentesco: Avô / Avó)	122
A.10	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Parentesco: Pai / Mãe)	123
A.11	Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Parentesco: Filho / Filha)	123
A.12	Experimento 2 - Número de tweets avaliados categorizados de acordo com o sentimento calculado.	126

Lista de Nomenclaturas

AC	Análise de conteúdo
API	<i>Application Programming Interface</i>
COVID	<i>Coronavirus disease</i>
CPI	Comissão Parlamentar de Inquérito
NLTK	<i>Natural Language Toolkit</i>
NRC	<i>National Research Council Canada</i>
OMS	Organização Mundial de Saúde
PLN	Processamento de Linguagem Natural
SML	<i>Supervised Machine Learning</i>
VADER	<i>Valence Aware Dictionary and sEntiment Reasoner</i>

1. Introdução

1.1 Contextualização

A mídia social teve um grande impacto no discurso público e na comunicação da sociedade na última década. Nesse cenário, o Twitter¹ despontou como uma das plataformas mais dominantes na área do discurso político (BOULIANNE; LARSSON, 2021) (ELBAGIR; YANG, 2019) (YAQUB, 2020) (KAUR; VERMA; OTOO, 2021). Embora o limite de 280 caracteres pareça restritivo, as postagens no Twitter revelam um enorme alcance e influência no cenário político em todo o mundo (DUBEY, 2020) (ALLCOTT; GENTZKOW, 2017). Uma característica importante do Twitter é sua natureza em tempo real que permite que seus dados sejam capturados para prever resultados eleitorais (ENDSUY, 2021) (HITESH et al., 2019), identificar laços políticos nas mídias sociais (HETTIA-CHCHI; ARORA; GONCALVES, 2021) (SHUGARS; BEAUCHAMP, 2019) e identificar padrões de comunicação, além de interações relacionadas a eventos políticos (FERNANDO et al., 2020) (YUAN; SCHUCHARD; CROOKS, 2019). Além disso, o Twitter também têm sido um meio para as pessoas manterem contato durante o distanciamento social necessário para atenuação do contágio do novo coronavírus.

Diante da declaração da pandemia, algumas estratégias para prevenir a transmissão comunitária do coronavírus foram adotadas por diversos países (ALSHAMMARI; AL-TEBAINAWI; ALENZI, 2020), exigindo medidas drásticas por parte das autoridades. O isolamento social foi comprovadamente a forma mais eficiente de combate à disseminação da Covid-19 (CROKIDAKIS, 2020). O confinamento exigiu adaptação no cotidiano das pessoas em diversos campos como trabalho, estudo e entretenimento (CLASSE et al., 2021) (LOUTFI et al., 2021). Entretanto, enquanto estudos científicos evidenciavam e autoridades de saúde orientavam sobre a eficácia das medidas de isolamento social para conter as contaminações, uma grande quantidade de informações falsas ou enganosas cir-

¹<<https://twitter.com/>>

cularam nas redes (KISSLER et al., 2020) (VOSOUGHI; ROY; ARAL, 2018). Em 15 de fevereiro de 2020, o diretor-geral da OMS, Tedros Adhanom Ghebreyesus, alertou o mundo sobre a ameaça de uma infodemia, uma superabundância de informações, particularmente a disseminação de informações erradas e desinformadas, que acompanhava a pandemia ². Notadamente, no Brasil, o governo Bolsonaro participava desta epidemia de desinformação, negando a ciência e divulgando informações que contradiziam as orientações divulgadas pelos órgãos e autoridades de saúde como o desencorajamento da população ao isolamento social (Figuras: 1.1, 1.2, 1.3 e 1.4) e o tratamento com o uso de hidroxicloroquina, que já havia sido revelado como ineficaz para o tratamento da Covid-19 (FILHO et al., 2020).

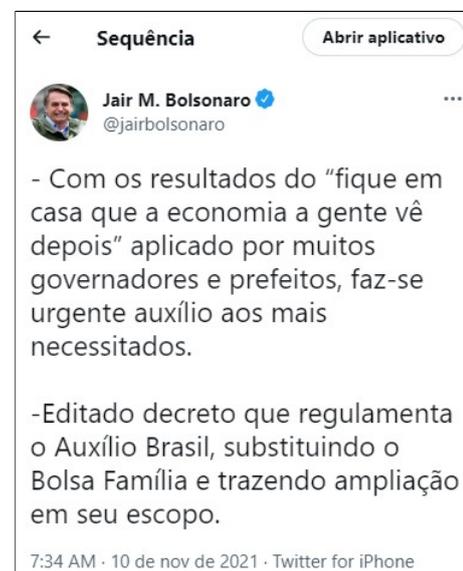
Os antagonismos colocados pelas políticas contra e a favor do isolamento social, dos que apoiavam e dos que eram contra tratamento precoce e assim por diante, aliado à grande comoção social provocada pelo número crescente de infectados e óbitos contribuíram para que se deflagrassem debates nas Redes Sociais envolvendo ao menos dois temas: i) A atuação do governo no combate à pandemia e; ii) Os relatos dos dramas vividos pelas pessoas impactadas pela pandemia.

Figura 1.1: Tweet publicado pelo presidente com mensagem de resistência ao isolamento social.



Fonte: Twitter (2022)

Figura 1.2: Tweet publicado pelo presidente com mensagem de resistência ao isolamento social.



Fonte: Twitter (2022)

²<<https://www.who.int/director-general/speeches/detail/munich-security-conference>>

Figura 1.3: Tweet publicado pela OMS orientando sobre as medidas de isolamento social.



Fonte: Twitter (2022)

Figura 1.4: Tweet publicado pela OMS orientando sobre as medidas de isolamento social.



Fonte: Twitter (2022)

1.2 Motivação

Este estudo é motivado pela necessidade em analisar e compreender como os dramas pessoais direcionam as percepções das pessoas em relação às autoridades. Para isso, partimos de eventos localizados temporalmente, relativo ao indivíduo analisado, que denotem dramas pessoais relacionados à pandemia da Covid-19. Tal abordagem se justifica por compreendermos que a pandemia foi um evento catastrófico que afetou milhares de famílias de diversas formas, mas não exatamente da mesma forma e nem no mesmo momento.

Portanto, por mais que trate-se de um único evento, este estudo entende que a pandemia produziu eventos individualizados e localizados temporalmente, materializados em relatos de dramas pessoais, que devem ser tratados, compreendidos e analisados como únicos.

Acreditamos, portanto, ser possível compreender como cada evento localizado temporalmente impacta na percepção individual em relação ao governo federal. Desta forma,

ao invés de partir de uma análise generalista, acreditamos que uma análise que individualize cada drama respeitando seu contexto oferece uma compreensão mais acurada sobre o problema.

O Twitter, por se tratar de um grande palco para o debate público e político, é a plataforma ideal para a extração dos relatos de dramas pessoais sobre a pandemia e também opiniões sobre o governo Jair Bolsonaro.

1.3 Problema

O governo Jair Bolsonaro, durante a pandemia da Covid-19, resistiu a argumentos científicos, indo contra às medidas de combate à pandemia (RICARD; MEDEIROS, 2020) (MONARI et al., 2021) (LEMOS, 2021) (COLETTA; SALDAÑA, 2020). O Twitter foi um dos palcos onde os debates em torno desse tema se estabeleceram, além disso, o Twitter serviu para as pessoas se expressarem sobre dramas familiares vividos causados pela Covid-19. O problema de pesquisa deste estudo concentra-se em identificar uma possível relação entre os dramas pessoais expressados e alguma eventual alteração das percepções destas pessoas sobre o governo.

1.4 Questões de pesquisa

Para subsidiar nossa análise partimos da seguinte questão de pesquisa: **as percepções das pessoas em relação ao governo Jair Bolsonaro mudam após elas relatarem, nas redes sociais, um familiar acometido pela Covid-19?**

Com objetivo de explorar nossa questão de pesquisa, definimos subquestões de pesquisa, que foram divididas em dois grupos: subquestões gerais e específicas do Experimento 2. Para responder as subquestões de pesquisa, foram realizados dois experimentos. As subquestões gerais (SRQ1 e SRQ2) são respondidas no experimento 1 e reforçadas no experimento 2, enquanto que as demais questões são respondidas especificamente no experimento 2.

- Gerais (Experimentos 1 e 2):
 - **SRQ1** — Em que medida os sentimentos negativos, positivos e neutros estão presentes nos grupos de tweets sobre o governo Bolsonaro antes e após os relatos sobre um familiar acometido pela Covid-19?

- **SRQ2** — Há diferença entre as palavras positivas, negativas e neutras mais frequentemente utilizadas entre os grupos de tweets antes e após um familiar ter sido afetado pela Covid-19?
- Específicas do experimento 2:
 - **SRQ3** — Existe uma tendência dos sentimentos positivos e negativos ao longo do tempo entre os grupos de tweets antes e após um familiar afetado pela Covid-19?
 - **SRQ4** — O quanto há de subjetividade (opinião) nas mensagens?
 - **SRQ5** — Em que medida os sentimentos estão relacionados ao número de casos e mortes provocados pela Covid-19?
 - **SRQ6** — Além dos sentimentos positivos, negativos e neutros, em que medida emoções como raiva, expectativa, nojo, medo, alegria, tristeza, surpresa, confiança estão presentes nos grupos de tweets postados antes e após os relatos sobre um familiar afetado pela Covid-19?
 - **SRQ7** — Em que medida as mensagens positivas são ligadas a alegria, enquanto as negativas estão mais ligadas a raiva, medo ou tristeza?
 - **SRQ8** — Existe uma mudança nos sentimentos entre os diferentes graus de gravidade dos relatados?
 - **SRQ9** — Existe uma mudança nos sentimentos entre diferentes graus de parentesco?

1.5 Hipótese

Nossa hipótese é que, por meio das redes sociais, é possível identificar mudanças nas percepções das pessoas em relação a governos quando confrontados com temas de forte apelo emocional. No Twitter, por exemplo, muitas pessoas emitiram opiniões relacionadas ao governo Jair Bolsonaro antes e após postarem relatos de pessoas próximas afetadas pela Covid-19. Uma análise de sentimentos sobre esses tweets nos permitiria entender se os dramas familiares provocados pela Covid-19 alteraram a percepção dessas pessoas em relação ao governo.

1.6 Objetivos

No presente estudo, objetivamos desenhar e executar um processo capaz de identificar mudanças na percepção das pessoas em relação ao governo Jair Bolsonaro durante a pandemia de Covid-19, com base nos tweets e no fato de essas pessoas terem um familiar afetado pela Covid-19.

Para avaliar possíveis mudanças de percepção das pessoas em relação ao governo Bolsonaro, realizamos análises sobre tweets publicados contendo relatos de dramas familiares vividos por estas pessoas. A partir destes tweets, analisamos outros tweets destes mesmos usuários, antes e após o fato publicado por cada um deles, e então buscamos identificar se há mudança na percepção destas pessoas em relação ao governo Jair Bolsonaro.

1.7 Organização da pesquisa

Esta dissertação está organizada em sete Capítulos, incluindo este capítulo de introdução. No Capítulo 2, são apresentados a fundamentação teórica sobre os tópicos referentes ao estudo em questão e os trabalhos relacionados ao tema. O Capítulo 3 apresenta a abordagem metodológica da presente pesquisa, onde descrevemos um processo de coleta e análise de tweets. No capítulo 4 apresentamos detalhes sobre as etapas de Coleta e Processamento de Dados realizadas, apresentamos também as análises desenvolvidas para alcançar os objetivos do Experimento 1. No capítulo 5, apresentamos detalhes sobre as etapas de Coleta e Processamento de Dados realizadas durante o Experimento 2 e as análises desenvolvidas para alcançar os objetivos do Experimento 2. No Capítulo 6 discutimos os principais achados frente às questões de pesquisa. Finalmente, no Capítulo 7 apresentamos as principais contribuições, limitações de nossa pesquisa, bem como as sugestões para trabalhos futuros.

2. Fundamentação e Trabalhos Relacionados

Este capítulo está dividido em 5 seções. A primeira seção 2.1 apresenta conceitos relacionados a análise de conteúdo em redes sociais. A seção 2.2 traz os conceitos de emoções e sentimentos. Na Seção 2.3 apresentamos conceitos de análise de sentimentos e ferramentas utilizadas nesta pesquisa. A seção 2.4 apresenta alguns trabalhos relacionados ao tema desta pesquisa disponíveis na literatura. Por último, a seção 2.5 traz as considerações finais deste capítulo.

2.1 Análise de conteúdo em redes sociais

De acordo com Krippendorff (2018), a Análise de Conteúdo (AC) é uma técnica de pesquisa para fazer inferências replicáveis e válidas a partir de dados em um determinado contexto. Ainda segundo Krippendorff (2018), como técnica de pesquisa, a AC fornece novos *insights*, aumenta a compreensão do pesquisador sobre fenômenos específicos ou informa ações práticas.

Laurence (2011) define a AC como a relação entre métodos estatísticos e a observação de materiais, avaliando deduções específicas por meio da análise qualitativa e frequência de aparição pela análise quantitativa.

Para Riff, Lacy e Fico (2014), a análise quantitativa de conteúdo é a investigação sistemática e replicável de símbolos de comunicação, aos quais foram atribuídos valores numéricos de acordo com regras de medição válidas, e a análise das relações envolvendo esses valores usando métodos estatísticos, para descrever a comunicação, fazer inferências sobre seu significado ou inferir a comunicação sobre seu contexto. Normalmente, esse tipo de análise envolve selecionar amostras representativas de conteúdo, desenvolver codificadores para aplicar regras de categoria criadas para mensurar ou refletir diferenças de conteúdo e medir a confiabilidade dos codificadores usando as regras. As regras de

categorias definidas podem ser tão simples quanto atribuir 1 a um determinado conteúdo, por exemplo, histórias positivas, e 0 a histórias negativas. A análise dos dados coletados geralmente descreve padrões, características típicas ou infere relações importantes entre as amostras dos conteúdos examinados, aplicando procedimentos de complexidade variável que examinam e caracterizam as relações entre as variáveis. Os resultados podem ser relatados na forma de porcentagens ou médias simples.

A AC está presente em diversas disciplinas acadêmicas variadas como: sociologia, ciência política, economia, psicologia, nutrição, entre outras. Devido à possibilidade de a AC indicar o estado psicológico do comunicador, sua aplicação tem uma longa data na psicologia, por exemplo. Também tem sido usada na pesquisa de comunicação de massa para descrever o conteúdo e testar hipóteses derivadas da teoria. Como um método, pode ser usada para responder a perguntas de pesquisa sobre o conteúdo, podendo ser usada em conjunto com outras estratégias de pesquisa (RIFF; LACY; FICO, 2014).

A AC pode analisar diferentes formas de comunicação documentada, como jornais, televisão, filmes, redes sociais na internet e outras fontes. Apoiada pela computação, a AC parece se enquadrar em categorias como: contagem de palavras, palavra-chave no contexto e concordâncias, dicionários, estrutura da linguagem e legibilidade (RIFF; LACY; FICO, 2014).

As interações dos usuários nas redes sociais geram dados que permanecem disponíveis nas redes e que podem ser coletados e analisados. A AC destes dados permite classificá-los em categorizações significativas e, conseqüentemente, revelar informações importantes para diversos contextos, como apoiar entendimentos e ações sociais, políticas e culturais, conforme demonstram estudos recentemente publicados que exploram as interações no Twitter sobre a Covid-19 (KAUR; VERMA; OTOO, 2021)(RECUERO; SOARES, 2022)(FERNANDO et al., 2020).

Para esta pesquisa, consideramos a AC quantitativa a partir de mensagens de texto coletadas da rede social Twitter. Para isto, utilizamos as técnicas de contagem de palavras e dicionários. De acordo com Riff, Lacy e Fico (2014), a técnica de contagem de palavras identifica todas as palavras usadas em uma coleção de texto e quantas vezes cada uma é usada. A lista resultante pode ser ordenada pela frequência de aparecimento e informações podem ser inferidas a partir da comparação das listas. A técnica de dicionários classifica as palavras com base em agrupamentos de significados projetados e específicos para o objetivo da pesquisa. Estudos de análise de palavras em mensagens pessoais ou outros documentos podem usar dicionários criados a partir de processos psicológicos básicos para diferenciar os indivíduos em dimensões de personalidade, afeto e outros.

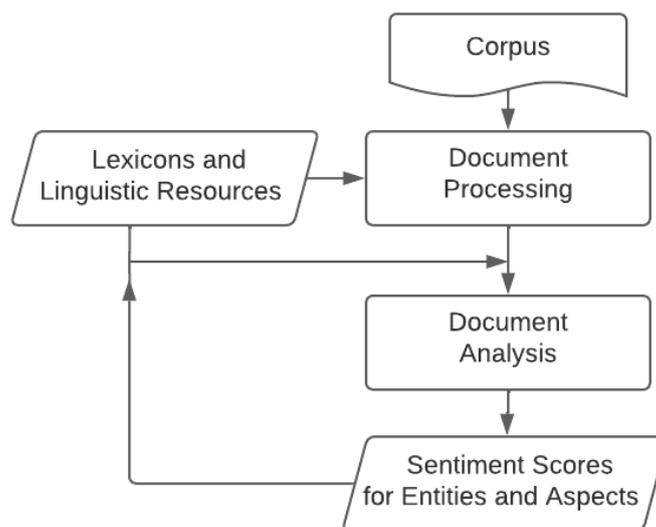
2.2 Emoções e sentimentos

De acordo com Liu (2012), as emoções têm sido estudadas em vários campos como psicologia, filosofia e sociologia. Os estudos são amplos, desde respostas emocionais de reações fisiológicas, expressões faciais, gestos e posturas a diferentes tipos de experiências subjetivas do estado de espírito de um indivíduo. As emoções foram agrupadas por cientistas em diferentes categorias. Segundo Plutchik (1980), existem oito emoções primárias: alegria, tristeza, raiva, medo, confiança, nojo, surpresa e expectativa. As emoções primárias podem ser conceituadas em termos de pares de opostos, por exemplo, raiva e medo são opostos no sentido de que um implica em ataque e o outro em fuga; alegria e tristeza são emoções opostas no sentido de que uma implica conquista ou ganho, enquanto a outra implica perda; confiança e nojo são opostos no sentido de que um implica em aceitação e a outra em rejeição; surpresa e expectativa são opostos no sentido de que uma implica o imprevisível e a outra o previsível. Ainda segundo Liu (2012), as emoções estão intimamente relacionadas com os sentimentos. A força de um sentimento ou opinião está tipicamente ligada à intensidade de certas emoções.

2.3 Análise de sentimentos

A Análise de sentimento e mineração de opinião são campos de estudo que analisam as opiniões, sentimentos, atitudes e emoções das pessoas a partir da linguagem escrita. (LIU, 2012). Há uma grande explosão de “sentimentos” disponíveis nas mídias sociais, incluindo Twitter, Facebook, blogs e fóruns de usuários (FELDMAN, 2013). De acordo com Liu (2012), a análise de sentimentos pode ocorrer em diferentes níveis de granularidade, por exemplo, documentos, sentenças e palavras. A análise de sentimentos mais básica é a análise no nível de palavras que classifica a palavra em polaridade positiva, negativa ou neutra. A análise no nível de sentença, além de verificar a polaridade de cada palavra, considera também o relacionamento entre as palavras e a sua função gramatical, sendo o resultado dessa análise o sentimento da sentença. A análise no nível de documento baseia-se no contexto do documento como um todo e calculando as polaridades de sentimento de frases ou palavras individuais e combinando-as para encontrar a polaridade do documento. Existem diferentes abordagens para análise de sentimento de um texto, por exemplo, a aplicação de um modelo de *machine learning* e abordagens baseadas em léxico (KHARDE; SONAWANE et al., 2016). Para esta pesquisa, adotamos a abordagem baseada em léxico.

Figura 2.1: Arquitetura geral de um sistema de análise de sentimento genérico.



Fonte: figura adaptada de Feldman (2013).

2.4 Trabalhos relacionados

A análise de sentimentos é uma abordagem que está no cerne da pesquisa de mídia social. Um conjunto de técnicas de Processamento de Linguagem Natural (PLN) pode ser usado para analisar as opiniões de uma pessoa (ALSAEEDI; KHAN, 2019), extrair sentimentos lexicais e classificá-los em positivos, negativos ou neutros (BAKSHI et al., 2016) (LIU, 2012) (KIM; HOVY, 2006).

Em 2020, a pandemia Covid-19 impactou a vida de pessoas em todo o mundo. Portanto, estudos estão em andamento para examinar os sentimentos sobre o novo coronavírus de muitas perspectivas e as conclusões são tiradas de uma ampla gama de ferramentas e técnicas disponíveis. Em (XUE et al., 2020), os autores utilizaram técnicas de aprendizado de máquina para compreender o discurso e as reações psicológicas dos usuários do Twitter em relação à Covid-19. Naseem et al. (2021) utilizaram ferramentas de Processamento de Linguagem Natural (PLN) para criar um novo conjunto de dados relacionados à Covid-19 composto por tweets na língua inglesa rotulados em classes de sentimentos positivos, negativos e neutros.

Dubey (2020) coletou tweets de quatro estados da Europa continental para analisar os sentimentos das pessoas durante a explosão do novo coronavírus. A coleta foi realizada por 20 dias em março de 2020 e o estudo descobriu que muitas pessoas em todo o mundo experimentaram sentimentos de medo, tristeza e nojo, embora a maioria das pessoas estivesse adotando uma abordagem positiva e esperançosa.

Medford et al. (2020) aplicaram técnicas de aprendizado de máquina não supervisionadas para analisar os dados coletados no coronavírus. O estudo visa quantificar e compreender os sentimentos dos usuários do Twitter sobre a pandemia Covid-19. Um total de 126.049 tweets foram avaliados e quase metade expressou medo.

Garcia e Berton (2021) classificaram dez tópicos relacionados à pandemia Covid-19 e analisaram o conteúdo discutido no Twitter por quatro meses. O estudo analisou a evolução da fala e do comportamento das pessoas ao longo do tempo no Brasil e nos Estados Unidos. Os temas identificados foram representativos da mídia durante os meses de abril e agosto de 2020 em ambos os países. O estudo analisou tendências de sentimento durante um longo período, relacionou-as às notícias relatadas e comparou o comportamento humano em duas localizações geográficas diferentes afetadas pela pandemia.

Zhunis et al. (2022), classificaram os estados emocionais de usuários do Twitter com objetivo de compreender em que medida o estado emocional de um indivíduo foi afetado pela pandemia, comparando os sentimentos destes usuários antes e depois da data de confirmação do primeiro caso de Covid-19 pela OMS¹. O estudo coletou mais de 9 milhões de tweets postados por 9.493 usuários. Os resultados indicaram que os usuários que expressaram emoções positivas no período pré-covid permaneceram positivos após o surto inicial, enquanto o oposto era verdadeiro para aqueles que expressavam emoções negativas regularmente.

Outros estudos usaram técnicas e ferramentas de análise de sentimento para compreender os sentimentos das pessoas em relação a um grupo político. Kaur, Verma e Otoo (2021) exploraram como as emoções são retratadas pelos líderes no Twitter, especialmente durante crises como a Covid-19. O estudo também aborda a necessidade de estabelecer laços de confiança com as autoridades para a divulgação gradual do conhecimento ao público. Um total de 12.128 tweets foram extraídos de 29 líderes políticos indianos durante 54 dias desde o dia da declaração de pandemia. Os resultados mostram emoções como raiva, antecipação, nojo, medo, alegria, tristeza, surpresa, confiança, sentimentos negativos e positivos, sendo o sentimento “Positivo” e a emoção “Confiança” foram os mais frequentes sempre que as autoridades emitiram ou comunicaram as novas orientações.

Ussama Yaqub (YAQUB, 2020) utiliza um modelo baseado em léxico para realizar uma análise de sentimentos dos tweets do presidente Donald Trump durante a fase inicial da disseminação da pandemia de Covid-19 nos Estados Unidos. O estudo apresenta uma correlação negativa estatisticamente significativa entre o sentimento das mensagens de

¹Em 31/12/2019 a OMS confirmou o primeiro caso de Covid-19.

Donald Trump e o número de casos de Covid-19 nos Estados Unidos, indicando um efeito no tom de seus tweets à medida que a pandemia afetava a vida e a economia americana. Também foi identificada uma mudança gradual do sentimento positivo para o negativo nas mensagens de Donald Trump mencionando a China e o coronavírus juntos.

Apesar de apresentar estudos que analisam sentimentos no contexto da Covid-19 e das pandemias governamentais, não foi identificado um trabalho relacionado que explore possíveis mudanças na percepção dos usuários sobre o governo Jair Bolsonaro, especialmente comparando antes e depois de relatar dramas pessoais e tragédias familiares causadas por Covid-19 nas redes sociais.

Tabela 2.1: Comparação entre estudos sobre análise de sentimentos dos usuários do Twitter no contexto da pandemia da Covid-19

Referência	Período analisado	Classificador sentimento	Tweets nos idiomas inglês e português	Percepção do sentimento do usuário em relação
(XUE et al., 2020)	23/01/2020 a 07/03/2020 (44 dias)	SML ²	Não	Covid-19
(NASEEM et al., 2021)	01/02/2020 a 31/03/2020 (60 dias)	Textblob	Não	Covid-19
(DUBEY, 2020)	11/03/2020 a 31/03/2020 (20 dias)	Syuzhet	Não	Covid-19
(MEDFORD et al., 2020)	14/01/2020 a 28/01/2020 (14 dias)	Syuzhet	Não	Covid-19
(GARCIA; BERTON, 2021)	17/04/2020 a 08/08/2020 (112 dias)	SML	Não	Covid-19
(ZHUNIS; et al. (2022))	31/12/2018 a 29/02/2020 (425 dias)	SML	Não	Covid-19
(KAUR; VERMA; OTOO, 2021)	11/03/2020 a 03/05/2020 (54 dias)	Syuzhet	Não	Covid-19
(YAQUB, 2020)	24/01/2020 a 30/06/2020 (159 dias)	VADER	Não	Covid-19
Nossa pesquisa	01/12/2020 a 31/01/2022 (426 dias)	VADER Syuzhet Textblob Polyglot	Sim	Governo

Fonte: O autor (2022).

2.5 Conclusão da fundamentação

Neste capítulo apresentamos a fundamentação para o estudo, com base na literatura, cobrindo os tópicos relacionados ao objetivo do presente estudo. Caracterizamos a AC e sua aplicação às redes sociais. Apresentamos também conceitos sobre emoções, sentimentos e como um conjunto de técnicas de PLN pode ser usado para analisar extrair sentimentos e classificá-los em positivos, negativos ou neutros. Por fim, apresentamos diversos trabalhos relacionados ao presente estudo destacando características comuns e pontos ainda não explorados.

Descrevemos no próximo capítulo a abordagem epistemológica-metodológica contemplada neste estudo.

²*Supervised Machine Learning (SML)*

3. Abordagem Epistemológica-Metodológica de Pesquisa

3.1 Epistemologia positivista

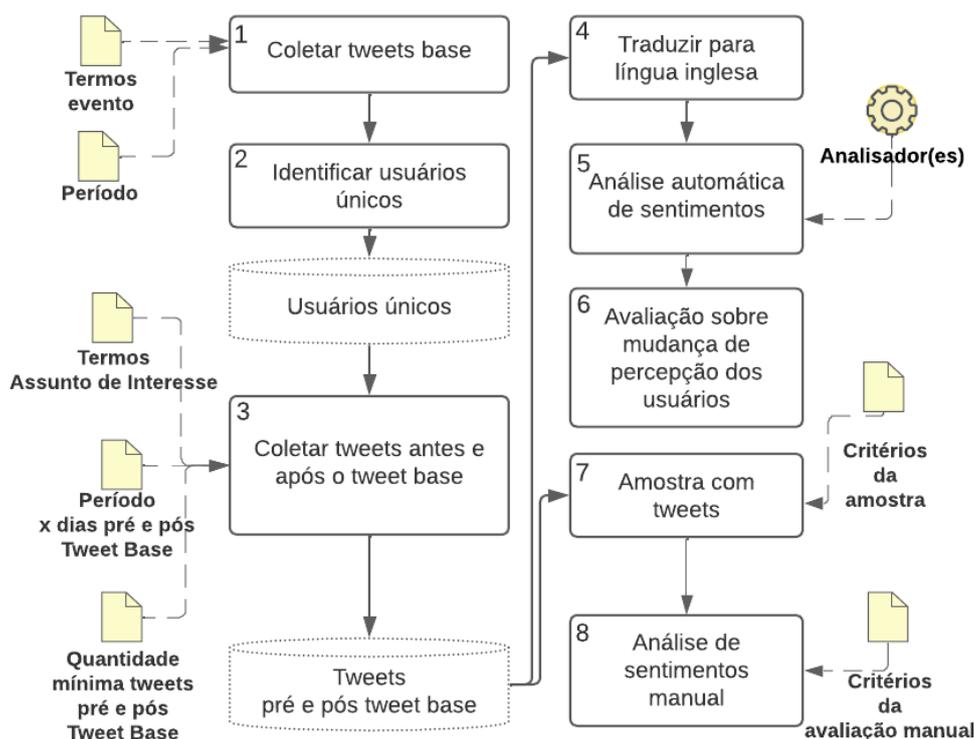
A presente pesquisa foi elaborada sob a perspectiva da epistemologia positivista. A epistemologia positivista é a teoria do conhecimento que se baseia nos princípios do positivismo, corrente filosófica que surgiu no século XIX. Essa teoria sustenta que o conhecimento pode ser obtido através da observação dos fenômenos, a partir da verificação de hipóteses por meio da aplicação de métodos quantitativos e representações matemáticas (MALIK; MALIK, 2021). De acordo com a epistemologia positivista, nossa abordagem seguiu o método quantitativo de pesquisa utilizando mensurações de número de tweets, frequências de palavras e intensidade de emoções e sentimentos para medir a mudança de percepção dos usuários do Twitter em relação ao governo Jair Bolsonaro.

3.2 Metodologia

Nesta pesquisa aplicamos a abordagem quantitativa por meio de estudos experimentais, compreendidos por dois experimentos, com a finalidade de testarmos a hipótese de nossa questão de pesquisa: as percepções das pessoas em relação ao governo Bolsonaro mudam após elas relatarem nas redes sociais um familiar acometido pela Covid-19?

Seguindo um processo de coleta e análise de tweets proposto por esta pesquisa (Figura: 3.1), executamos dois experimentos. Ambos experimentos com objetivo identificar mudanças na percepção das pessoas em relação ao governo Jair Bolsonaro durante a pandemia da Covid-19, com base em tweets e no fato de essas pessoas terem um familiar afetado pela Covid-19.

Figura 3.1: Processo de coleta e análise de tweets



Fonte: O autor (2022).

O processo de coleta e análise de tweets proposto foi desenhado de modo que fosse possível instanciá-lo com diferentes configurações, de acordo com os objetivos pretendidos. A descrição das etapas que compõem este processo, bem como os itens de configurações possíveis, destacados na cor amarela (Figura: 3.1), são explicados a seguir:

- 1. Coletar tweets base:** inicialmente são coletados tweets que identificam eventos (quando alguém relata um caso de Covid-19 na família). Neste estudo, denominamos os tweets coletados nesta etapa como “Tweet Base” e os utilizamos como marcadores temporais para a análise dos sentimentos antes e depois de cada usuário.

 - **Termos evento:** são os termos que compreendem a *string* de busca utilizada para a coleta dos tweets relacionados ao evento a partir do qual se pretende analisar os sentimentos dos usuários antes e depois.
 - **Período:** datas de início e fim utilizadas para delimitar a busca por tweets base.
- 2. Identificar usuários únicos:** nesta etapa são identificados os usuários únicos a

partir dos tweets que foram coletados na etapa anterior. Existem casos em que os usuários postaram vários tweets contendo os termos buscados. Nestes casos, foi convencionalizado que o tweet com a data mais antiga seria considerado o tweet base.

3. **Coletar tweets antes e após o tweet base:** a partir do tweet base de cada usuário único são coletados outros tweets, destes mesmos usuários, que foram postados x dias antes e x dias após o seu tweet base. Sobre os tweets coletados nesta etapa, é aplicado um filtro com objetivo de eliminar tweets que não tenham relação com o assunto de interesse (governo Jair Bolsonaro) e , finalmente, um último filtro para eliminar os usuários que não restaram uma quantidade mínima de tweets pré e pós o seu tweet base. A figura 3.3 ilustra os tweets base e os grupos pré e pós tweet base de cada usuário.

- **Termos assunto de interesse:** termos relacionados ao assunto de interesse sobre o qual se deseja inferir o sentimento do usuário. Estes termos são utilizados como filtro para a base de tweets pré e pós tweet base.
- **Período x dias pré e pós Tweet Base:** número de dias antes e após o tweet base de cada usuário. Utilizado para delimitar o período de coleta de tweets, relacionados ao assunto de interesse, antes e após o tweet base de cada usuário.
- **Quantidade mínima tweets pré e pós Tweet Base:** quantidade mínima de tweets antes e após o tweet base de cada usuário. Utilizado como um critério de exclusão aplicado aos usuários cuja quantidade de tweets pré e pós tweet base não atinja a quantidade mínima estabelecida.

4. **Traduzir para língua inglesa:** nesta etapa os tweets dos grupos pré e pós tweet base são traduzidos para a língua inglesa. No estudo publicado por Pereira (2021), o autor realiza um levantamento dos esforços feitos especificamente para abordar a análise de sentimentos na língua portuguesa. Ele categoriza e descreve trabalhos de última geração envolvendo abordagens para cada uma das tarefas de análise de sentimentos, bem como recursos de linguagem de suporte, como ferramentas de PLN, léxicos, corpora, ontologias e conjuntos de dados. O estudo conclui que traduzir textos para o inglês e utilizar ferramentas desenvolvidas para aquela língua é mais eficaz do que aplicar ferramentas e esforços específicos em português.

5. **Análise automática de sentimentos:** os tweets dos grupos pré e pós tweet base são submetidos a analisadores de sentimentos responsáveis por calcular a polaridade do sentimento contido na mensagem. Devido a polaridades dos sentimentos, calculadas pelos analisadores, serem representadas por um número contínuo entre -1 e +1,

a partir das polaridades que foram calculadas para cada tweet, utilizamos uma escala com intervalos para categorização dos sentimentos (Figura 3.2). Ao final desta etapa, cada tweet dos grupos pré e pós tweet base, para cada um dos analisadores utilizados, recebem um rótulo indicando o sentimento daquele tweet.

- **Analisadores:** analisadores de sentimentos capazes de calcular a polaridade do sentimento de um tweet. Para representar a polaridade os analisadores utilizam valores entre -1,0 e +1,0, onde -1,0 se refere a 100% da polaridade negativa, +1,0 se refere à polaridade positiva e 0 indica polaridade neutra.
6. **Avaliação sobre mudança de percepção dos usuários:** nesta etapa, os sentimentos dos tweets dos grupos pré e pós do tweet base são quantificados e comparados com base em métricas como variação percentual das intensidades dos sentimentos e frequência de palavras em ambos os grupos de dados.
 7. **Amostra com tweets:** uma amostra de tweets dos grupos pré e pós tweet base é selecionada. O objetivo desta amostra é submetê-la a um processo de análise de sentimentos manual para que seja possível comparar os sentimentos que foram atribuídos aos tweets de maneira automática e manual.
 - **Critérios da amostra:** critérios aplicados a amostra a ser avaliada manualmente;
 8. **Análise de sentimentos manual:** nesta etapa os tweets selecionados na etapa anterior são submetidos a uma avaliação de sentimentos manual.
 - **Critérios da avaliação manual:** critérios aplicados a avaliação manual de acordo com o objetivo pretendido;

Figura 3.2: Escala com os intervalos utilizados para categorização dos sentimentos a partir da polaridade calculada para cada tweet.

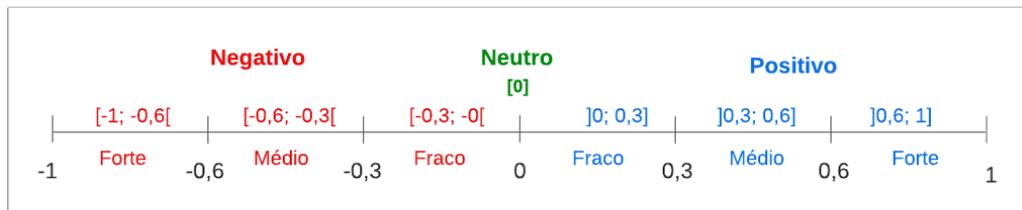
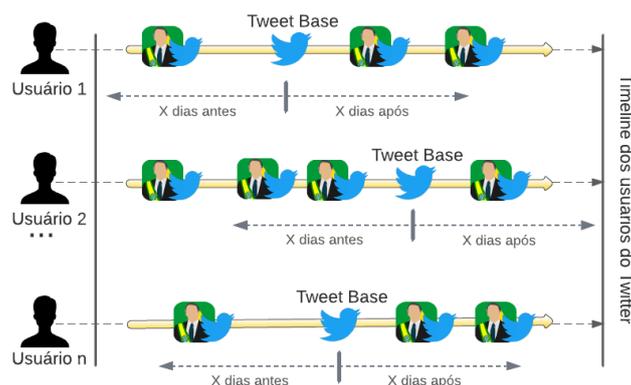


Figura adaptada de Naseem et al. e Jakhar e Pandey (2021).

Em cada um dos experimentos desenvolvidos neste estudo (Experimento 1 e Experimento 2), executamos uma instância diferente do processo apresentado nesta seção. Os

Figura 3.3: Tweets base e os grupos pré e pós tweet base de cada usuário



Fonte: O autor (2022).

detalhes sobre as configurações utilizadas, bem como detalhes sobre a coleta, processamentos dos dados e as análises realizadas em cada experimento são apresentadas nos capítulos seguintes: capítulos 4 (Experimento 1) e 5 (Experimento 2).

3.3 Considerações finais sobre a abordagem metodológica

Neste capítulo abordamos a epistemologia positivista e a abordagem quantitativa aplicada a presente pesquisa por meio de dois experimentos que serão apresentados ao longo dos próximos dois capítulos. Explicamos também cada uma das etapas do processo de coleta e análise de tweets proposto por esta pesquisa. No próximo capítulo descrevemos detalhes sobre a execução do nosso primeiro experimento.

4. Experimento 1

Este capítulo está dividido em 3 seções principais. A seção 4.1 apresenta os critérios utilizados para a coleta de dados, procedimentos, ferramentas e o período de análise dos dados; na seção 4.2 apresentamos os procedimentos para a tradução dos tweets para língua inglesa e também para classificação automática e manual dos sentimentos extraídos dos tweets. Na seção 4.3 utilizamos análise quantitativa das intensidades dos sentimentos presentes nos tweets e frequência de palavras para responder as subquestões de pesquisa SQR1 “Em que medida os sentimentos negativos, positivos e neutros estão presentes nos grupos de tweets sobre o governo Bolsonaro antes e após os relatos sobre um familiar acometido pela Covid-19?” e SQR2 “Há diferença entre as palavras positivas, negativas e neutras mais frequentemente utilizadas entre os grupos de tweets antes e após um familiar ter sido afetado pela Covid-19?”, estabelecidas na seção 1.4.

4.1 Coleta de dados

De acordo com o processo, apresentado na seção 3.2, nossa coleta dos dados foi realizada em duas etapas: coleta dos tweets base e coleta dos tweets antes e após os tweets base de cada usuário.

Primeiramente, durante a etapa de coleta dos tweets base, foi feita uma extração de tweets de usuários que postaram relatos sobre familiares vitimados pela Covid-19. O tweet correspondente foi marcado como um tweet base. A biblioteca Tweepy (ROESSLEIN, 2020) da linguagem Python foi usada para extração dos tweets. Na etapa de coleta dos tweets base, procuramos todos os tweets contendo os termos: (“meu pai” OR “minha mãe” OR “meu filho” OR “minha filha” OR “meu tio” OR “minha tia” OR “meu avô” OR “minha avó” OR “meu irmão” OR “minha irmã” OR “meu primo” OR “minha prima” OR “meu sobrinho” OR “minha sobrinha”) AND (morreu OR faleceu OR teve OR pegou OR internado OR curou OR curado OR melhorou OR “teve alta” OR “recebeu

alta”) AND (corona OR coronavírus OR “corona vírus” OR covid OR covid-19) ¹. O período de extração de dados ocorreu em 72 dias consecutivos de coleta de dados entre 30/03/2021 e 10/06/2021, sendo identificados 3.756 usuários únicos nesta etapa.

Ao término da coleta dos tweets base e após identificados os usuários únicos, iniciou-se a etapa de coleta de tweets pré e pós cada tweet base. Nesta etapa, para cada um dos 3.756 usuários únicos identificados na etapa anterior, coletamos tweets antes e depois de seus respectivos tweets base. Para obter uma quantidade mínima de tweets antes e depois do tweet base de cada usuário, foi necessário restringir o período de coleta. Definimos uma janela de tempo para esta segunda fase de extração de tweet de 30 dias antes e 30 dias após o tweet base de cada usuário. A escolha do intervalo de 30 dias foi baseada em estudos que mostram que o período de internação na Covid-19 é em média de 22 dias (CAMILLE; BEATRIZ, 2021). Em seguida, aplicamos um filtro para selecionar apenas tweets relacionados ao assunto de interesse deste estudo: governo Jair Bolsonaro². Como resultado da aplicação deste último filtro, obtivemos dois conjuntos de tweets sobre o governo Bolsonaro, um antes do tweet base e um depois dele. Usamos esses dois conjuntos de tweets para realizar nossas análises, entretanto consideramos somente os usuários que possuíam no mínimo cinco³ tweets em ambos conjuntos. O número final de tweets em cada conjunto consistiu em 12.057 tweets no grupo antes e 10.670 no grupo de depois, sendo 447 usuários distintos que postaram em média 27 tweets antes e 24 tweets após o tweet base. A tabela 4.1 apresenta a descrição dos dados coletados para grupos finais de tweets antes e depois dos tweets base.

O período de análise como um todo é referente aos 72 dias de coleta para os tweets bases, de 30/03/2021 e 10/06/2021, acrescidos de 30 dias antecedentes a data do primeiro tweet base coletado e 30 dias subsequentes ao último tweet base coletado, que representa o período em que foram coletados os tweets dos grupos de tweets antes e depois do tweet base dos usuários. A figura 4.1 ilustra o período de coleta dos tweets base e o período de coleta dos tweets dos grupos antes e após o tweet base.

Ao término da coleta de tweets, iniciamos o processamento dos dados com a finalidade de preparar os dados para nossas análises (seção 4.3). Os procedimentos e ferramentas utilizadas para o processamento dos dados são apresentados na seção seguinte.

¹Os termos estão descritos exatamente como foram submetidos a API de busca da biblioteca Tweepy.

²O filtro consistiu em identificar mensagens que continham ao menos uma das palavras “presidente” ou “Bolsonaro” ou que continham a marcação de citação “@jairbolsonaro”.

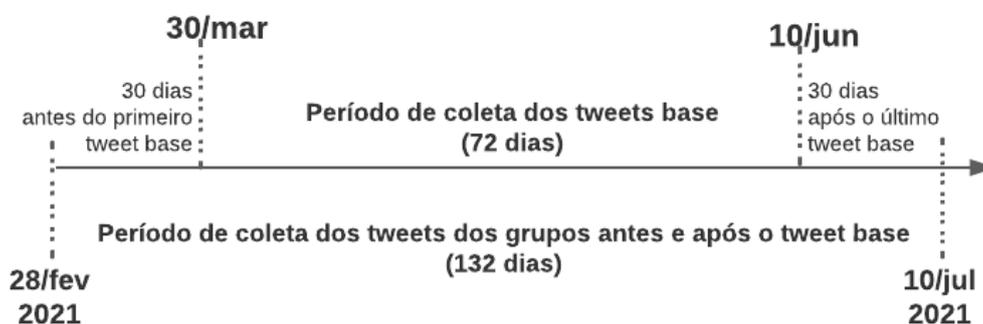
³A quantidade mínima de 5 tweet pré e pós tweet base por usuário foi definida de forma arbitrária para que pudéssemos ter um mínimo de tweets por usuário para que fosse calculado o sentimento do usuário em cada grupo. Neste estudo não limitamos a quantidade máxima de tweets a serem analisados por usuário.

Tabela 4.1: Descrição dos grupos finais de tweets antes e depois dos tweets base

	Grupos	
	Antes	Depois
Número de Tweets	10.670	12.057
Número de usuários	447	447
Média de tweets por usuário	27	24
Desvio padrão	75	44
min	5	5
25%	8	7
50%	12	11
75%	22	21
max	1.345	501

Fonte: O autor (2022).

Figura 4.1: Período de coleta dos tweets base e o período de coleta dos tweets dos grupos pré e pós tweet base

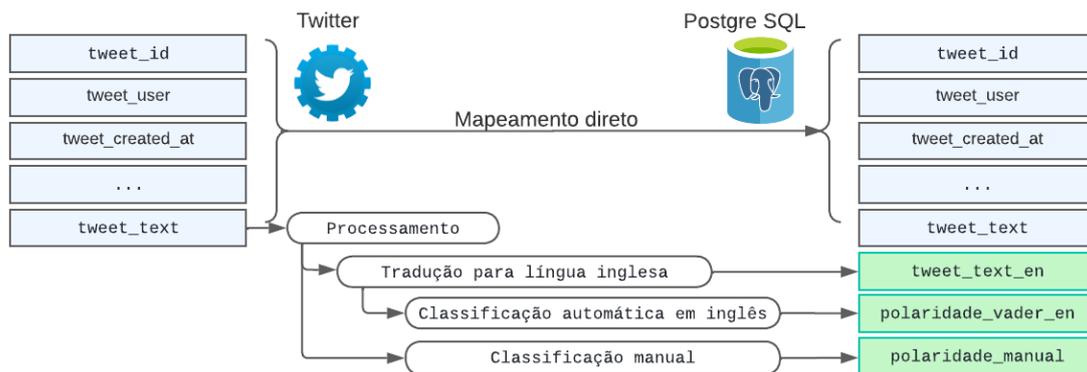


Fonte: O autor (2022).

4.2 Processamento de dados

Esta seção está dividida em três subseções. A subseção 4.2.1 apresenta os procedimentos utilizados para tradução dos tweets para a língua inglesa, a subseção 4.2.2 apresenta a ferramenta e os procedimentos empregados para a classificação automática de sentimentos. A subseção 4.2.3 apresenta os procedimentos para classificação de sentimentos manual dos tweets.

Figura 4.2: Etapa de processamento dos dados.



Fonte: O autor (2022).

4.2.1 Tradução para língua inglesa

Tweets sobre o governo Bolsonaro tiveram que ser traduzidos para o inglês, pois a ferramenta de análise de sentimentos VADER⁴ não possui um dicionário léxico em português. No estudo publicado por Pereira (2021), o autor realiza um levantamento dos esforços feitos especificamente para abordar a análise de sentimentos na língua portuguesa. Ele categoriza e descreve trabalhos de última geração envolvendo abordagens para cada uma das tarefas de análise de sentimentos, bem como recursos de linguagem de suporte, como ferramentas de PLN, léxicos, corpora, ontologias e conjuntos de dados. O levantamento considerou, além de tweets, revisões de produtos, resenhas de comida e resenhas de filmes, e concluiu que traduzir textos para o inglês e utilizar ferramentas desenvolvidas para aquela língua é mais eficaz do que aplicar ferramentas e esforços específicos em português.

Para tradução dos tweets, utilizamos o Googletrans⁵, uma biblioteca de tradução, implementada em Python e que suporta tradução automática de grandes volumes de texto.

⁴<<https://github.com/cjhutto/vaderSentiment>>

⁵<<https://py-googletrans.readthedocs.io/en/latest/>>

4.2.2 Classificação automática de sentimentos

A classificação automática de sentimentos foi realizada utilizando a ferramenta de análise de sentimentos VADER. Este analisador recebe o texto do tweet como entrada e gera a polaridade de toda a frase, analisando palavra por palavra. Para representar a polaridade, o VADER utiliza valores entre -1,0 e +1,0, onde -1,0 se refere a 100% da polaridade negativa, +1,0 se refere à polaridade positiva e 0 indica polaridade neutra. Aplicamos um mecanismo para classificar o sentimento de acordo com as categorias positivo, neutro e negativo (SINGH; JAKHAR; PANDEY, 2021) (NASEEM et al., 2021) e suas subcategorias, conforme ilustrado pelas figuras 3.2 e 4.3.

Todos os tweets processados foram submetidos previamente a uma etapa de limpeza, em que realizamos a remoção de links, caracteres especiais, referências para pessoas, que são palavras iniciadas com “@” e hashtags. Adicionalmente, para a etapa de classificação automática de sentimentos, removemos também stopwords contidas nas mensagens utilizando a biblioteca NLTK⁶, desenvolvida em Python.

Figura 4.3: Método utilizado para categorização dos sentimentos a partir da polaridade calculada.

```
def polarity_to_categ_and_subcateg(polarity):
    if polarity == 0:
        return polarity, "NEU", ""
    elif 0 < polarity <= 0.3:
        return polarity, "POS", "Positivo Fraco"
    elif 0.3 < polarity <= 0.6:
        return polarity, "POS", "Positivo Médio"
    elif 0.6 < polarity <= 1.0:
        return polarity, "POS", "Positivo Forte"
    elif -0.3 <= polarity < 0:
        return polarity, "NEG", "Negativo Fraco"
    elif -0.6 <= polarity < -0.3:
        return polarity, "NEG", "Negativo Médio"
    elif -1.0 <= polarity < -0.6:
        return polarity, "NEG", "Negativo Forte"
    return polarity, "", ""
```

Fonte: adaptado de Jakhar e Pandey (2021)

4.2.3 Classificação manual de sentimentos

Realizamos uma classificação manual de sentimentos em uma amostra de tweets. O objetivo foi compreender os motivos relacionados aos problemas de tradução e classifi-

⁶<https://www.nltk.org/>

cação automática de sentimentos observados (seção 4.3.3), comparando os resultados da classificação realizada de maneira automática e manual (seção 4.3.4).

Nessa abordagem, filtramos termos relevantes presentes nos tweets que a ferramenta de tradução não entendeu ou tweets que suspeitamos ter havido uma qualificação incorreta por parte do analisador automático de sentimento. Dos dois grupos de tweets sobre o governo, utilizamos uma amostra de 650 tweets com os termos de difícil tradução: CPI, Pfizer, Lula, Genocida, 29M (movimento social em 29 de maio de 2021, contra Bolsonaro), Impeachment e ForaBolsonaro. Assim, desenvolvemos e disponibilizamos um aplicativo web (Figura 4.4) para permitir que as pessoas participantes avaliassem os tweets⁷.

Os participantes foram selecionados por conveniência considerando os contatos dos autores: cinco professores, uma psicóloga, três analistas de sistemas computacionais, uma geóloga, uma geofísica, uma advogada, uma jornalista e um geógrafo. Todos os 14 participantes selecionados são usuários frequentes de redes sociais e possuem, no mínimo, o ensino superior. Solicitamos aos participantes que classificassem os tweets, no idioma português, de acordo com a quantidade de termos negativos, positivos e neutros identificados por eles em cada tweet. Conforme pode ser observado na figura 4.4, as opções de classificação disponíveis eram: neutro, positivo (forte e fraco) ou negativo (forte e fraco). Devido a quantidade restrita de participantes, para que os 650 tweets de nossa amostra fossem avaliados, cada tweet recebeu apenas uma única avaliação.

A pesquisa foi disponibilizada aos participantes no dia 26 de agosto de 2021. Aos participantes foram fornecidas as instruções necessárias sobre sua participação na pesquisa, juntamente com a orientação que o link da pesquisa não deveria ser repassado para outras pessoas.

A Tabela 4.2 apresenta a quantidade de tweets sobre o governo Bolsonaro dos grupos antes e após do tweet base para cada tipo de análise de sentimentos realizada.

Tabela 4.2: Quantidades de tweets avaliados em cada grupo

Análise de Sentimentos	Grupo de Tweets	Quantidade
Automática	Antes	12.057
	Após	10.670
Manual	Antes	325
	Após	325

Fonte: O autor (2022).

⁷O conjunto de tweets classificados manualmente está disponível em: <https://github.com/juniori/covid19_users_perception_qualitative_research>

Figura 4.4: Artefato desenvolvido para classificação manual dos tweets.

Replied to @ [redacted]

Tomara que ele vá, sem máscara e...
Deixa pra lá, melhor não concluir meus
pensamentos.
[#ForaBolsonaroGenocida](#) e toda sua turma!

4:21 PM · Mar 19, 2021

See the latest COVID-19 infor...

Tweet your reply

Como você classificaria a mensagem deste
tweet? A mensagem é:

Neutra

Positiva

Fraco Médio Forte

Negativa

Fraco Médio Forte

PRÓXIMO >

Fonte: O autor (2022).

4.3 Análises

Nesta seção consideramos a intensidade dos sentimentos e frequência de palavras para as análises dos dados processados. Além disso, apresentamos os resultados da análise de sentimento realizada manualmente.

4.3.1 Intensidades dos sentimentos

Para responder nossa primeira subquestão de pesquisa: “(SRQ1) Em que medida os sentimentos negativos, positivos e neutros estão presentes nos grupos de tweets sobre o governo Bolsonaro antes e após os relatos sobre um familiar acometido pela Covid-19?”, desenvolvemos dois gráficos setorizados, cada um dos gráficos com os percentuais das intensidades de sentimento que foram calculadas para cada grupo de tweets. O objetivo foi possibilitar entendimento dos percentuais calculados para cada intensidade de sentimento e compará-los entre os grupos de tweets sobre o governo antes e após o tweet base.

A Figura 4.5 apresenta os percentuais das intensidades dos sentimentos calculados para os conjuntos de tweets relacionados ao governo antes e depois do tweet base.

Observou-se que, quando comparados, os percentuais variaram levemente. O grupo de tweets depois do tweet base apresentou uma discreta redução dos sentimentos negativos e positivos. Houve uma redução de 1% quando comparado o sentimento negativo e de 0,3% quando comparado o sentimento positivo. A redução dos percentuais de negatividade e positividade foi refletida no aumento de 1,3% do sentimento neutro.

Percebeu-se também uma pequena variação quando comparado os percentuais das categorias “forte”, “médio” e “fraco” de cada sentimento entre os grupos. A maior variação entre os negativos ocorreu na categoria “Negativo Forte”, a qual passou de 13,9% para 12,5% reduzindo em 1,4%. Entre os positivos, as maiores variações ocorreram nas categorias “Positivo Fraco” e “Positivo Médio”, onde ambas tiveram uma variação de 0,9%, entretanto, enquanto a categoria “Positivo Fraco” aumentou em 0,9%, “Positivo Médio” reduziu 0,9%.

Tabela 4.3: Resultado dos testes de Mann-Whitney e Vargha & Delaney’s entre os pares de amostras de tweets negativos

	Negativo Forte			Negativo Médio			Negativo Fraco		
	Média (SD)	p-value	T. Efeito	Média (SD)	p-value	T. Efeito	Média (SD)	p-value	T. Efeito
Antes	0,15 (0,12)			0,17 (0,11)			0,11 (0,10)		
Depois	0,13 (0,12)	0,003	0,55	0,18 (0,13)	0,611	0,49	0,11 (0,11)	0,734	0,5

Fonte: O autor (2022).

Tabela 4.4: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets neutros

		Neutro		
		Média (SD)	p-value	T. Efeito
Antes		0,30 (0,16)	0,673	0,49
Depois		0,30 (0,17)		

Fonte: O autor (2022).

Tabela 4.5: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets positivos

		Positivo Fraco			Positivo Médio			Positivo Forte		
		Média (SD)	p-value	T. Efeito	Média (SD)	p-value	T. Efeito	Média (SD)	p-value	T. Efeito
Antes		0,07 (0,08)	0,012	0,45	0,13 (0,10)	0,423	0,51	0,07 (0,08)	0,116	0,52
Depois		0,09 (0,09)			0,13 (0,10)			0,06 (0,08)		

Fonte: O autor (2022).

Aplicando um teste de Mann-Whitney (Wilcoxon)^{8, 9,10} entre os pares de amostras dos tweets de mesmo sentimento¹¹ entre os grupos antes e depois, observamos diferenças significativas entre os pares de amostras dos tweets de sentimento “Negativo Forte” e “Positivo Fraco”. Com objetivo de verificar o tamanho de efeito sobre as diferenças significativas indicadas pelo teste Mann-Whitney, aplicamos um teste Vargha & Delaney's entre os pares de amostras dos tweets de sentimento “Negativo Forte” e “Positivo Fraco” entre os grupos antes e depois. Como resultado do teste Vargha & Delaney's obtivemos tamanhos de efeito 0,55 e 0,45 para os pares de amostras dos tweets de sentimento “Negativo Forte” e “Positivo Fraco” respectivamente. A proximidade de 0,5 dos valores de tamanho de efeito calculados indica que, apesar de haver uma diferença significativa entre os grupos, essa diferença é considerada pequena. As tabelas 4.3, 4.4 e 4.5 apresentam os resultados dos testes. A tabela ?? apresenta a quantidade de tweets classificados de acordo com o sentimento calculado.

Constatada a pouca variação entre os percentuais das intensidades dos sentimentos entre os dois grupos, seguimos analisando os dados a fim de obtermos um melhor entendimento sobre a dispersão da intensidade dos sentimentos dos usuários entre os grupos. Acrescentamos em nossas análises a quantidade de tweets publicados pelos usuários antes e depois do tweet base, conforme apresentado na seção seguinte 4.3.2.

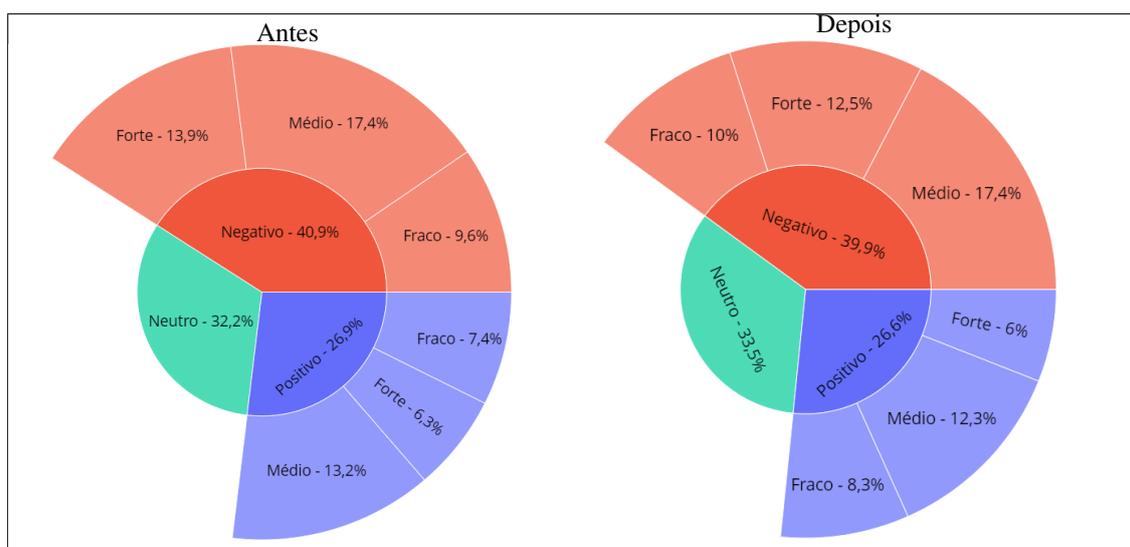
⁸<<https://search.r-project.org/R/refmans/stats/html/wilcox.test.html>>

⁹O teste não paramétrico de Mann-Whitney foi aplicado após a constataremos a ausência de normalidade na distribuição dos dados em todos os grupos de dados testados.

¹⁰O nível de significância (alfa) utilizado foi de 0,05.

¹¹Disponibilizamos o dataset utilizado para este teste no endereço: <https://github.com/juniori/IMPACTO_COVID-19_PERCEPCAO_USUARIOS_TWITTER/blob/main/TESTES_ESTADISTICOS>

Figura 4.5: Intensidade dos sentimentos antes e após o tweet base



Fonte: O autor (2022)

4.3.2 Quantidade de tweets e intensidade dos sentimentos por usuário

Nesta seção, buscamos entender em que medida a polaridade média dos sentimentos está relacionada à quantidade de tweets postados por cada usuário entre os grupos de tweets sobre o governo Bolsonaro antes e após o tweet base. Para isto, apresentamos um conjunto de gráficos de dispersão (Figura 4.6).

Os gráficos apresentam o número de tweets e a média das intensidades dos sentimentos calculados antes e depois do tweet de base para cada usuário.

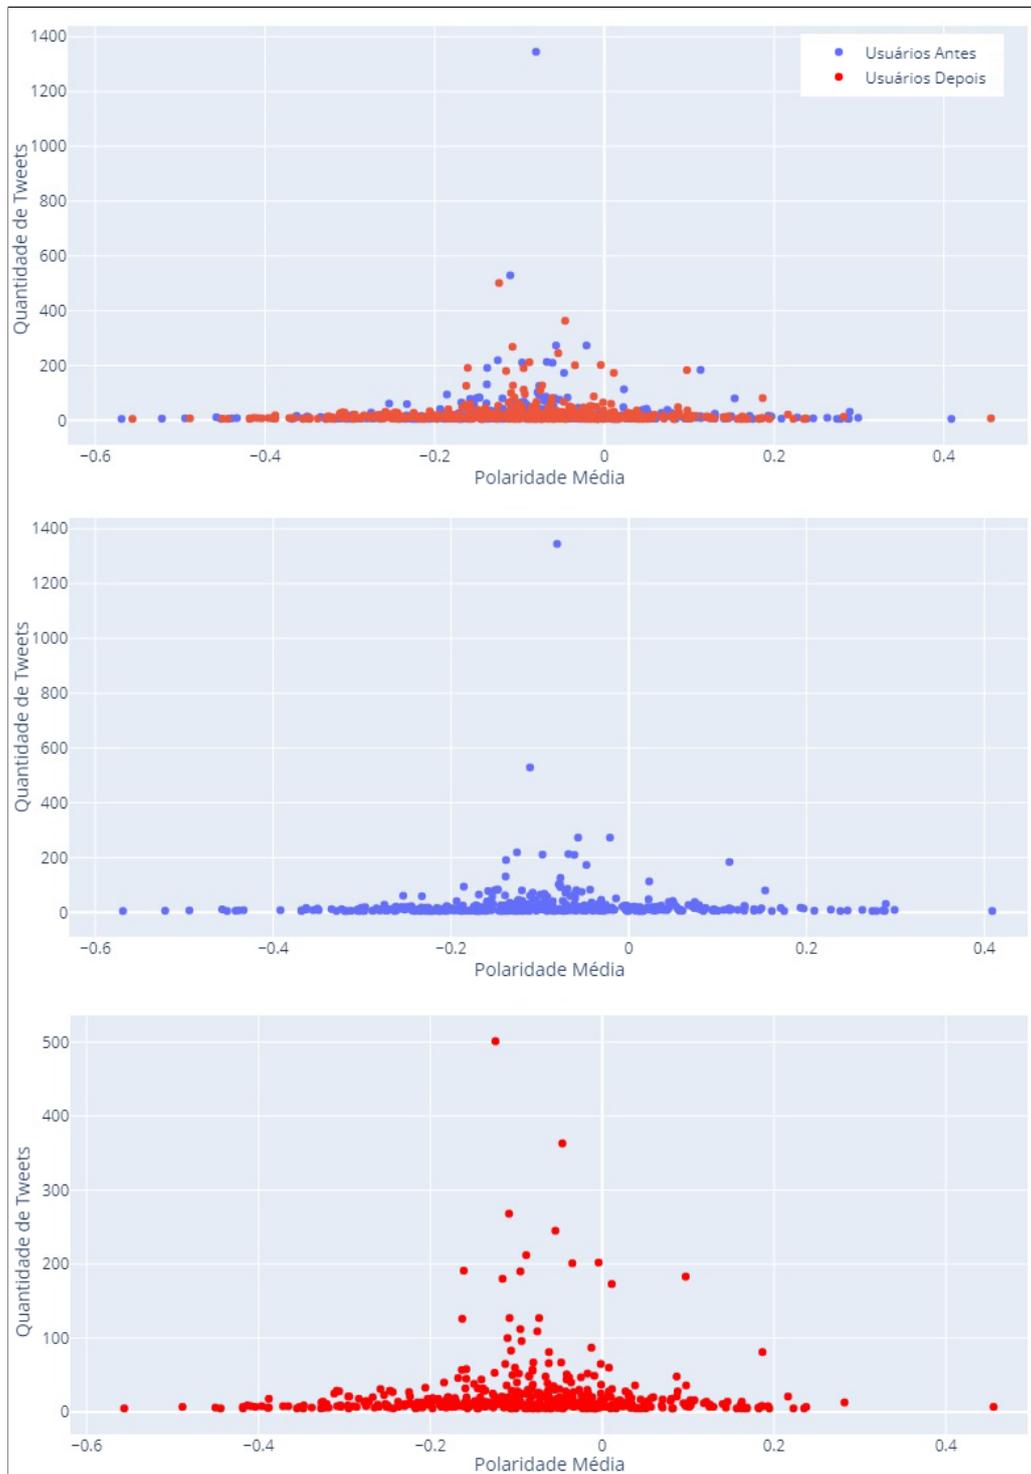
Quando analisadas as quantidades de tweets postados antes e depois do tweet base, observou-se que, em ambos os grupos, a maioria dos usuários postou poucos tweets, enquanto poucos usuários postaram muitos tweets.

Observou-se nos gráficos que, a dispersão dos pontos “azuis” que representam os usuários do grupo de tweets antes do tweet base (tanto com relação ao eixo “x”, que indica a polaridade média do sentimento do usuário, quanto no eixo “y” que indica a quantidade de tweets postados pelo usuário) confundem-se, indicando pouca mudança entre os dois grupos.

O primeiro dos três gráficos de dispersão (Figura 4.6) apresenta uma sobreposição dos pontos que representam os usuários nos grupos antes e depois do tweet base. Esse gráfico tem como objetivo evidenciar com mais clareza a frequência com relação a quantidade de tweets nos dois grupos e a dispersão dos usuários com relação aos sentimentos nos respectivos grupos.

Assim como verificado na análise da intensidade dos sentimentos apresentada na seção anterior (4.3.1), a análise apresentada nesta seção também não mostrou diferenças expressivas para média das polaridades dos sentimentos e quantidade de mensagens por usuário entre os grupos de tweets antes e depois do tweet base.

Figura 4.6: Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base



Fonte: O autor (2022).

4.3.3 Nuvens de palavras

A presente seção tem como objetivo responder a nossa segunda subquestão de pesquisa **SRQ2**: “Há diferença entre as palavras positivas, negativas e neutras mais frequentemente utilizadas entre os grupos de tweets antes e após um familiar ter sido afetado pela Covid-19?”.

As nuvens de palavras são ferramentas úteis para apresentar de uma forma ilustrativa a frequência com que determinados termos aparecem em textos. As palavras que apresentam o tamanho maior na nuvem são as mais frequentes, ao passo que as menores são as menos frequentes. Na presente pesquisa, as cores têm um caráter meramente ilustrativo para facilitar a visualização das palavras na nuvem.

Nas seções 4.3.1 e 4.3.2, classificamos os tweets a partir do sentimentos expressos em suas mensagens. Nesta seção apresentamos uma nuvem de palavras para cada categoria, mostrando como as palavras foram classificadas e como aparecem nas respectivas categorias antes e depois do tweet de base.

A Figura 4.7 mostra as nuvens de palavras para grupos de tweets antes e depois de seus tweets base. As nuvens de palavras foram geradas a partir dos tweets previamente submetidos a classificação de sentimentos automática. As palavras negativas foram extraídas dos tweets que foram classificados como negativos, as neutras dos tweets neutros e as positivas extraídas dos tweets positivos. Para criar nossas nuvens de palavras, removemos as palavras irrelevantes e não emocionais (stop words¹²).

Nas nuvens de palavras dos tweets negativos, a palavra “pandemic” foi a que mais se destacou. Ao comparar a nuvem de palavras dos tweets negativos antes e depois do tweet base, percebeu-se o aumento no tamanho das palavras “pandemic”, “protest”, “hate”, “death”, “hunger” e “shit”.

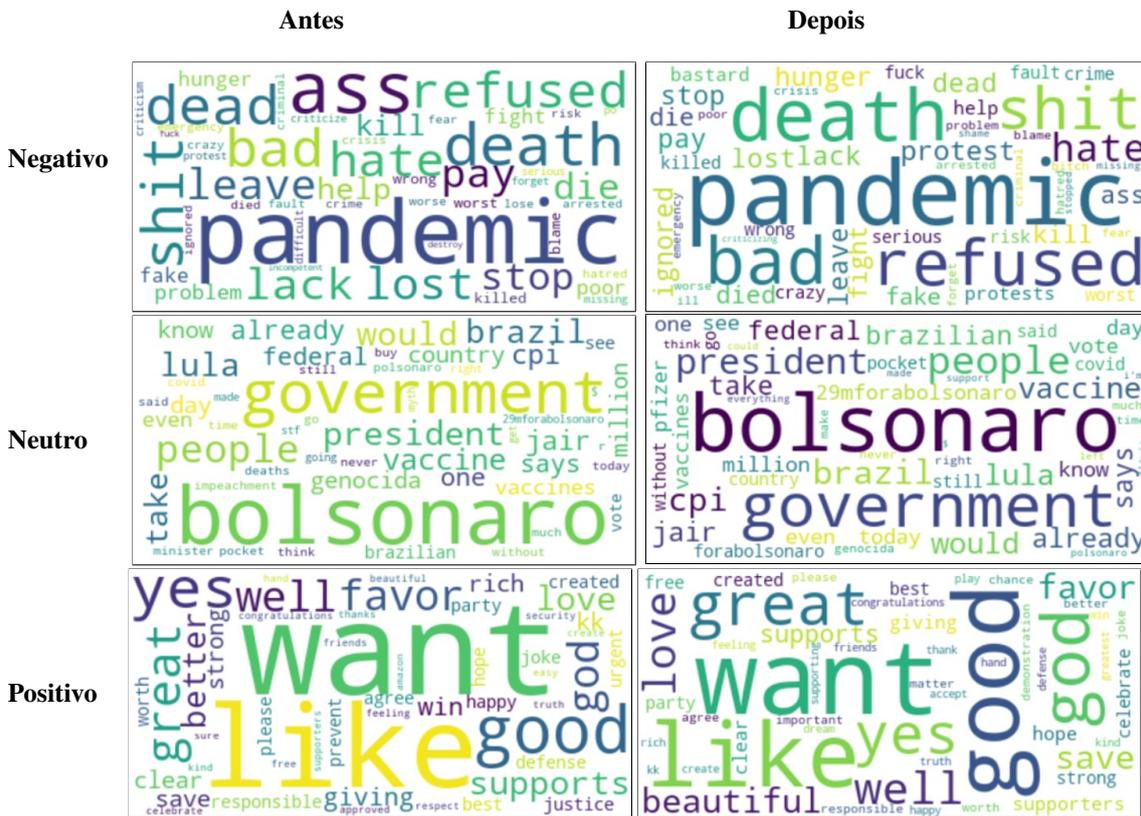
Uma comparação entre as nuvens de palavras de tweets positivos antes e depois dos tweets base mostrou que as palavras “want”, “like” e “good” permaneceram com ligeira variação no tamanho antes e depois do tweet base. Observamos um aumento no tamanho da palavra “god”. As palavras “celebrate” e “party” também aparecem na nuvem de palavras positivas após o tweet base.

Nas nuvens de palavras relacionadas ao sentimento neutro foi percebido que palavras como “cpi” e “genocida” aparecem em português. Isto ocorreu devido a problemas no processo de tradução dos tweets para a língua inglesa. Como estas palavras, não tradu-

¹²<https://www.nltk.org/>

zidas, não existem no dicionário léxico utilizado pelo VADER, elas foram classificadas indevidamente pela ferramenta com o sentimento neutro. Devido às falhas identificadas no processo de tradução, realizamos uma classificação manual de sentimentos em uma amostra de tweets dos grupos antes e depois do tweet base. Os resultados do processo de avaliação manual sobre esta amostra de tweets são apresentados na próxima seção (4.3.4).

Figura 4.7: Palavras negativas, neutras e positivas, antes e depois do tweet base (VADER)



Fonte: O autor (2022)

4.3.4 Avaliação manual

Nesta seção apresentamos os resultados do processo de avaliação manual dos tweets abordado na seção 4.2.3.

Em nosso processo de avaliação manual, utilizamos uma aplicação web como instrumento de coleta de dados. Os participantes foram orientados a classificar cada tweet conforme o número de termos negativos, positivos ou neutros observados. Conforme pode ser observado na figura 4.4, as opções de classificação disponíveis eram: neutro, positivo (forte e fraco) ou negativo (forte e fraco)

A partir dos convites enviados aos 14 convidados, que foram selecionados por conveniência dos autores, todos aceitaram participar. Cada participante classificou entre 30 e

50 tweets. A média de tweets classificados por cada participante foi de 46. A tabela 4.6 apresenta o número de tweets classificados de acordo com as avaliações dos participantes.

Ao compararmos as correspondências entre as classificações automática e manual, descobrimos que dos 650 tweets, 54% obtiveram correspondência entre as duas abordagens. Para compreender os motivos que ocasionaram uma baixa correspondência entre as classificações automáticas e manuais, inspecionamos alguns tweets e tentamos atribuir alguns prováveis motivos, os quais são discutidos na seção 7.2.

Tabela 4.6: Quantidade de tweets classificados manualmente

		Grupos					
		Antes n (%)		Depois n (%)		Total n(%)	
Negativo	Forte		64 (19,7)		69 (21,2)		133 (20,5)
	Médio	214 (65,8)	69 (21,2)	197 (60,6)	59 (18,2)	411 (63,2)	128 (19,7)
	Fraco		81 (24,9)		69 (21,2)		150 (23,1)
Neutro		56 (17,2)	56 (17,2)	60 (18,5)	60 (18,5)	116 (17,8)	116 (17,8)
Positivo	Forte		10 (3,1)		19 (5,8)		29 (4,5)
	Médio	55 (16,9)	19 (5,8)	68 (21)	20 (6,2)	123 (18,9)	39 (6,0)
	Fraco		26 (8,0)		29 (8,9)		55 (8,5)
Total		325 (100)	325 (100)	325 (100)	325 (100)	650 (100)	650 (100)

Fonte: O autor (2022).

4.4 Considerações finais sobre o Experimento 1

Neste capítulo apresentamos os critérios, ferramentas e procedimentos utilizados para a coleta de tweets e processamento dos dados coletados. Mostramos também como consideramos a intensidade dos sentimentos e frequência de palavras para as análises dos dados processados. Além disso, apresentamos os resultados da análise de sentimento realizada manualmente.

Após a análise dos resultados obtidos durante a execução do nosso primeiro experimento, descobrimos que o sentimento geral das pessoas em relação ao governo Jair Bolsonaro não variou, ou não conseguimos captar uma variação significativa.

Considerando que o intervalo de extração dos tweets base coincidiu com o período em que pandemia atingiu seu ápice em números de casos e mortes no Brasil (ESTRADA; NÓBREGA, 2022), entre março a junho/2021, e que neste momento pesquisas apontavam que grande parte dos brasileiros desaprovava a forma com que o governo enfrentava

a pandemia ¹³, incluindo famílias de vítimas da Covid-19 que atribuíam a culpa ao governo Jair Bolsonaro (LEMOS, 2021), esperávamos encontrar diferenças mais evidentes ao comparar os resultados do cálculo dos sentimentos dos tweets antes e depois do tweet base, o que não ocorreu de forma significativa.

Diante do fato de que nossas análises não revelaram diferenças significativas e de limitações de pesquisas observadas, como problemas na tradução automática e baixa correspondência entre a classificação de sentimentos automática e manual, continuamos testando nossa hipótese (seção 1.5) por meio de um segundo experimento, no qual adicionamos algumas melhorias ao conhecimento adquirido no Experimento 1, conforme apresentado no próximo capítulo.

¹³<https://g1.globo.com/politica/noticia/2021/05/14/datafolha-51percent-reprovam-desempenho-de-bolsonaro-na-pandemia-gh.html>

5. Experimento 2

Em nosso segundo experimento, alteramos algumas configurações em nosso processo de coleta e análise de dados de acordo com o conhecimento adquirido no primeiro experimento. O objetivo destas mudanças foi superar algumas limitações de pesquisas apresentadas no capítulo anterior e verificar se o Experimento 1 deixou de captar uma mudança na percepção dos usuários devido a tais limitações. Neste segundo experimento, adicionamos ao conhecimento adquirido no Experimento 1, melhorias como:

- **Temporalidade:** expandimos nosso período de coleta de dados de maneira que nos permitisse analisar tweets de usuários contendo relatos sobre familiares acometidos pela Covid-19 (tweets base) que foram publicados durante todo ano de 2021;
- **Tradução:** devido aos problemas de tradução dos tweets para a língua inglesa, detectados no Experimento 1, adicionamos à etapa de análise automática de sentimentos de nosso processo uma nova ferramenta de análise de sentimentos capaz de calcular o sentimento a partir de textos no idioma português;
- **Análise de sentimentos automática:** além das emoções positivas, negativas e neutras quantificadas no Experimento 1, incluímos também outras ferramentas que nos permitiu refinar a classificação dos sentimentos presentes nos tweets, identificando e quantificando também emoções como raiva, tristeza, medo e ansiedade; além da detecção da quantidade de subjetividade presente nas mensagens;
- **Análise de sentimentos manual:** alteramos nosso instrumento de pesquisa. Diferentemente da pesquisa realizada no Experimento 1, em que os participantes eram solicitados a classificarem os tweets conforme os termos positivos e negativos presentes, na análise de sentimentos manual realizada para este segundo experimento, solicitamos aos participantes que avaliassem o sentimento presente em cada tweet do ponto de vista de quem postou a mensagem.

Este capítulo está dividido em 3 seções principais. A seção 5.1 apresenta os critérios utilizados para a coleta de dados, procedimentos, ferramentas e o período de análise dos dados; na seção 5.2 apresentamos os procedimentos para a tradução dos tweets para língua inglesa, os procedimentos de classificação automática e manual dos sentimentos extraídos dos tweets. Na seção 5.3 utilizamos análise quantitativa das intensidades de emoções e sentimentos presentes nos tweets e frequência de palavras para responder as subquestões de pesquisa, estabelecidas na seção 1.4.

5.1 Coleta de dados

No Experimento 2 foi realizado um procedimento de coleta de dados em duas etapas semelhante ao que foi realizado no Experimento 1. Sendo assim, coletamos os tweets base e, em seguida, os tweets sobre o governo Jair Bolsonaro antes e após cada tweet base.

Durante a etapa de coleta dos tweets base, consideramos ampliar nossa análise ao incluir também usuários com grau de parentesco além da família biológica tradicional. Para isto, ampliamos nossos termos de busca com outras formas coloquiais presentes na língua portuguesa que se referem a pessoas próximas ou entes familiares, como: “parceiro”, “parceira”, “amado”, “amada”. Após realizar uma análise exploratória dos tweets coletados com estes novos termos, recuamos e decidimos não adicioná-los ao nosso estudo, pois estes termos não retornaram tweets de qualidade satisfatória para o objetivo deste estudo.

A tabela 5.1 mostra exemplos dos tweets retornados para os termos de busca com grau de parentesco além da família biológica testados.

Os termos “parceiro” e “parceira” retornaram apenas tweets com a expressão comumente falada “meu parceiro”, associando à mensagem qualquer tipo de pessoa e não alguém próximo considerado um familiar; para os termos “amado” e “amada”, verificamos que estes termos são frequentemente utilizados em conjunto com outros termos que designam entes familiares como “meu amado tio”.

Assim sendo, mantivemos nossos termos de busca de tweets base originais, os mesmos que foram utilizados no Experimento 1: (“meu pai” OR “minha mãe” OR “meu filho” OR “minha filha” OR “meu tio” OR “minha tia” OR “meu avô” OR “minha avó” OR “meu irmão” OR “minha irmã” OR “meu primo” OR “minha prima” OR “meu sobrinho” OR “minha sobrinha”) AND (morreu OR faleceu OR teve OR pegou OR internado OR

curou OR curado OR melhorou OR “teve alta” OR “recebeu alta”) AND (corona OR coronavírus OR “corona vírus” OR covid OR covid-19)

Tabela 5.1: Termos de busca com grau de parentesco além da família biológica e tweets retornados

Termos	Tweets
Parceiro / Parceira	“ Minha parceira de viagem pegou covid na semana que íamos para Curitiba”
	“Estava preparado pra me lascar na semana que vêm que o meu parceiro ia sair de férias, agora ele pegou covid e antecipou isso”
Amado / Amada	“Hoje meu amado tio Beto morreu de covid-19 ... Estou sentindo um turbilhão de sentimentos... Tristeza misturada com revolta. É muita dor!”
	“Acabo de receber a notícia que minha amada tia está com Covid internada em um pronto socorro, ela está no oxigênio esperando uma vaga em uma UTI de um hospital, peço orações e torcida de todos para que tudo termine bem.”

Fonte: Twitter.com.

No processo de identificação dos tweets base para este segundo experimento executamos uma nova etapa de coleta dos tweets base equivalente ao que foi realizado no Experimento 1, no entanto esta etapa apresentou uma grande diferença com relação a executada no Experimento 1, pois substituímos a ferramenta de coleta de tweets para que fosse possível coletar tweets base em uma janela de tempo bem maior.

Realizamos uma nova etapa de coleta dos tweets base, extraindo usuários que postaram relatos sobre familiares vitimados pela Covid-19 e marcando o tweet correspondente como um tweet base. Substituímos a biblioteca Tweepy, utilizada no Experimento 1 para extração dos tweets base pela biblioteca Snsrape ¹ em Python. O motivo foi que a biblioteca Tweepy realiza chamadas à API (search/tweets)² do Twitter, ficando restrita às limitações impostas pela API, como por exemplo, a limitação do período de coleta que é restrita a tweets publicados nos últimos 7 dias. Como precisávamos coletar tweets postados durante todo o ano de 2021, optamos pela utilização da biblioteca Snsrape, a qual realiza a coleta de tweets por meio de técnicas de web scraping ³, superando a limitação do período de coleta imposta pela API do Twitter.

O período de extração dos tweets base ocorreu entre 01/01/2021 e 31/12/2021, sendo identificados 64.733 usuários únicos.

Assim como no Experimento 1, ao término da coleta dos tweets base, iniciou-se a etapa de coleta de tweets antes e após o tweet base. Nesta etapa, para cada um dos 64.733

¹<<https://github.com/JustAnotherArchivist/snsrape>>

²<<https://developer.twitter.com/en/docs/twitter-api/v1/tweets/search/api-reference/get-search-tweets>>

³<<https://w3cschool.com/web-scraping-using-python>>

usuários únicos identificados na etapa anterior, coletamos tweets antes e depois de seus respectivos tweets base, conforme mostrado na Figura 3.3. Utilizamos para esta etapa da coleta a API (statuses/user_timeline)^{4 5} do Twitter, por meio da biblioteca Tweepy.

O critério utilizado para se obter uma quantidade mínima de tweets antes e depois do tweet base foi o mesmo do Experimento 1, ou seja, novamente definimos uma janela de tempo para esta segunda fase de extração de tweet de 30 dias antes e 30 dias após o tweet base de cada usuário. Em seguida, aplicamos um filtro para selecionar apenas tweets sobre o governo Bolsonaro⁶. Como resultado da aplicação deste último filtro, obtivemos dois conjuntos de tweets sobre o governo Bolsonaro, um antes do tweet base e um depois dele. Usamos esses dois conjuntos de tweets para realizar nossas análises, entretanto consideramos somente os usuários que possuíam no mínimo cinco tweets em ambos conjuntos. O número final de tweets em cada conjunto consistiu em 134.160 tweets no grupo antes e 135.480 no grupo de depois, sendo 4.918 usuários distintos, que postaram em média 27 tweets antes e 28 tweets após o tweet base.

Tabela 5.2: Descrição dos grupos finais de tweets antes e depois dos tweets base

	Grupos	
	Antes	Depois
Número de Tweets	134.160	135.480
Número de usuários	4.918	4.918
Média de tweets por usuário	27	28
Desvio padrão	34	35
min	5	5
25%	9	9
50%	16	16
75%	31	31
max	359	458

Fonte: O autor (2022).

O período de análise como um todo é referente aos 365 dias de coleta para os tweets

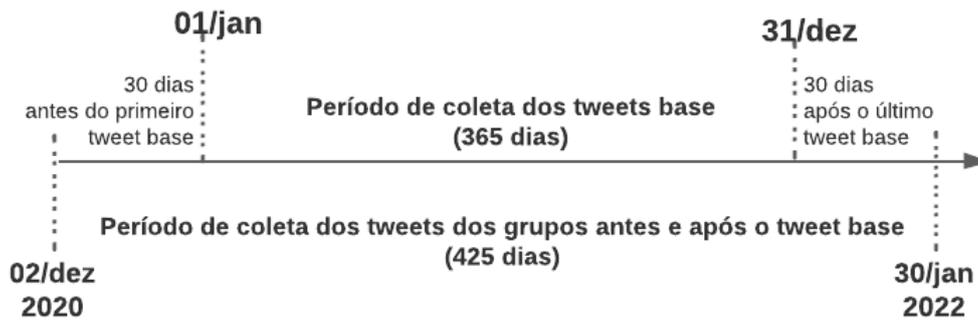
⁴A API (statuses/user_timeline) não restringe a coleta dos tweets publicados nos últimos 7 dias, pois ela permite que seja informado o identificador do usuário e também período para qual se deseja coletar os tweets do usuário.

⁵<https://developer.twitter.com/en/docs/twitter-api/v1/tweets/timelines/api-reference/get-statuses-user_timeline>

⁶O filtro consistiu em identificar mensagens que continham ao menos uma das palavras “presidente” ou “Bolsonaro” ou que continham a marcação de citação “@jairbolsonaro”.

bases, de 01/01/2021 e 31/12/2021, acrescidos de 30 dias antecedentes a data do primeiro tweet base coletado e 30 dias subsequentes ao último tweet base coletado, que representa o período em que foram coletados os tweets dos grupos de tweets antes e depois do tweet base dos usuários. A figura 5.1 ilustra o período de coleta dos tweets base e o período de coleta dos tweets dos grupos antes e após o tweet base.

Figura 5.1: Período de coleta dos dados analisados no experimento 2

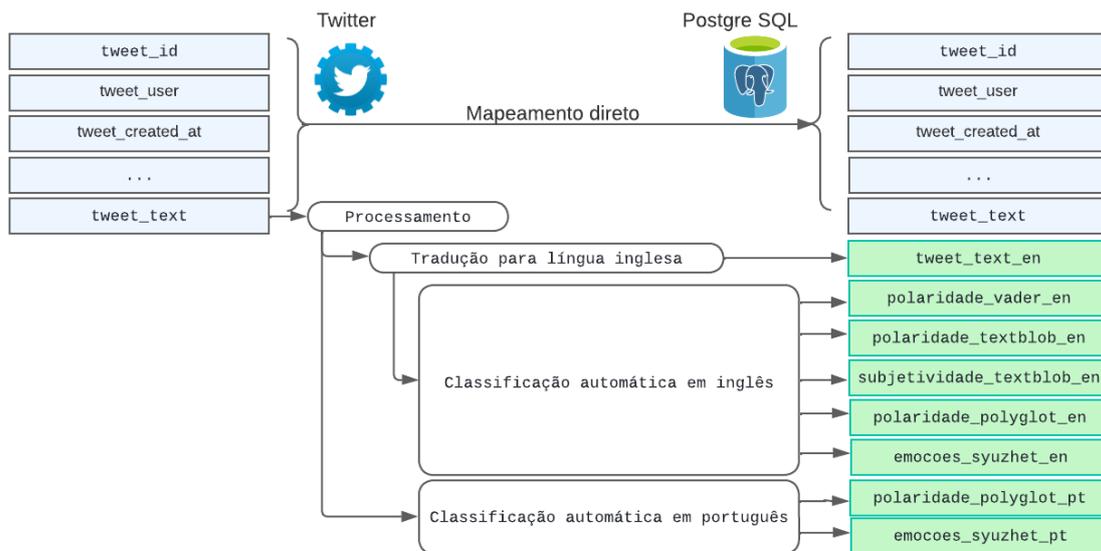


Fonte: O autor (2022).

5.2 Processamento de dados

Esta seção está dividida em três subseções e apresenta as etapas de processamento dos dados realizadas nesta pesquisa.

Figura 5.2: Etapa de processamento dos dados



Fonte: O autor (2022).

5.2.1 Tradução para língua inglesa

Assim como no Experimento 1, para este segundo experimento, traduzimos os tweets sobre o governo Bolsonaro para o inglês. A tradução continuou sendo necessária, pois nem todas as ferramentas que utilizamos em nossa análise de sentimentos possuem um dicionário léxico em português.

Neste segundo experimento, seguimos exatamente o mesmo processo para tradução dos tweets utilizado no Experimento 1.

5.2.2 Classificação automática de sentimentos

A classificação automática de sentimentos foi realizada utilizando quatro ferramentas de análise de sentimentos. Extraímos dos tweets a polaridade dos sentimentos contidos neles, e também emoções como “raiva”, “expectativa”, “nojo”, “medo”, “alegria”, “tristeza”, “surpresa” e “confiança”. A extração da polaridade dos sentimentos foi realizada utilizando as ferramentas VADER ⁷, Textblob ⁸ e Polyglot ⁹. Para extração as emoções, foi utilizada a ferramenta Syuzhet ¹⁰.

Assim como no Experimento 1, todos os tweets processados foram submetidos previamente a uma etapa de limpeza, em que realizamos a remoção de links, caracteres especiais, referências para pessoas, que são palavras iniciadas com “@”, hashtags e stopwords contidas nas mensagens utilizando a biblioteca NLTK, desenvolvida em Python¹¹.

Textblob (LORIA, 2018) é uma biblioteca escrita em Python para processamento de texto. Ela fornece uma API para execução de tarefas comuns relacionadas ao PLN, como marcação de parte da fala, extração de frases nominais, análise de sentimentos, classificação e tradução. O analisador de sentimentos provido pelo Textblob retorna duas propriedades para uma determinada sentença de entrada: i) a polaridade representada por um número entre [-1,1], -1 indica sentimento negativo e +1 indica sentimentos positivos e 0 para neutros; ii) a subjetividade, que é representada no intervalo de [0,1], quanto mais próximo de 1 significa que o texto é mais subjetivo. Frases subjetivas geralmente se referem a opinião, emoção ou julgamento. O analisador de sentimento do Textblob desconsidera as palavras que não conhece, considera somente palavras e expressões que ele consegue determinar a polaridade e retorna a polaridade e subjetividade calculada para a sentença.

⁷<<https://github.com/cjhutto/vaderSentiment>>

⁸<<https://textblob.readthedocs.io/en/dev/>>

⁹<<https://polyglot.readthedocs.io/en/latest/Sentiment.html>>

¹⁰<<https://cran.r-project.org/web/packages/syuzhet/index.html>>

¹¹<<https://www.nltk.org/>>

Assim como o Textblob e o VADER, o Polyglot, representa o sentimento por meio de uma escala de polaridade, em que -1 indica sentimento negativo e +1 indica sentimentos positivos e 0 para neutros. Entretanto, diferentemente do VADER e do Textblob, o Polyglot é capaz de obter uma compreensão do sentimento geral expresso no texto a partir de 136 idiomas diferentes, incluindo os idiomas inglês e português (CHEN; SKIENA, 2014).

O Syuzhet (JOCKERS, 2017) é um pacote da linguagem R que permite calcular pontuações de polaridade de sentimentos (positivas e negativas) e emoções (raiva, medo, antecipação, confiança, surpresa, tristeza, alegria e nojo) usando diferentes dicionários internos e em diferentes idiomas. Entretanto, vale destacar que os dicionários léxicos disponíveis em diversos idiomas, tratam-se de traduções realizadas por meio do Google Translate a partir do inglês. Segundo Jockers (2017), apesar de algumas diferenças culturais, a maioria das categorias emocionais são comuns entre os idiomas. No estudo desenvolvido por Misuraca et al. (2020), o autor compara diferentes pacotes da linguagem R que podem ser utilizados para análise de sentimentos. O estudo conclui que o Syuzhet possui uma das melhores acurácias.

5.2.3 Classificação manual de sentimentos

Neste segundo experimento, realizamos novamente a classificação manual de sentimentos em uma amostra de tweets por meio de uma nova pesquisa, que utilizou uma aplicação web como instrumento de coleta.

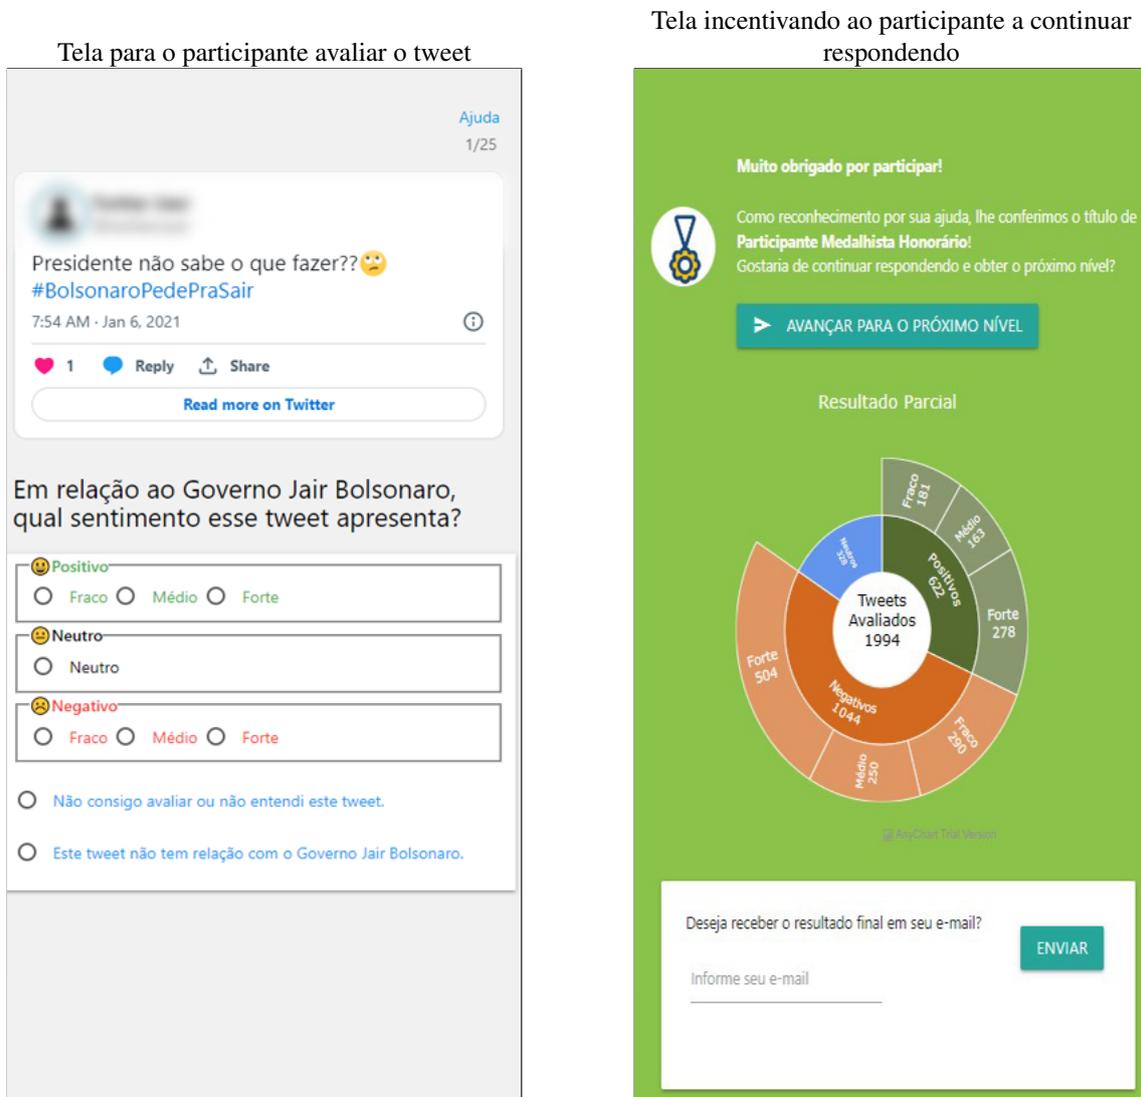
Nesta pesquisa, os participantes foram solicitados a interagir com uma aplicação web, na qual tweets relacionados ao governo Bolsonaro, previamente selecionados pelo autor, eram exibidos em sequência na tela da aplicação web.

Para a classificação manual, geramos uma amostra de tweets sobre o governo Bolsonaro que foram coletados durante o Experimento 2. Para que tivéssemos uma amostra diversificada, selecionados aleatoriamente 800 tweets para cada mês do ano de 2021, sendo 400 tweets do grupo antes do tweet base e 400 depois do tweet base. Conseqüentemente, a amostra disponível para classificação manual totalizou 9.600 tweets, contendo 4.800 tweets que foram selecionados de cada grupo.

Enquanto no Experimento 1 solicitamos aos participantes que classificassem os tweets de acordo com a quantidade de termos negativos, positivos e neutros contidos em cada tweet (seção 4.2.3), para este segundo experimento os participantes foram solicitados a classificarem os tweets de acordo com o sentimento identificado no tweet, do ponto de vista de quem postou o tweet.

A aplicação web utilizada como instrumento de coleta de dados para o Experimento 1 foi modificada. Incluímos duas novas opções de respostas para que os participantes pudessem classificar o tweet como: “Este tweet não tem relação com o governo Jair Bolsonaro” e “Não consigo avaliar ou não entendi este tweet”. A figura 5.3 apresenta as opções de respostas presentes na pesquisa submetida aos participantes durante a execução do Experimento 2. Também ampliamos o limite máximo de tweets avaliados por cada participante, que no Experimento 1, a fim de não ser cansativa para o usuário - havíamos limitado em 50 - para 100 tweets no Experimento 2. A cada 25 tweets avaliados, a aplicação web apresenta um resultado parcial da pesquisa com uma frase com o objetivo de estimular o participante a continuar classificando novos tweets (Figura 5.3).

Figura 5.3: Artefato utilizado pelo Experimento 2 para classificação manual dos tweets.



Fonte: Twitter (2022)

Diferentemente da pesquisa realizada no Experimento 1, na qual os participantes foram selecionados por conveniência a partir dos contatos dos autores, a pesquisa realizada

como parte deste segundo experimento, além de submetida por e-mails para contatos dos autores, foi também submetida por e-mail para os alunos do curso de Bacharelado em Sistemas de Informação e alunos do Programa de Pós-graduação em Informática da UNIRIO. Os e-mails enviados aos participantes continham um link com o endereço da aplicação web que desenvolvemos. A pesquisa foi disponibilizada aos participantes no dia 15 de junho de 2022). A partir de e-mails enviados aos convidados, 86 pessoas participaram respondendo nossa pesquisa. Uma análise sobre os resultados deste processo de avaliação manual é apresentada na seção 5.3.11.

5.3 Análises

Nesta seção consideramos a intensidade dos sentimentos, frequência de palavras e intensidade das emoções para as análises dos dados processados. Além disso, apresentamos os resultados da análise de sentimento realizada manualmente durante nosso segundo experimento.

5.3.1 Intensidades dos sentimentos

Nesta seção utilizamos as ferramentas VADER, Textblob e Polyglot para calcular o sentimento dos tweets. Comparamos os percentuais de cada sentimento com objetivo de entender em que medida os sentimentos negativos, positivos e neutros estão presentes nos grupos de tweets sobre o governo Bolsonaro antes e após os tweets base.

A fim de possibilitar comparação dos percentuais calculados para os tweets sobre o governo antes e após o tweet base, desenvolvemos quatro pares de gráficos setorizados representando os percentuais calculados por cada ferramenta. Um par para os grupos antes e depois utilizando ferramenta de sentimento VADER, representado pela Figura 5.4; Um par para os grupos antes e depois utilizando a ferramenta Textblob, representado pela Figura 5.5; Um par para os grupos antes e depois utilizando a ferramenta Polyglot com textos em inglês, representado pela Figura 5.6; Finalmente um par para os grupos antes e depois utilizando a ferramenta Polyglot com textos em português, representado pela Figura 5.7. Estes pares de gráficos agrupados por ferramenta de análise de sentimentos permitem uma comparação das diferentes abordagens utilizadas para este fim.

Observou-se que, quando comparados os percentuais dos sentimentos positivos, negativos e neutros dos grupos de tweets antes e depois do tweet base calculados pela mesma ferramenta, os percentuais variaram levemente.

Quando olhamos somente para o sentimento “Negativo” nos grupos antes de depois, percebe-se um leve aumento do percentual de negatividade. O aumento da negatividade está presente no cálculo do sentimento realizado com as ferramentas VADER, Textblob e Polyglot (inglês), sendo respectivamente de 0,4%, 0,2% e 0,2%. Apenas o percentual de negatividade calculado pela ferramenta Polyglot (português) apresentou redução da negatividade que foi de 0,1%.

Em relação ao sentimento “Positivo”, observou-se uma redução percentual em todas as ferramentas utilizadas. O percentual de redução da positividade para as ferramentas VADER, Textblob, Polyglot (inglês), Polyglot (português) foram respectivamente: 0,7%; 0,2%; 0,8% e 0,1%. A maior redução de positividade ocorreu com a ferramenta Polyglot (inglês), que foi de 0,8%, passando de 23,3% calculado para o grupo de tweets antes do tweet base para 22,5% para o grupo de tweets após o tweet base.

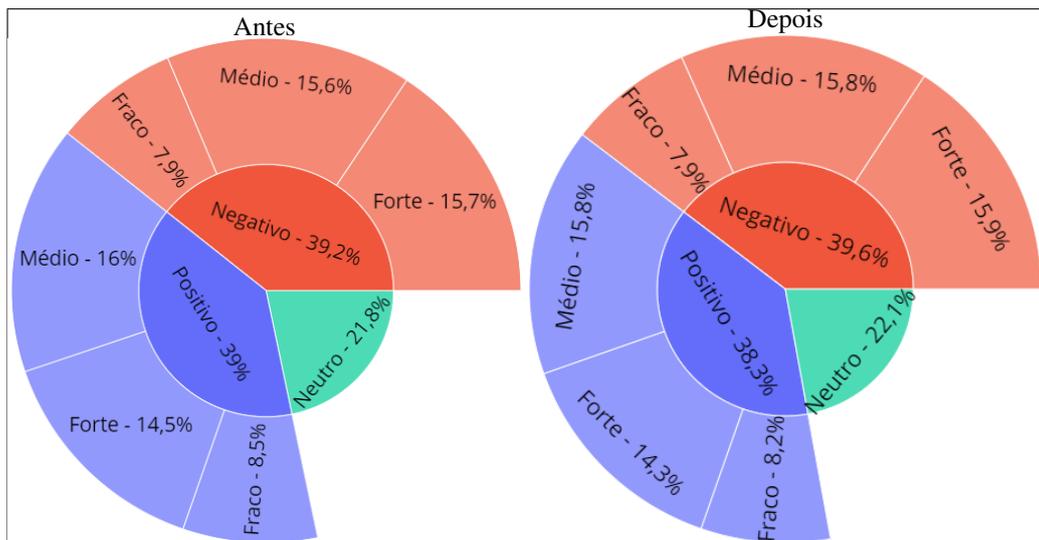
Aplicamos um teste de Mann-Whitney (Wilcoxon) ^{12,13} entre os pares de amostras dos tweets de mesmo sentimento¹⁴ entre os grupos antes e depois e, em todos os casos em que o teste de Mann-Whitney apontou uma diferença estatisticamente significativa entre os pares, executamos um teste Vargha & Delaney’s com objetivo de observar o tamanho de efeito. Em todos os casos obtivemos tamanho de efeito entre 0,49 e 0,50. A proximidade de 0,5 dos valores de tamanho de efeito calculados indica que, apesar de haver uma diferença significativa entre os grupos, essa diferença é considerada pequena. As tabelas com os resultados dos testes estão disponíveis no apêndice deste estudo A.3.

¹²O teste não paramétrico de Mann-Whitney foi aplicado após a constatarmos a ausência de normalidade na distribuição dos dados em todos os grupos de dados testados.

¹³O nível de significância (alfa) utilizado foi de 0,05.

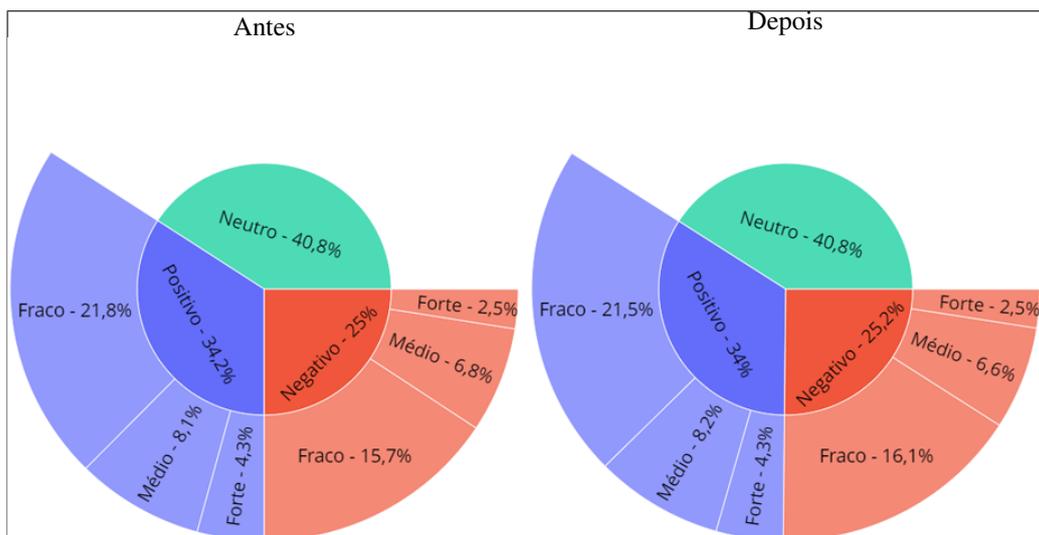
¹⁴Disponibilizamos o dataset utilizado para este teste no endereço: <https://github.com/juniori/IMPACTO_COVID-19_PERCEPCAO_USUARIOS_TWITTER/blob/main/TESTES_ESTADISTICOS>

Figura 5.4: Intensidade dos sentimentos antes e depois do tweet base (VADER)



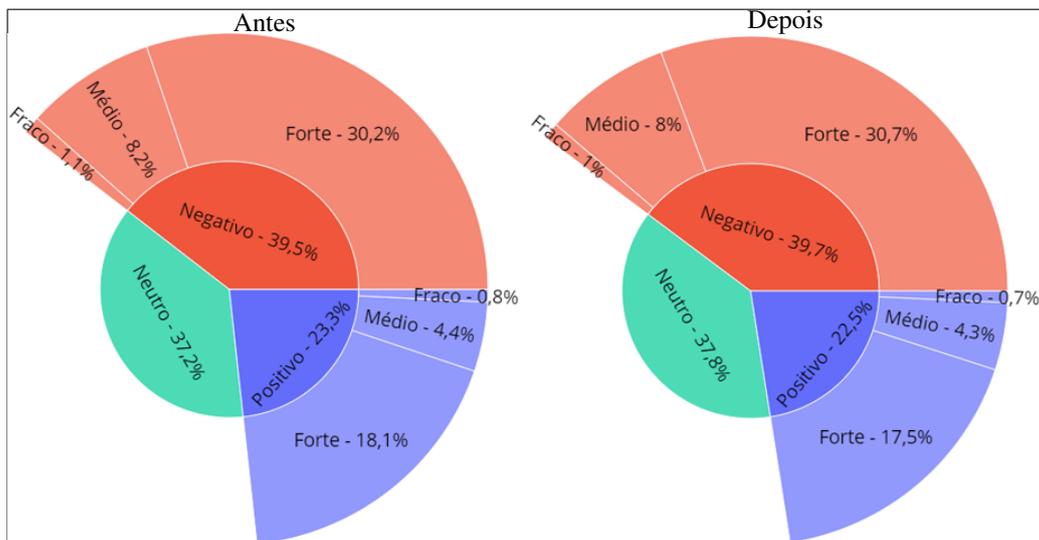
Fonte: Twitter (2022)

Figura 5.5: Intensidade dos sentimentos antes e depois do tweet base (Textblob)



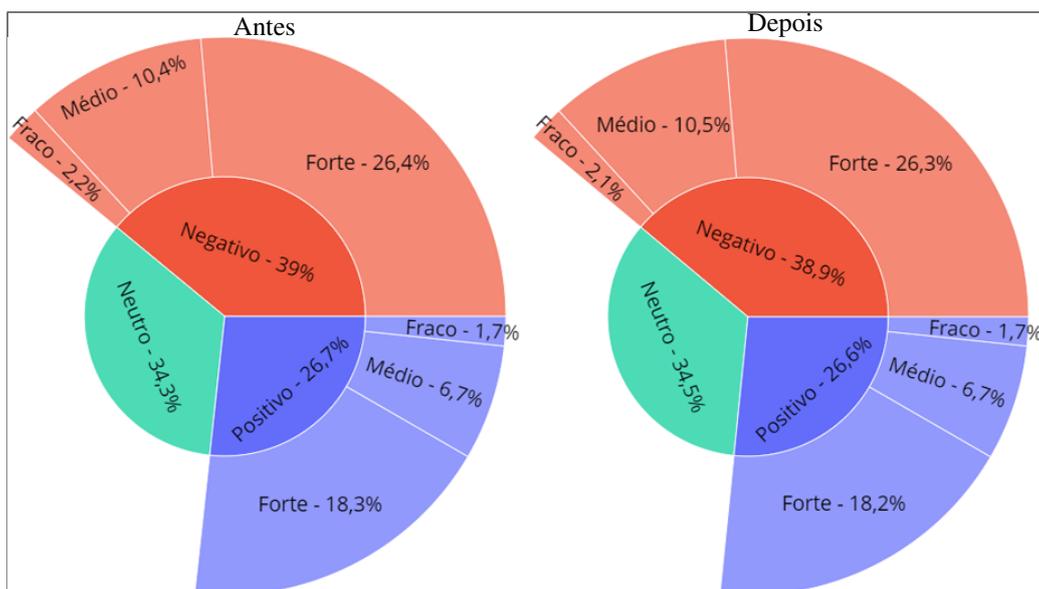
Fonte: Twitter (2022)

Figura 5.6: Intensidade dos sentimentos antes e depois do tweet base (Polyglot - texto em inglês)



Fonte: Twitter (2022)

Figura 5.7: Intensidade dos sentimentos antes e depois do tweet base (Polyglob - texto em português)



Fonte: Twitter (2022)

Tabela 5.3: Percentuais das intensidades dos sentimentos calculados.

Categoria		VADER				Textblob				Polyglot (Inglês)				Polyglot (Português)			
		Antes		Depois		Antes		Depois		Antes		Depois		Antes		Depois	
Negativo	Forte		15,7		15,9		2,5		2,5		30,2		30,7		26,4		26,3
	Médio	39,2	15,6	39,6	15,8	25	6,8	25,2	6,6	39,5	8,2	39,7	8	39	10,4	38,9	10,5
	Fraco		7,9		7,9		15,7		16,1		1,1		1		2,2		2,1
Neutro		21,8		22,1		40,8		40,8		37,2		37,8		34,3		34,5	
Positivo	Forte		14,5		14,3		4,3		4,3		18,1		17,5		18,3		18,2
	Médio	39	16	38,3	15,8	34,2	8,1	34	8,2	23,3	4,4	22,5	4,3	26,7	6,7	26,6	6,7
	Fraco		8,5		8,2		21,8		21,5		0,8		0,7		1,7		1,7

Fonte: O autor (2022).

5.3.2 Quantidade de tweets e intensidade dos sentimentos por usuário

Nesta seção, buscamos entender em que medida a intensidade dos sentimentos está relacionada quantidade de tweets postados por cada usuário entre os grupos de tweets sobre o governo antes e após o tweet base. Para isto, utilizamos as ferramentas de análise de sentimento VADER, Textblob e Polyglot para calcular o sentimento dos tweets.

Com objetivo de comparar dispersão dos dados entre os grupos de tweets sobre o governo antes e após o tweet base, desenvolvemos quatro conjuntos de gráficos de dispersão: (i) um conjunto para os grupos antes e depois utilizando ferramenta de sentimento VADER, representado pela Figura 5.8; (ii) um conjunto para os grupos antes e depois utilizando a ferramenta Textblob, representado pela Figura 5.9; (iii) um conjunto para os grupos antes e depois utilizando a ferramenta Polyglot com textos em inglês, representado pela Figura 5.10; e (iv) um conjunto para os grupos antes e depois utilizando a ferramenta Polyglot com textos em português, representado pela Figura 5.11. Estes conjuntos de gráficos agrupados por ferramenta de análise de sentimentos permitem uma comparação entre os grupos antes e depois do tweet base para as diferentes ferramentas de análise de sentimento utilizadas para este fim. Os gráficos apresentam o número de tweets e a média das intensidades dos sentimentos calculados antes e depois do tweet de base para cada usuário.

As ferramentas de análise de sentimentos utilizadas para este experimento avaliaram os mesmos tweets, sendo assim, a quantidade de tweets apresentados no eixo “y” dos gráficos não varia em função da ferramenta.

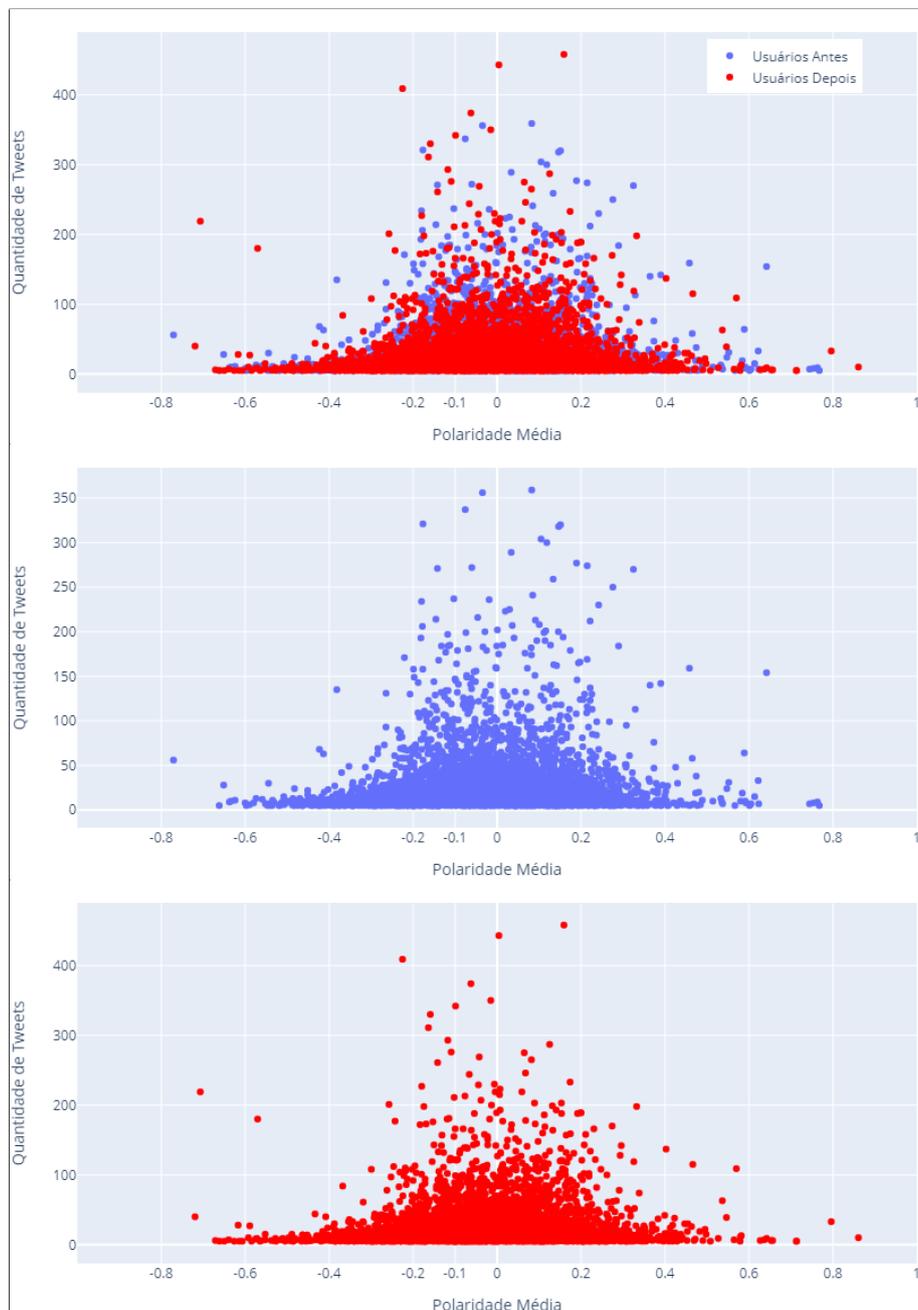
Observou-se que, nos grupos antes e depois do tweet base, a maioria dos usuários postou poucos tweets, enquanto poucos usuários postaram muitos tweets. Conforme a dispersão dos pontos no gráfico, não é possível perceber uma relação clara entre a quantidade de tweets postados pelos usuários e a média de intensidade do sentimento destes tweets. Ao compararmos as médias de tweets por usuário entre os grupos antes e depois

do tweet base, observamos que elas são muito próximas, sendo 27,3 tweets por usuário no grupo antes do tweet base e 27,5 no grupo depois do tweet base.

Quando olhamos para a dispersão dos pontos no eixo “x”, eixo que representa a polarização média do sentimento dos usuários, verifica-se que nos gráficos das ferramentas VADER e Textblob, os pontos concentram-se próximo ao zero, entre -0.2 e 0.2, indicando uma maior tendência aos sentimentos negativo fraco e positivo fraco por usuário. A ferramenta Polyglot apresentou (tanto para os textos avaliados em inglês, quanto para os textos em português) uma dispersão um pouco maior, onde a concentração dos pontos varia entre -0.4 e 0.4, indicando uma tendência aos sentimentos negativo médio e positivo médio, conforme nosso método de categorização apresentado pela Figura 4.3.

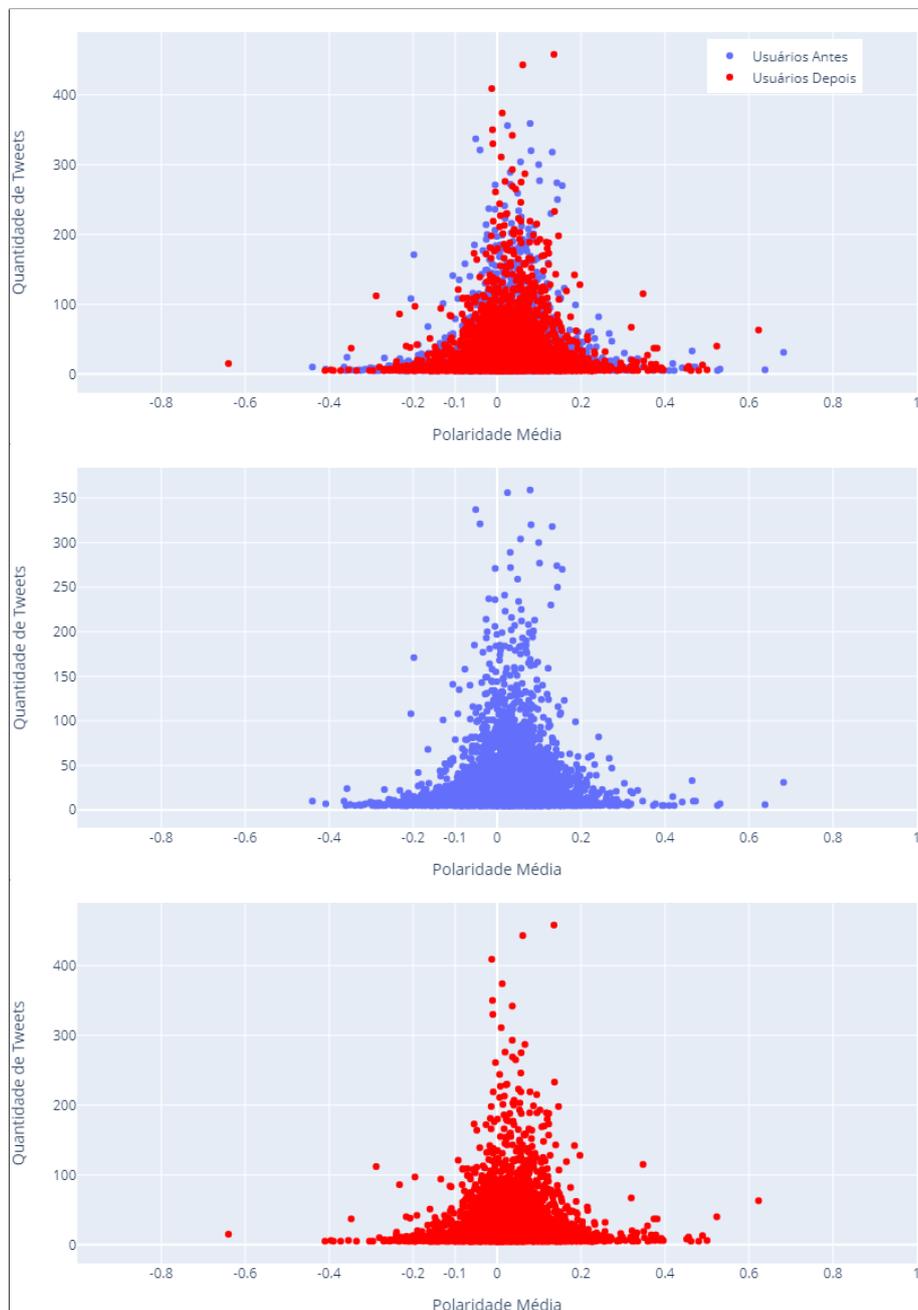
Em cada conjunto de gráficos gerado para cada uma das ferramentas de análise de sentimentos, o primeiro dos três gráficos de dispersão apresenta uma sobreposição dos pontos que representam os usuários nos grupos antes (pontos azuis) e depois do tweet base (pontos vermelhos). A alta frequência de sobreposição dos pontos azuis e vermelhos, indicam que não há diferenças expressivas tanto para média das polaridades dos sentimentos, quanto para a quantidade de mensagens entre os grupos de tweets antes e depois do tweet base.

Figura 5.8: Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base (VADER)



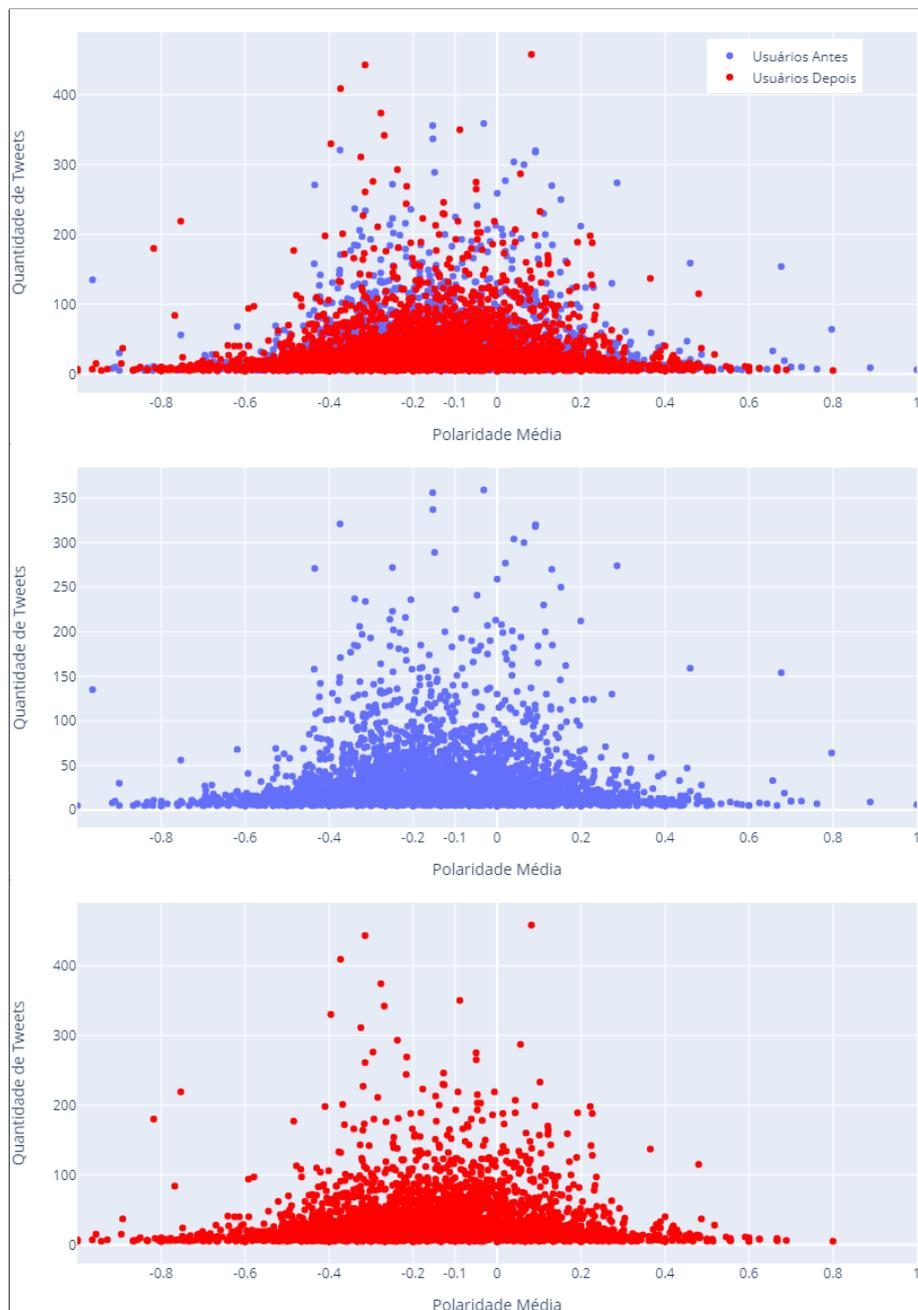
Fonte: Twitter (2022)

Figura 5.9: Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base (Textblob)



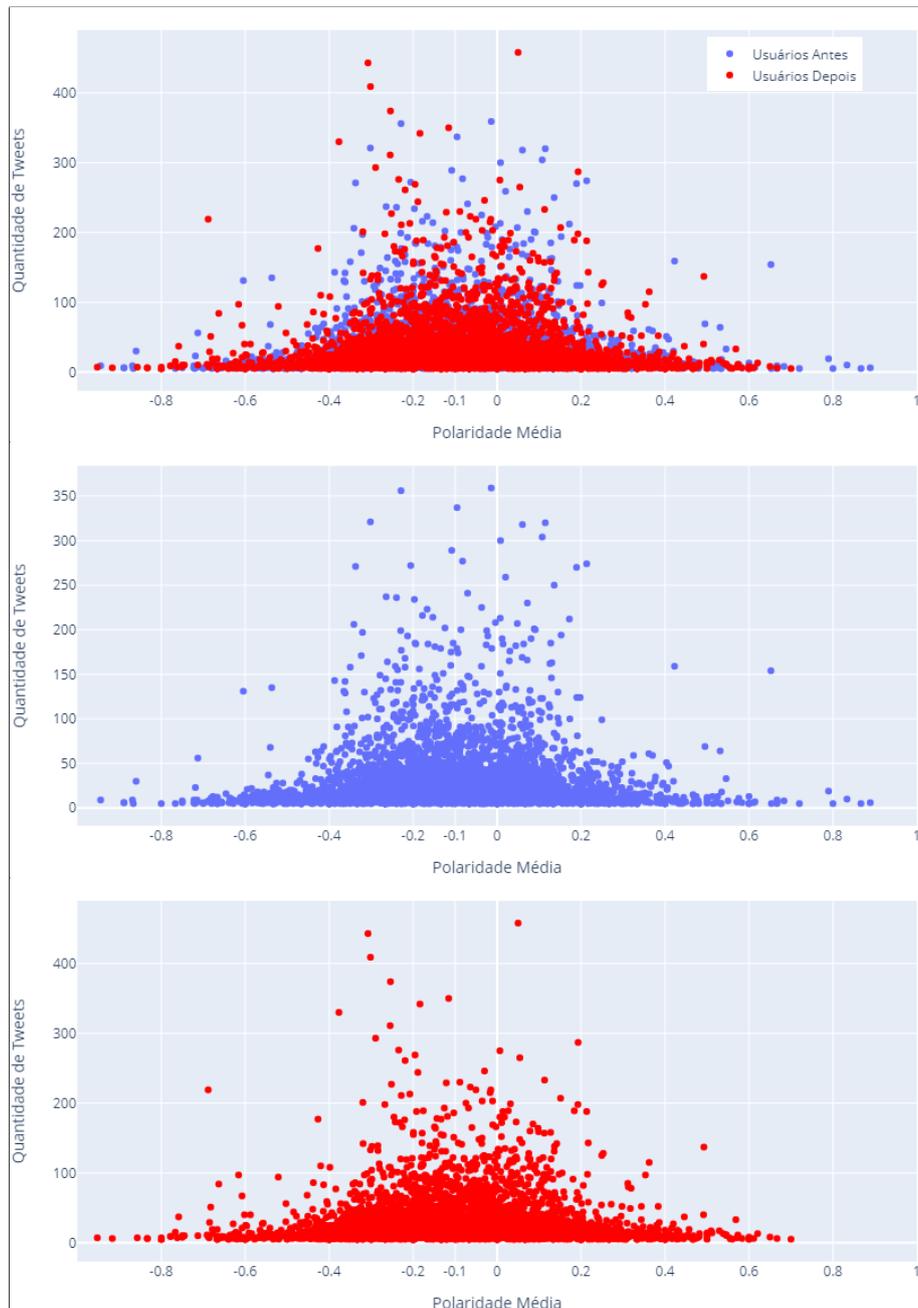
Fonte: Twitter (2022)

Figura 5.10: Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base (Polyglot - texto em inglês)



Fonte: Twitter (2022)

Figura 5.11: Quantidade de tweets e polaridade média dos sentimentos por usuário, antes e depois do tweet base (Polyglot - texto em português)



Fonte: Twitter (2022)

5.3.3 Nuvens de palavras

Nesta seção ampliamos nossa análise realizada no Experimento 1 sobre a frequência com que determinados termos aparecem nos tweets. Neste segundo experimento, além da ferramenta de análise de sentimentos VADER utilizada no Experimento 1 para classificar o sentimento contido nas palavras, incluímos também as ferramentas Textbob e Polyglot.

Com objetivo de comparar a frequência das palavras presentes nos tweets negativos, neutros e positivos antes e após o tweet base, desenvolvemos quatro conjuntos de nuvens de palavras: (i) um conjunto para os grupos antes e depois utilizando ferramenta de sentimento VADER, representado pela Figura 5.12; (ii) um conjunto para os grupos antes e depois utilizando a ferramenta Textblob, representado pela Figura 5.13; (iii) um conjunto para os grupos antes e depois utilizando a ferramenta Polyglot com textos em inglês, representado pela Figura 5.14; e (iv) um conjunto para os grupos antes e depois utilizando a ferramenta Polyglot com textos em português, representado pela Figura 5.15. Estes conjuntos de nuvens de palavras agrupados por ferramenta de análise de sentimentos permitem uma comparação entre os termos mais frequentes antes e depois do tweet base para as diferentes ferramentas de análise de sentimento utilizadas para este fim. Em cada nuvem de palavras, as palavras que apresentam o tamanho maior são as mais frequentes, ao passo que as menores são as menos frequentes. As cores têm um caráter meramente ilustrativo para facilitar a visualização das palavras na nuvem.

Assim como no Experimento 1, neste segundo experimento as nuvens de palavras foram geradas a partir dos tweets previamente submetidos a classificação de sentimentos automática (seção 5.2.2). As palavras negativas foram extraídas dos tweets que foram classificados como negativos, as neutras dos tweets neutros e as positivas extraídas dos tweets positivos.

Nas nuvens de palavras classificadas com a ferramenta VADER, as palavras “fascist”, “Shit”, “death” e “killer”, aparecem nas nuvens de palavras negativas dos grupos “Antes” e “Depois” do tweet base, porém com tamanhos discretamente maiores na nuvem de palavras do grupo “Depois”; as palavras “brazil”, “lula”, “people” e “vaccine” aparecem nas nuvens de palavras neutras de ambos grupos, com tamanhos bem aproximados; as palavras “good”, “god”, “best”, “support” e “like” aparecem nas nuvens de palavras positivas dos grupos “Antes” e “Depois” do tweet base, sendo que as palavras “good” e “best” aparecem discretamente menores, as palavras “good” e “god” aparecem com o mesmo tamanho e a palavra “support” aparece com tamanho discretamente aumentado com relação à nuvem de palavras do grupo “Antes” do tweet base.

As nuvens de palavras classificadas com a ferramenta Textblob apresentaram as palavras negativas “hate”, “bad”, “worst” em destaque no grupo antes do tweet base, que continuaram em destaque também na nuvem de palavras negativas do grupo depois do tweet, onde podemos perceber outros destaques como: “idiot”, “fucking” e “corrupt”. Entre as palavras das nuvens de palavras neutras, as palavras “people”, “Brazil” e “Lula” figuraram em destaque nos grupos antes e depois do tweet base, sem muita alteração em seus tamanhos em ambos grupos. Finalmente, entre as palavras das nuvens de palavras

positivas, destacaram-se as palavras “good”, “best” e “great”, também sem muita variação entre ambos grupos.

Nas nuvens de palavras classificadas com a ferramenta Polyglot (idioma inglês), as palavras “genocide”, “shit”, “bad” e “death”, aparecem nas nuvens de palavras negativas dos grupos antes e depois do tweet base. Estas mesmas palavras, incluindo “fascist”, aparecem com tamanhos discretamente maiores na nuvem de palavras do grupo “Depois”; as palavras “Brazil”, “people” e “Lula” aparecem nas nuvens de palavras neutras de ambos grupos, com tamanhos aproximados; as palavras “good”, “right” e “support” e “like” aparecem nas nuvens de palavras positivas dos grupos antes e depois do tweet base com tamanhos aproximados entre os grupos.

As nuvens de palavras classificadas com a ferramenta Polyglot (idioma português) apresentaram as palavras negativas “contra”, “culpa”, “morte” e “ódio” em destaque no grupo antes do tweet base, estas palavras também aparecerem na nuvem de palavras negativas do grupo depois do tweet, onde outras palavras podem ser percebidas, como: “fascista” e “assassino”, que não aparecem em destaque entre as palavras do grupo “Antes”. Entre as palavras das nuvens de palavras neutras, as palavras “Lula”, “Brazil” e “povo” apareceram com pouca alteração em seus tamanhos nos grupos antes e depois do tweet base. Por fim, entre as palavras das nuvens de palavras positivas, destacaram-se “bem”, “melhor” e “parabéns”, também sem muita variação de tamanho entre ambos grupos.

Quando observadas as nuvens de palavras dos grupos de tweets antes e após o tweet base para um mesmo sentimento, percebe-se que muitas palavras que estão presentes na nuvem do grupo de tweets antes do tweet base também aparecem na nuvem do grupo de palavras depois do tweet base. Na maioria das nuvens, as palavras mais frequentes (as maiores), estão presentes nos dois grupos: “Antes” e “Depois” do tweet base. A ocorrência das mesmas palavras em destaque nos dois grupos indicam que os usuários utilizaram predominantemente as mesmas palavras nos tweets que postaram sobre o governo antes e após ao seu tweet base, em alguns casos com frequências diferentes.

Figura 5.15: Palavras negativas, neutras e positivas, antes e depois do tweet base (Polyglot - texto em português)



Fonte: O autor (2022)

5.3.4 Polaridade média dos sentimentos no período

A presente seção tem como objetivo verificar se há uma tendência dos sentimentos positivos, negativos entre os grupos de tweets antes e após ao tweet base ao longo do tempo.

Utilizamos um conjunto de gráficos para comparar a tendência dos sentimentos entre os grupos de tweets antes e após ao tweet base ao longo do tempo. Um gráfico para representar a tendência dos grupos antes e depois utilizando ferramenta de sentimento VADER, representado pela Figura 5.16; um gráfico para representar a tendência dos grupos antes e depois utilizando ferramenta de sentimento Textblob, representado pela Figura 5.17; um gráfico para representar a tendência dos grupos antes e depois utilizando ferramenta de sentimento Polyglot com textos em inglês, representado pela Figura 5.18; finalmente um gráfico para representar a tendência dos grupos antes e depois utilizando ferramenta de sentimento Polyglot com textos em português, representado pela Figura 5.19. Nos gráficos, a polaridade média dos sentimentos dos tweets presentes no grupo antes do tweet base estão representadas na cor azul e na cor vermelha a polaridade média dos sentimentos

dos tweets presentes no grupo depois do tweet base.

Nos gráficos observa-se que as linhas que representam a média da polaridade dos sentimentos do grupo de tweets antes do tweet base (linhas vermelhas) e do grupo de tweets após o tweet base (linhas azuis) não iniciam no mesmo mês e também não terminam no mesmo mês. A justificativa para isto é que o primeiro tweet base foi coletado em janeiro de 2021 e o último em dezembro de 2021, sendo assim, antes do mês de janeiro coletamos tweets apenas para o grupo antes do tweet base. O mesmo ocorre após ao mês de dezembro de 2021, onde coletamos tweets apenas do grupo depois o tweet base.

O conjunto de gráficos mostram tendências similares. Destacamos o mês de julho, onde a maioria dos gráficos apresentam o início de um movimento tendendo ao sentimento mais positivo e o mês de outubro, onde os gráficos apresentam uma queda relativamente acentuada da positividade.

Figura 5.16: Polaridade média dos sentimentos no período (VADER)



Fonte: O autor (2022).

Figura 5.17: Polaridade média dos sentimentos no período (Textblob)



Fonte: O autor (2022).

Figura 5.18: Polaridade média dos sentimentos no período (Polyglot - texto em inglês)



Fonte: O autor (2022).

Figura 5.19: Polaridade média dos sentimentos no período (Polyglot - texto em português)



Fonte: O autor (2022).

5.3.5 Análise da subjetividade média no período

Esta seção analisa a intensidade dos sentimentos considerando o grau de subjetividade extraídos dos tweets. Considerando que frases subjetivas geralmente se referem a opiniões, emoções ou julgamentos (KHARDE; SONAWANE et al., 2016), analisamos as intensidades dos sentimentos para os tweets mais subjetivos.

Utilizamos a ferramenta Textblob para calcular a subjetividade presente nas mensagens dos tweets dos grupos antes e depois do tweet base. Entre as ferramentas de análise de sentimento que utilizamos neste estudo, apenas o Textblob disponibiliza uma função capaz de inferir a quantidade de subjetividade presente no texto avaliado. Esta função recebe como parâmetro o texto a ser avaliado e retorna um número entre 0 e 1, sendo 0 muito objetivo e 1 muito subjetivo¹⁵. A figura A.3 apresenta um exemplo de chamada à função do Textblob responsável por calcular a subjetividade presente em um texto.

O gráfico da figura 5.20 apresenta a subjetividade média por mês calculada para os tweets dos grupos antes e depois do tweet base. Neste gráfico as médias do cálculo de subjetividade para os tweets dos grupos antes e depois do tweet base estão representadas respectivamente pelas cores azul e vermelha.

No gráfico da figura 5.20, observa-se que a linha que representa a média da subjetividade dos tweets do grupo antes do tweet base (linha vermelha) e do grupo de tweets após o tweet base (linha azul) não iniciam no mesmo mês e também não terminam no mesmo mês. A justificativa para isto é que o primeiro tweet base foi coletado em janeiro de 2021

¹⁵<<https://textblob.readthedocs.io/en/dev/quickstart.html>>

e o último em dezembro de 2021, sendo assim, antes do mês de janeiro coletamos tweets apenas para o grupo antes do tweet base. O mesmo ocorre após ao mês de dezembro de 2021, onde coletamos tweets apenas do grupo depois o tweet base.

Figura 5.20: Subjetividade média no período



Fonte: O autor (2022).

Com objetivo de aprofundar nossa análise, classificamos os tweets dos grupos antes e depois do tweet base de acordo com a subjetividade calculada em três categorias: “Subjetividade Fraca”, “Subjetividade Média” e “Subjetividade Forte”¹⁶, conforme ilustrado na Figura 5.21. A tabela 5.4 apresenta, para cada grupo de tweets, a quantidade de tweets classificados em cada categoria.

Tabela 5.4: Classificação dos tweets dos grupos antes e depois do tweet base de acordo com a subjetividade.

Subjetividade	Antes		Depois	
	n	%	n	%
Fraca	70.229	52,35	71.077	52,46
Média	37.376	27,86	37.675	27,81
Forte	26.555	19,79	26.728	19,73

Fonte: O autor (2022).

¹⁶A escolha sobre os limites para os níveis de subjetividade foi definida de maneira arbitrária, de modo a dividirmos o intervalo entre 0 e 1 em 3 categorias.

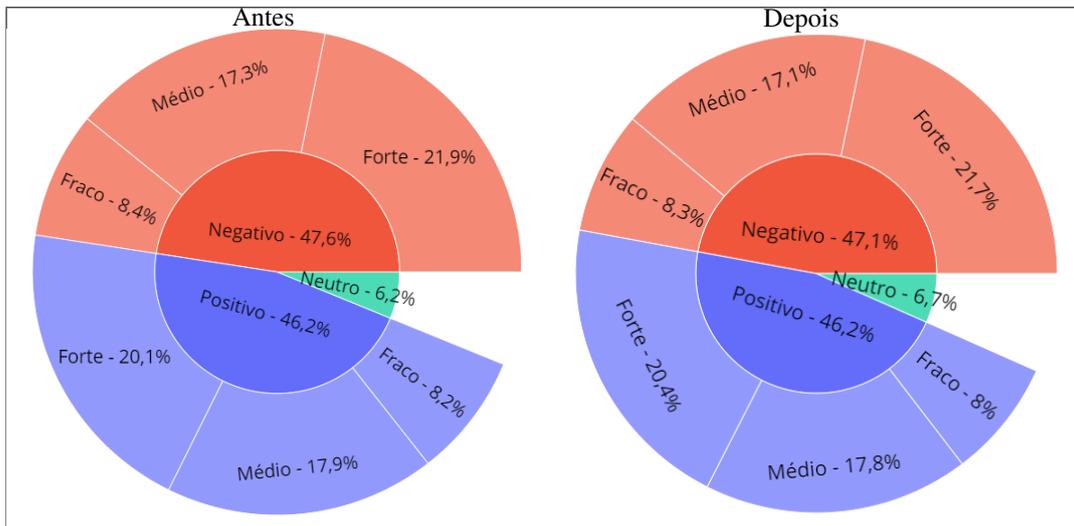
Figura 5.21: Método utilizado para categorização da subjetividade calculada.

```
def subjectivity_to_categ(subjectivity):  
    if (subjectivity <= 0.3):  
        return "Fraca"  
    elif (intensity > 0.3 and intensity <= 0.6):  
        return "Média"  
    elif (intensity > 0.6 and intensity <= 1.0):  
        return "Forte"
```

Fonte: O autor (2022).

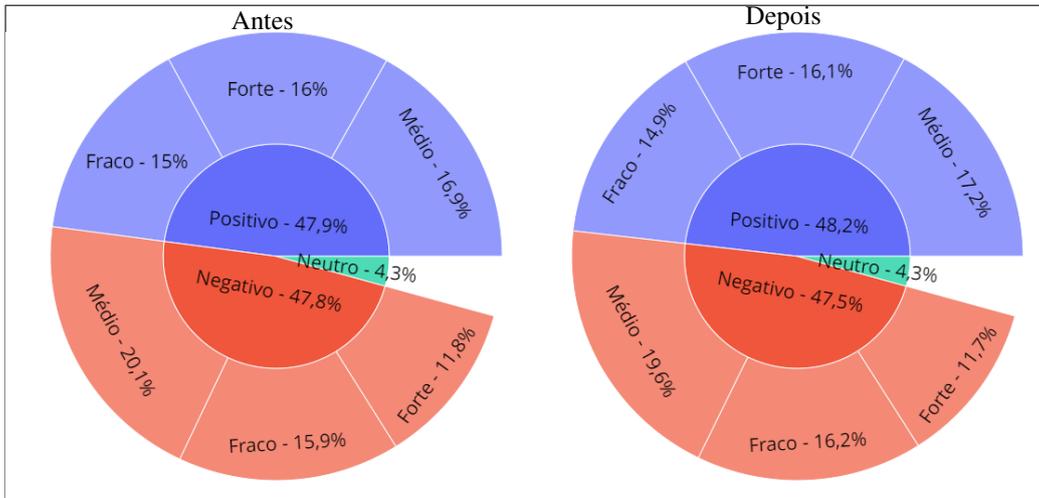
Após a classificação dos tweets em categorias de acordo com a subjetividade (tabela 5.4), consideramos apenas os tweets categorizados com “Subjetividade Forte” e desenvolvemos quatro pares de gráficos setorizados representando os percentuais dos sentimentos calculados por cada ferramenta sobre estes tweets: (i) um par para os grupos antes e depois utilizando ferramenta de sentimento VADER, representado pela Figura 5.22; (ii) um par para os grupos antes e depois utilizando a ferramenta Textoblob, representado pela Figura 5.23; (iii) um par para os grupos antes e depois utilizando a ferramenta Polyglot com textos em inglês, representado pela Figura 5.24; e (iv) um par para os grupos antes e depois utilizando a ferramenta Polyglot com textos em português, representado pela Figura 5.25. Estes pares de gráficos agrupados por ferramenta de análise de sentimentos permitem uma comparação das diferentes abordagens utilizadas para este fim.

Figura 5.22: Intensidade dos sentimentos dos tweets classificados com subjetividade forte antes e depois do tweet base (VADER)



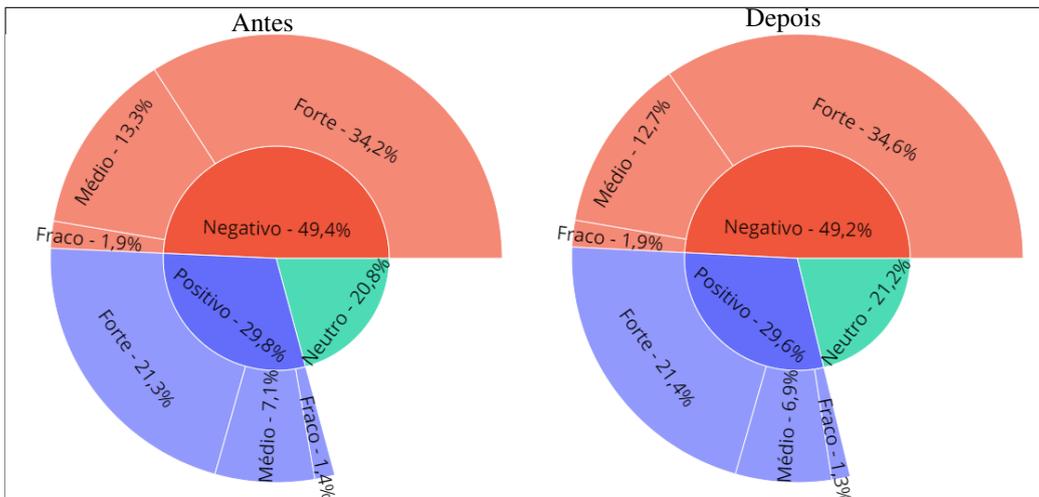
Fonte: Twitter (2022)

Figura 5.23: Intensidade dos sentimentos dos tweets classificados com subjetividade forte antes e depois do tweet base (Textblob)



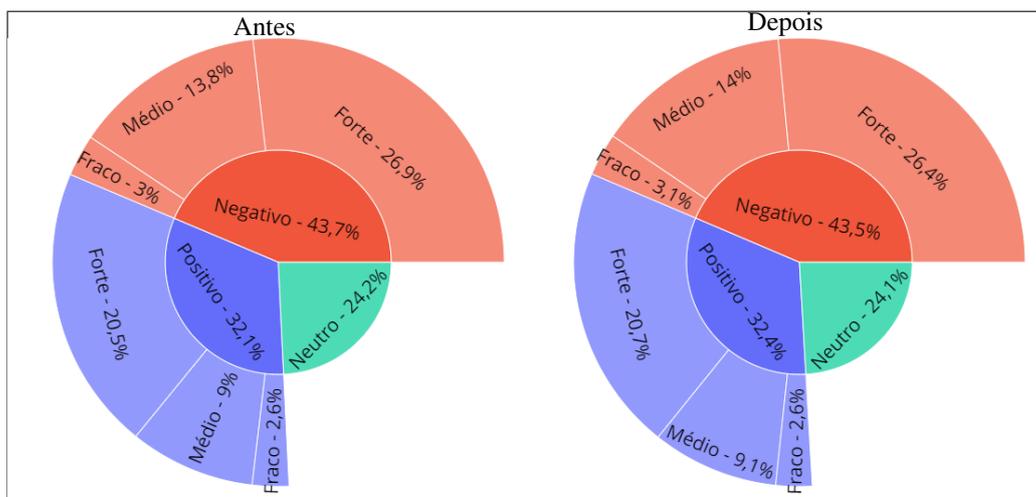
Fonte: Twitter (2022)

Figura 5.24: Intensidade dos sentimentos dos tweets classificados com subjetividade forte antes e depois do tweet base (Polyglot - texto em inglês)



Fonte: Twitter (2022)

Figura 5.25: Intensidade dos sentimentos dos tweets classificados com subjetividade forte antes e depois do tweet base (Polyglob - texto em português)



Fonte: Twitter (2022)

Tabela 5.5: Percentuais das intensidades dos sentimentos calculados a partir dos tweets classificados com subjetividade forte.

Categoria	VADER				Textblob				Polyglot (Inglês)				Polyglot (Português)			
	Antes		Depois		Antes		Depois		Antes		Depois		Antes		Depois	
Negativo	Forte	21,9	21,7	48	11,8	11,7	49,4	34,2	34,6	43,7	26,9	43,5	26,4			
	Médio	47,6	17,3	47,1	17,1	19,6	49,4	13,3	12,7	43,7	13,8	43,5	14			
	Fraco	8,4	8,3	4,3	15,9	16,2	20,8	1,9	1,9	24,2	3	24,1	3,1			
Neutro	6,2	6,7	4,3	4,3	20,8	21,2	20,8	21,2	24,2	24,2	24,1	24,1	24,1			
Positivo	Forte	20,1	20,4	47,9	16	16,1	29,8	21,3	21,4	32,1	20,5	32,4	20,7			
	Médio	46,2	17,9	46,2	17,8	17,2	29,8	7,1	6,9	32,1	9	32,4	9,1			
	Fraco	8,2	8	4,3	15	14,9	29,8	1,4	1,3	24,2	2,6	24,1	2,6			

Fonte: O autor (2022).

5.3.6 Relação dos sentimentos e número de casos e mortes provocados pela Covid-19

Nesta seção analisamos se os sentimentos estão relacionados ao número de casos e mortes provocados pela Covid-19.

Na data em que este trabalho foi escrito, o ministério da saúde brasileiro já havia disponibilizado os números de novos casos e óbitos provocados pela Covid-19 no Brasil para todo ano de 2021. Com o objetivo de examinar em que medida os sentimentos estão relacionados aos números de casos e mortes provocados pela Covid-19, desenvolvemos dois gráficos (Figuras 5.26 e 5.27) que permitem confrontarmos visualmente a polaridade média dos sentimentos com os números de novos casos e óbitos divulgados pelo ministério da saúde do Brasil¹⁷ sumarizados por mês. A tabela 5.6 apresenta a polaridade média

¹⁷Os números de novos casos e mortes provocadas pela Covid-19 foram obtidos por meio do download

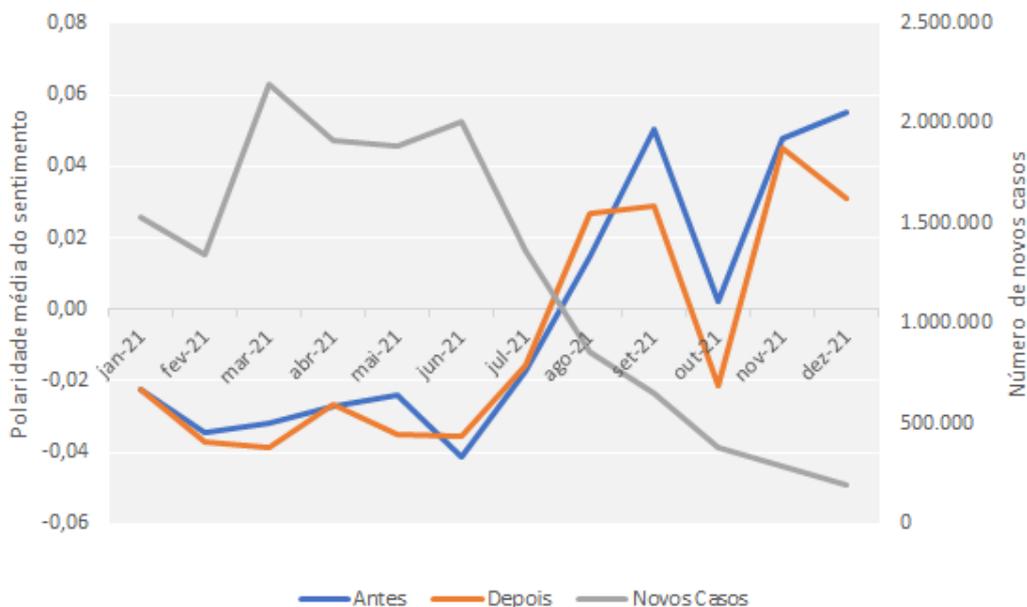
dos sentimentos calculados a partir dos grupos antes e depois do tweet base e também os números de novos casos e novos óbitos provocados pela pandemia da Covid-19 durante o ano de 2021.

Diante da similaridade entre as médias da polaridade dos sentimentos no período, calculadas pelas diferentes ferramentas, que foram apresentadas na seção 5.3.4, limitamos a análise desta seção aos tweets classificados pela ferramenta VADER. O motivo da escolha pelo VADER é que ele foi a ferramenta, entre todas as outras utilizadas neste estudo, que obteve o maior número de correspondências quando comparamos as classificações automáticas com as manuais. A seção 7.2 apresenta uma comparação entre as classificações automáticas de sentimentos realizadas pelas diferentes ferramentas e a classificação manual realizadas por este estudo.

O gráfico representado pela figura 5.26, apresenta os meses do ano de 2021 em seu eixo “x” e dois eixos “y”, o primário e secundário. O eixo “y” primário, à esquerda do gráfico, está relacionado à polaridade dos sentimentos e o eixo “y” secundário, à direita do gráfico, está relacionado ao número de novos casos de Covid-19. Da mesma forma, o gráfico representado pela figura 5.26 também apresenta um eixo “x” e dois eixos “y”. Entretanto seu eixo “y” secundário está relacionado ao número de novos óbitos causados pela Covid-19.

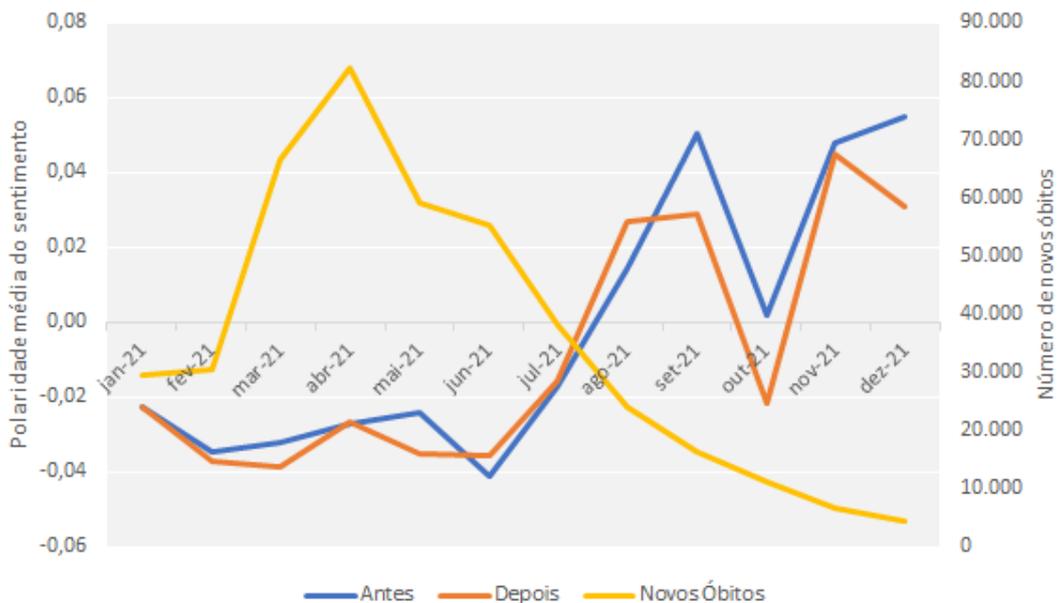
de arquivos no formato “csv” que foram disponibilizados pelo ministério da saúde no endereço: <<https://infoms.saude.gov.br>>

Figura 5.26: Polaridade média dos sentimentos (VADER) e números de novos casos de Covid-19 por mês



Fonte: O autor (2022). Os dados relacionados aos novos casos de Covid-19 no Brasil foram retirados do site do ministério da saúde do Brasil em 06/03/2022.

Figura 5.27: Polaridade média dos sentimentos (VADER) e números de óbitos causados pela Covid-19 por mês



Fonte: O autor (2022). Os dados relacionados aos novos óbitos causados pela Covid-19 no Brasil foram retirados do site do ministério da saúde do Brasil em 06/03/2022.

Tabela 5.6: Polaridade dos sentimentos calculados e números de novos casos e novos óbitos provocados pela pandemia da Covid-19.

	Polaridade média do sentimento (VADER)		Números da Pandemia	
	Antes	Depois	Novos Casos	Novos Óbitos
jan/2021	-0,02	-0,02	1.528.758	29.555
fev	-0,03	-0,04	1.346.528	30.438
mar	-0,03	-0,04	2.197.488	66.573
abr	-0,03	-0,03	1.910.264	82.266
mai	-0,02	-0,03	1.886.543	59.010
jun	-0,04	-0,04	2.011.587	55.275
jul	-0,02	-0,02	1.360.714	38.304
ago	0,01	0,03	859.015	24.043
set	0,05	0,03	650.203	16.336
out	0,00	-0,02	383.782	11.075
nov	0,05	0,05	283.604	6.857
dez/2021	0,06	0,03	193.062	4.375

Fonte: O autor (2022). Os dados relacionados aos novos óbitos causados pela Covid-19 no Brasil foram retirados do site do ministério da saúde do Brasil em 06/03/2022.

5.3.7 Análise das emoções

Nesta seção utilizamos o pacote Syuzhet¹⁸ da linguagem R para calcular as emoções dos tweets. Comparamos as pontuações de cada emoção com objetivo de entender, além dos sentimentos positivos, negativos e neutros, em que medida emoções como “raiva”, “expectativa”, “nojo”, “medo”, “alegria”, “tristeza”, “surpresa”, “confiança” estão presentes nos grupos de tweets sobre o governo antes e após os tweets base.

Para calcular as emoções presentes nos tweets utilizamos a função `get_nrc_sentiment` da biblioteca Syuzhet. A função `get_nrc_sentiment` implementa o dicionário NRC Emotion Lexicon¹⁹ que é composto por uma lista de palavras em inglês, e suas respectivas traduções em mais de 100 idiomas, associadas com oito emoções básicas “raiva”, “expectativa”, “nojo”, “medo”, “alegria”, “tristeza”, “surpresa”, “confiança” e dois sentimentos (negativo e positivo). As anotações do NRC Emotion Lexicon foram feitas manualmente por crowdsourcing (MOHAMMAD; TURNEY, 2010). A função `get_nrc_sentiment` recebe como parâmetros o texto e o idioma no qual o texto deve ser avaliado e retorna

¹⁸<<https://cran.r-project.org/web/packages/syuzhet/index.html>>

¹⁹<<https://saifmohammad.com/WebPages/NRC-Emotion-Lexicon.htm>>

um dataframe onde cada coluna representa uma emoção com uma pontuação indicando a força da emoção presente naquele texto. A figura 5.28 exemplifica a execução da função `get_nrc_sentiment` e apresenta o conteúdo do dataframe resultante.

Figura 5.28: Exemplo de chamada à função `get_nrc_sentiment` do pacote `Syuzhet`

```
library(syuzhet)

sentence = "People of God help our president build a better Brazil"

df_en = get_nrc_sentiment(sentence, language = "english")

print(df_en)
```

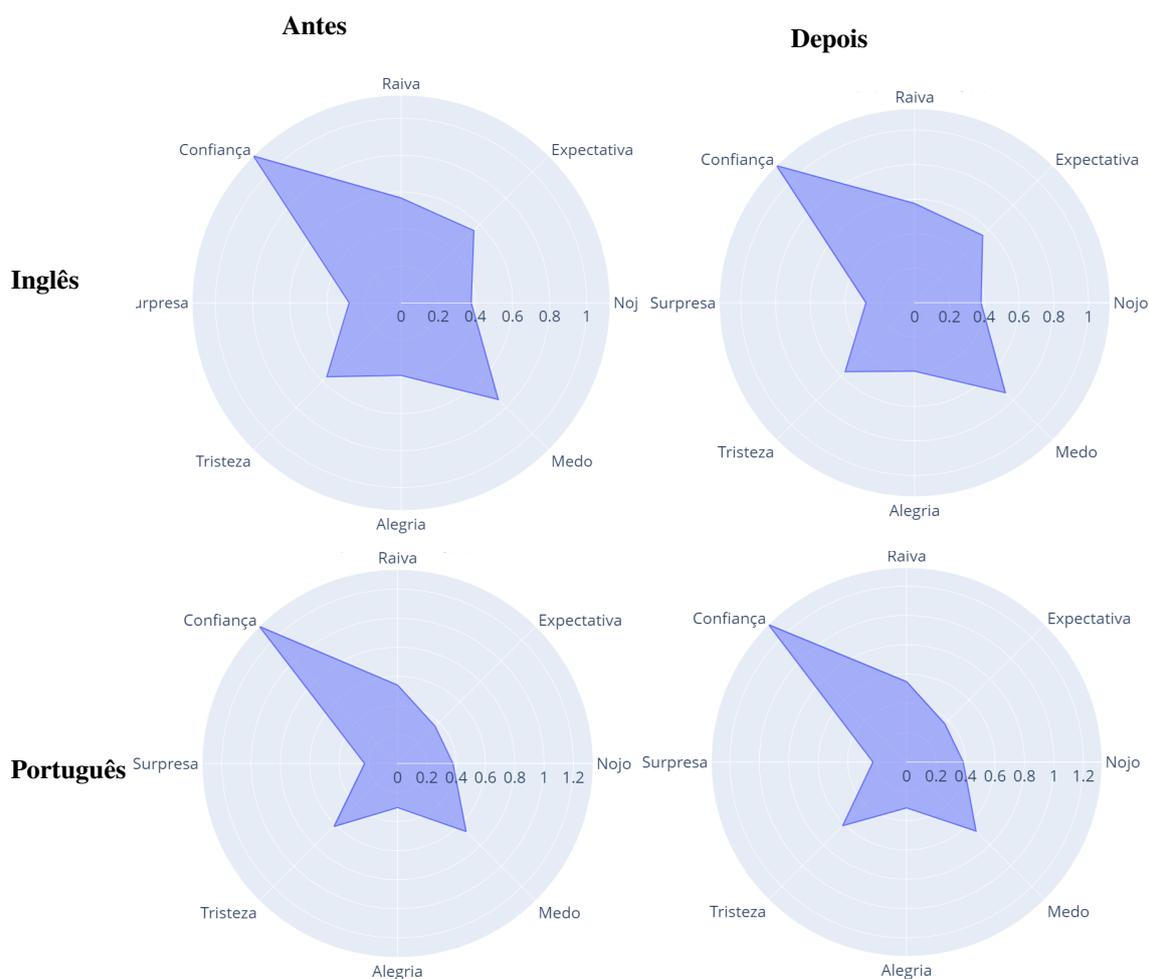
	anger	anticipation	disgust	fear	joy	sadness	surprise	trust	negative	positive
	0	1	0	1	1	0	0	2	0	3

Fonte: O autor (2022).

Os gráficos (Figura 5.29) apresentam as médias das emoções presentes nos tweets dos grupos antes e depois do tweet que foram calculadas a partir da função `get_nrc_sentiment`. Primeiro, para cada grupo, executamos a função `get_nrc_sentiment` para calcular a presença das oito emoções correspondentes em cada tweet nos idiomas inglês e português. Em seguida, calculamos a média para cada uma das emoções presentes em cada grupo.

A tabela 5.7 apresenta as médias das emoções calculadas para cada grupo nos idiomas inglês e português.

Figura 5.29: Emoções presentes nos grupos antes e depois do tweet base



Fonte: O autor (2022)

Tabela 5.7: Média das emoções calculadas

Idioma	Grupo	Emoções							
		Raiva	Expectativa	Nojo	Medo	Alegria	Tristeza	Surpresa	Confiança
Inglês	Antes	0,568	0,554	0,378	0,740	0,392	0,660	0,280	1,125
	Depois	0,575	0,552	0,382	0,737	0,396	0,565	0,280	1,123
Português	Antes	0,540	0,362	0,379	0,662	0,303	0,613	0,225	1,334
	Depois	0,547	0,367	0,385	0,666	0,314	0,614	0,229	1,325

Fonte: O autor (2022).

5.3.8 Análise das emoções presentes entre os sentimentos negativos, positivos e neutros

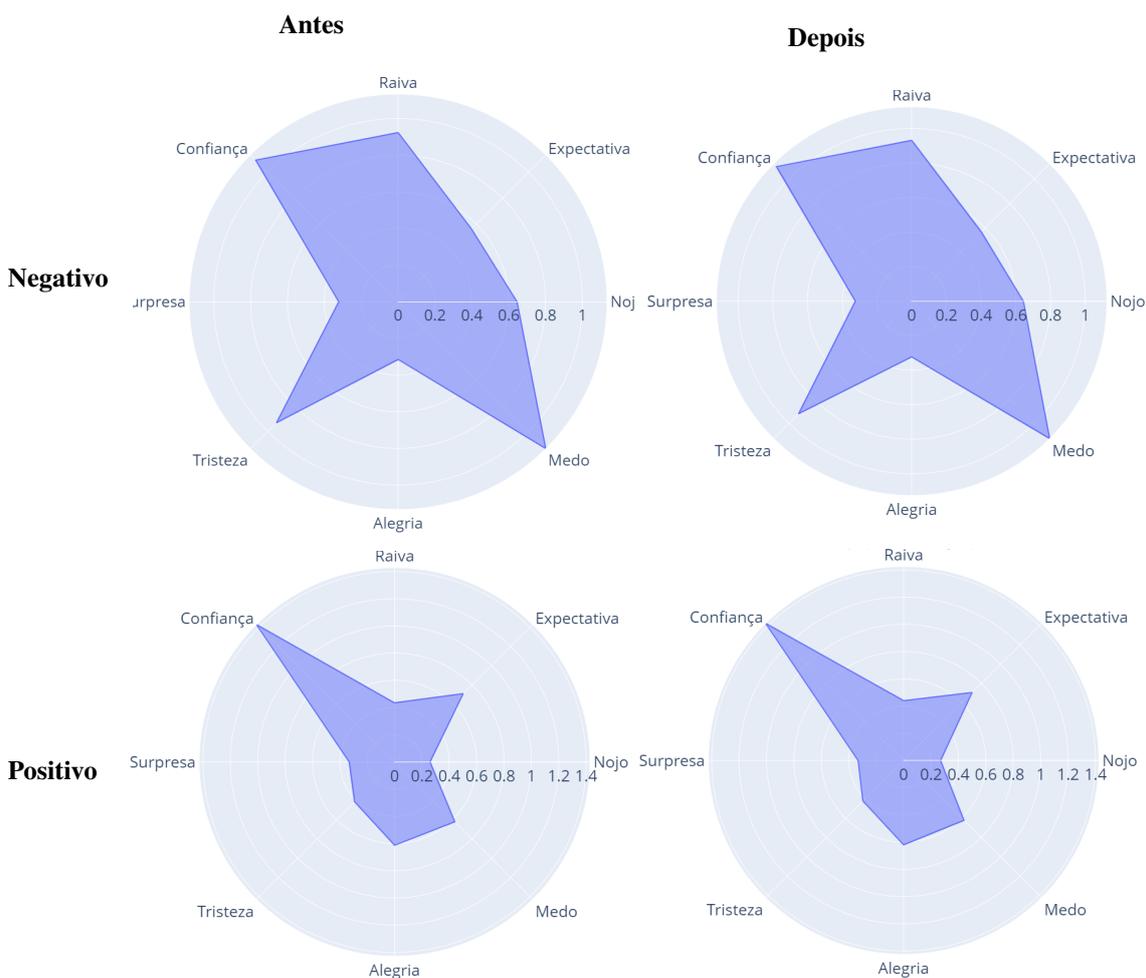
Nesta seção aprofundamos nossa análise realizada na seção anterior (5.3.7) com o propósito de verificar em que medida as mensagens positivas estão ligadas à alegria, enquanto as negativas estão ligadas a raiva medo e tristeza.

Para esta análise, consideramos os tweets dos grupos antes e depois do tweet base e as classificações de sentimentos calculados a partir das ferramentas VADER e Polyglot (texto em português). Para classificação das emoções utilizamos a função `get_nrc_sentiment` da biblioteca Syuzhe, da mesma maneira como as emoções dos tweets da seção anterior (5.3.7) foram classificados.

A fim de possibilitar comparação da intensidade das emoções presentes nas mensagens positivas e negativas entre os grupos antes e depois do tweet base, desenvolvemos dois conjuntos de gráficos: um conjunto de gráficos (Figura 5.30) para representar as médias das emoções calculadas a partir das mensagens que foram traduzidas para o inglês e outro conjunto de gráficos (Figura 5.31) para representar as médias das emoções calculadas a partir das mensagens em português.

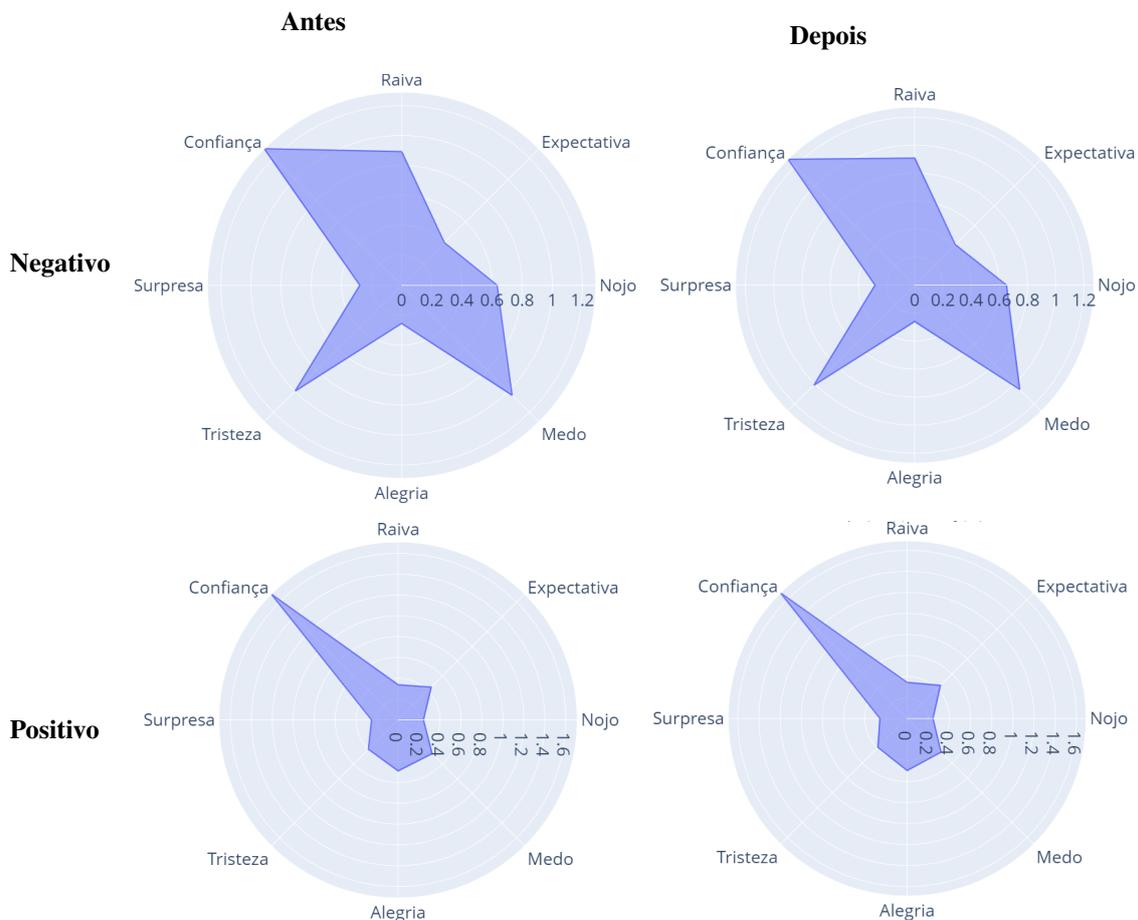
A tabela 5.8 apresenta as médias das emoções presentes em cada sentimento, calculadas para cada grupo nos idiomas inglês e português.

Figura 5.30: Emoções presentes nos grupos antes e depois do tweet base (Syuzhet Inglês - VADER)



Fonte: O autor (2022)

Figura 5.31: Emoções presentes nos grupos antes e depois do tweet base (Syuzhet Português - Polyglot)



Fonte: O autor (2022)

Tabela 5.8: Média das emoções calculadas para cada sentimento

		Emoções								
Idioma	Grupo	Sentimento	Raiva	Expectativa	Nojo	Medo	Alegria	Tristeza	Surpresa	Confiança
Inglês	Antes	Negativo	0,923	0,563	0,645	1,133	0,315	0,934	0,322	1,092
		Neutro	0,166	0,260	0,106	0,242	0,138	0,175	0,112	0,640
		Positivo	0,434	0,709	0,259	0,622	0,613	0,414	0,332	1,428
	Depois	Negativo	0,931	0,567	0,644	1,125	0,323	0,923	0,325	1,102
		Neutro	0,172	0,260	0,108	0,244	0,140	0,175	0,110	0,640
		Positivo	0,440	0,707	0,270	0,622	0,620	0,421	0,332	1,424
Português	Antes	Negativo	0,893	0,402	0,635	1,038	0,255	0,998	0,277	1,288
		Neutro	0,296	0,253	0,194	0,392	0,214	0,341	0,143	1,096
		Positivo	0,338	0,446	0,242	0,459	0,489	0,399	0,254	1,708
	Depois	Negativo	0,907	0,408	0,651	1,054	0,260	1,010	0,281	1,270
		Neutro	0,299	0,261	0,193	0,393	0,234	0,342	0,149	1,106
		Positivo	0,344	0,445	0,244	0,453	0,495	0,390	0,257	1,690

Fonte: O autor (2022).

5.3.9 Intensidade dos sentimentos entre os diferentes graus de gravidade relatados

Na presente seção buscamos identificar se há uma mudança dos sentimentos das pessoas entre os diferentes graus de gravidade dos relatos.

Para esta análise, primeiramente rotulamos os tweets base de cada usuário de acordo com o grau de gravidade dos relatos contidos neles. Utilizamos os seguintes critérios para rotulação destes tweets: i) tweets que continham as palavras “teve”, “pegou”, “curado”, “curou” ou “melhorou”, foram rotulados como “Grau Baixo”; ii) tweets que continham as palavras “internado”, “teve alta” ou “recebeu alta”, foram rotulados como “Grau Médio”; iii) tweets que continham as palavras “morreu” ou “faleceu”, foram rotulados como “Grau alto”. Nos casos em que o tweet possuía palavras comuns ao conjunto de palavras de diferentes rótulos (Figura 5.32), prevaleceu o rótulo de maior grau. Todos os tweets base foram rotulados, pois todas as palavras que utilizamos nos conjuntos de palavras de cada rótulo fazem parte da string de busca que utilizamos para coletar os tweets base. Ao término da etapa de rotulação dos tweets base conforme o grau de gravidade dos relatos, propagamos os rótulos atribuídos a cada tweet base para os tweets dos grupos antes e depois do mesmo usuário. Finalmente calculamos os percentuais para cada sentimento dentro dos diferentes graus de gravidade para os grupos antes e depois do tweet base. Para esta análise utilizamos a classificação dos sentimentos realizada com o VADER. O motivo da escolha pelo VADER é que ele foi a ferramenta, entre todas as outras utilizadas neste estudo, que obteve o maior número de correspondências quando comparamos as classificações automáticas com as manuais. A seção 7.2 apresenta uma comparação entre as classificações automáticas de sentimentos realizadas pelas diferentes ferramentas e a classificação manual realizadas por este estudo.

A fim de possibilitar comparação da intensidade dos sentimentos presentes nos tweets entre os graus de gravidade, desenvolvemos três pares de gráficos setorizados representando os percentuais dos sentimentos calculados para cada grau de gravidade: (i) um par para os grupos antes e depois para o grau de gravidade baixo, representado pela Figura 5.33; (ii) um par para os grupos antes e depois para o grau médio, representado pela Figura 5.34; e (iii) um par para os grupos antes e depois para o grau alto, representado pela Figura 5.35. Estes pares de gráficos agrupados por grau de gravidade permitem uma comparação da intensidade dos sentimentos nos diferentes graus de gravidade.

A tabela 5.9 apresenta os percentuais de cada sentimento, calculadas para cada grau de gravidade.

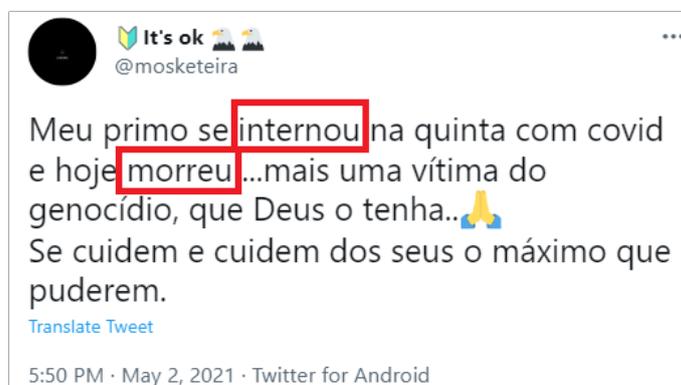
Aplicamos um teste de Mann-Whitney (Wilcoxon)^{20,21} entre os pares de amostras dos tweets de mesmo sentimento²², dentro de cada um dos graus de gravidade, entre os grupos antes e depois. O resultado do teste apontou uma diferença estatisticamente significativa na comparação dos percentuais do sentimento “Positivo Fraco” antes e depois, pra os relatos com grau de gravidade “Médio”, no entanto, com um tamanho de efeito pequeno 0,53. As tabelas com os resultados dos testes estão disponíveis no apêndice deste estudo A.4.

Tabela 5.9: Percentuais das intensidades dos sentimentos calculados para cada grau de gravidade.

Categoria		Grau Baixo				Grau Médio				Grau Alto			
		Antes		Depois		Antes		Depois		Antes		Depois	
Negativo	Forte	38,3	15,3	38,7	15,3	38,8	16	39,6	15,8	40,7	16,1	40,8	16,6
	Médio		15,2		15,5		15,5		15,7		16,3		16,2
	Fraco		7,8		7,9		7,3		8,1		8,3		8
Neutro		21,6		22,2		22		21,9		21,7		22,1	
Positivo	Forte	40,1	15,1	39,1	14,9	39,2	14,4	38,5	14,1	37,6	13,8	37,1	13,5
	Médio		16,4		16		16,2		16,6		15,3		15,4
	Fraco		8,6		8,2		8,6		7,8		8,5		8,2

Fonte: O autor (2022).

Figura 5.32: Exemplo de tweet base contendo palavras comuns ao conjunto de palavras de diferentes graus de gravidade.



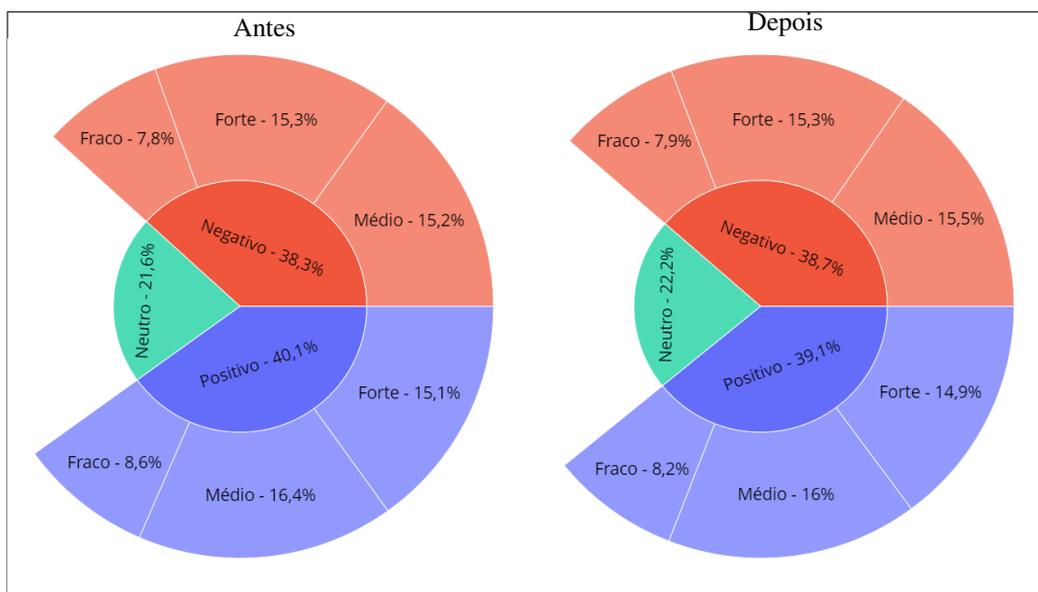
Fonte: Twitter (2022).

²⁰O teste não paramétrico de Mann-Whitney foi aplicado após a constatarmos a ausência de normalidade na distribuição dos dados em todos os grupos de dados testados.

²¹O nível de significância (alfa) utilizado foi de 0,05.

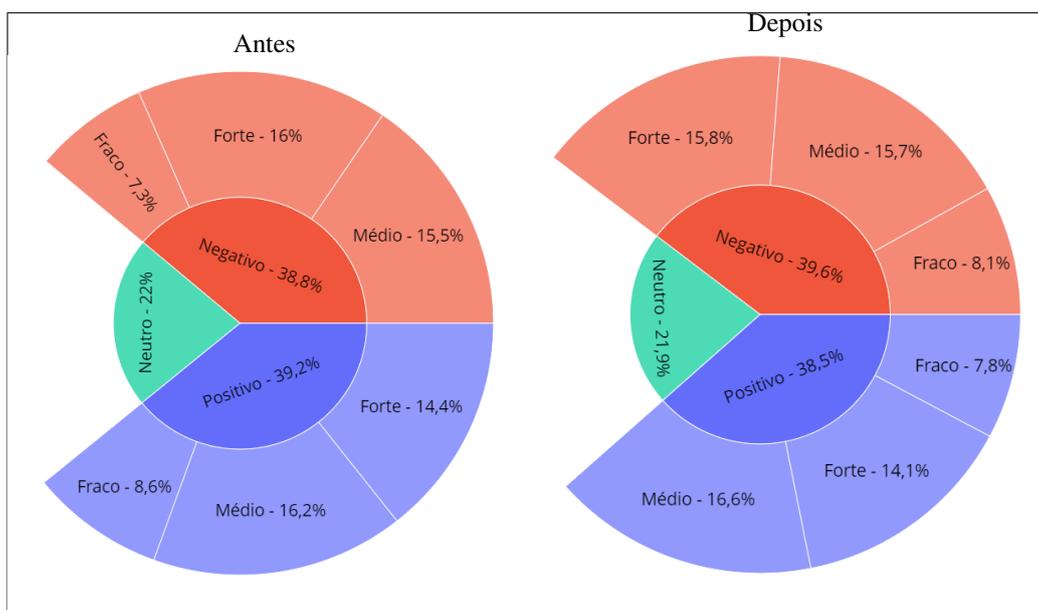
²²Disponibilizamos o dataset utilizado para este teste no endereço: <https://github.com/juniori/IMPACTO_COVID-19_PERCEPCAO_USUARIOS_TWITTER/blob/main/TESTES_ESTADISTICOS>

Figura 5.33: Intensidade dos sentimentos dos tweets x grau de gravidade baixo



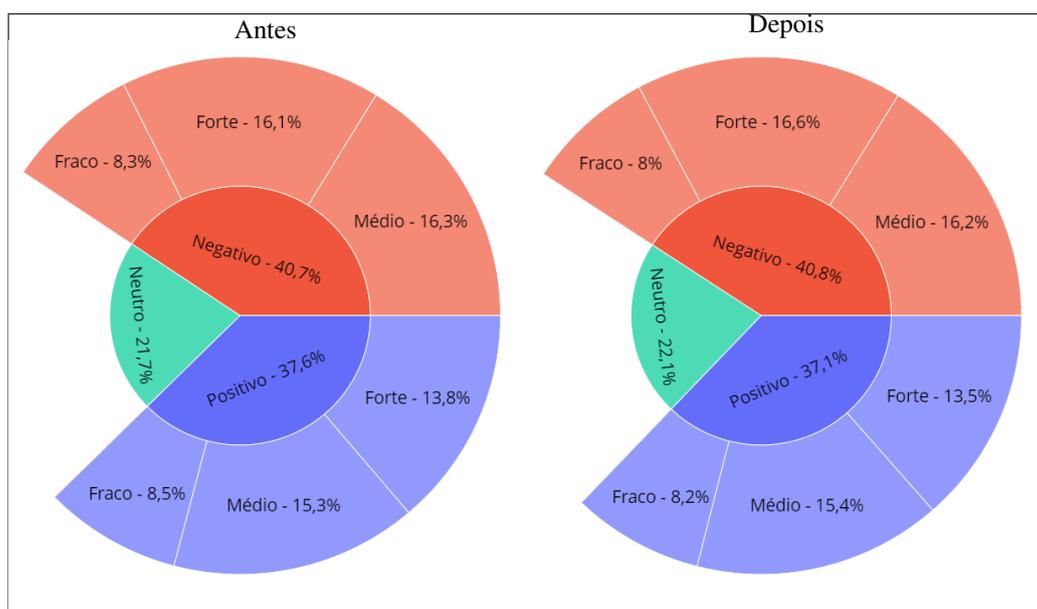
Fonte: Twitter (2022)

Figura 5.34: Intensidade dos sentimentos dos tweets x grau de gravidade médio



Fonte: Twitter (2022)

Figura 5.35: Intensidade dos sentimentos dos tweets x grau de gravidade alto



Fonte: Twitter (2022)

5.3.10 Intensidade dos sentimentos entre os diferentes graus de parentesco

Nesta seção buscamos identificar se há uma mudança dos sentimentos das pessoas entre os diferentes graus de parentescos relatados nos tweets base.

Assim como na análise apresentada na seção anterior 5.3.9, onde rotulamos os tweets base de acordo com o grau de gravidade identificados nos relatos, nesta análise também rotulamos os tweets base, entretanto agora os rótulos foram aplicados para classificar os tweets base a partir do parentesco identificados nos relatos contidos nestes tweets.

Para esta análise, primeiramente rotulamos os tweets base de cada usuário de acordo com o ente familiar identificado nestes tweets, por exemplo, tweets que continham o termo “meu pai”, receberam o rótulo “Pai”, tweets que continha o termo “minha mãe”, receberam o rótulo “Mãe” e assim por diante para cada um dos termos que designam entes familiares utilizados em nossa etapa de coleta dos tweets base. Nos casos em que o tweet possuía mais de um termo designando entes familiares diferentes (Figura 5.36), estes tweets receberam múltiplos rótulos, um para cada ente familiar identificado. Todos os tweets base foram rotulados, pois os termos que utilizamos para identificar os entes familiares relatados fazem parte da string de busca que utilizamos para coletar os tweets base, sendo assim, cada tweet base contém pelo menos um dos termos necessários para identificação do rótulo a ser aplicado. Ao término da etapa de rotulação dos tweets base de cada usuário, propagamos os rótulos atribuídos a cada tweet base para os tweets dos grupos antes e depois do mesmo usuário. Finalmente calculamos os percentuais para

cada sentimento dentro dos diferentes entes familiares para os grupos antes e depois do tweet base. Para esta análise utilizamos a classificação dos sentimentos realizada com o VADER.

Consideramos nesta análise os graus de parentesco ascendentes de primeiro grau (pai e mãe), segundo grau (avô e avó) e descendente de primeiro grau (filho e filha).

A fim de possibilitar comparação da intensidade dos sentimentos presentes nos tweets entre os diferentes graus de parentesco, desenvolvemos três pares de gráficos setorizados representando os percentuais dos sentimentos calculados para cada grau. Um par para os grupos antes e depois para o grau de parentesco ascendente de primeiro grau, representado pela Figura 5.33; Um par para os grupos antes e depois para o grau de parentesco ascendente de segundo grau, representado pela Figura 5.34; finalmente um par para os grupos antes e depois para o grau de parentesco descendente de primeiro grau, representado pela Figura 5.35. Estes pares de gráficos agrupados por grau de parentesco permitem uma comparação da intensidade dos sentimentos dentro dos diferentes graus de parentesco.

A tabela 5.10 apresenta os percentuais de cada sentimento, calculadas para cada grau de parentesco.

Aplicamos um teste de Mann-Whitney (Wilcoxon) ^{23,24} entre os pares de amostras dos tweets de mesmo sentimento ²⁵, dentro de cada um dos graus de parentesco, entre os grupos antes e depois. O resultado do teste apontou uma diferença estatisticamente significativa na comparação dos percentuais do sentimento “Positivo Fraco” antes e depois, pra os relatos com grau “Filho / Filha”, no entanto, com um tamanho de efeito pequeno 0,53. As tabelas com os resultados dos testes estão disponíveis no apêndice deste estudo A.5.

²³O teste não paramétrico de Mann-Whitney foi aplicado após a constatarmos a ausência de normalidade na distribuição dos dados em todos os grupos de dados testados.

²⁴O nível de significância (alfa) utilizado foi de 0,05.

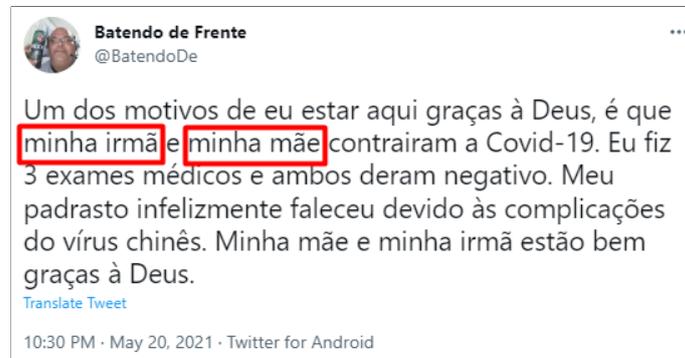
²⁵Disponibilizamos o dataset utilizado para este teste no endereço: <https://github.com/juniori/IMPACTO_COVID-19_PERCEPCAO_USUARIOS_TWITTER/blob/main/TESTES_ESTADISTICOS>

Tabela 5.10: Percentuais das intensidades dos sentimentos calculados para cada grau de gravidade.

Categoria		Avô / Avó				Pai / Mãe				Filho / Filha			
		Antes		Depois		Antes		Depois		Antes		Depois	
Negativo	Forte	40,2	15,9	40,2	15,8	39,9	15,5	40	16	36,9	14,9	36,7	14,6
	Médio		16,1		15,6		16,2		16		14,5		14,7
	Fraco		8,2		8,8		8,2		8		7,5		7,4
Neutro		21,8		22,9		21,7		22,3	22,3	21,3		21,7	
Positivo	Forte	38	13,4	36,9	12,7	38,4	13,9	37,8	13,7	41,8	16,5	41,6	16,7
	Médio		16		15,2		15,9		15,8		16,5		16,8
	Fraco		8,6		9		8,6		8,3		8,8		8,1

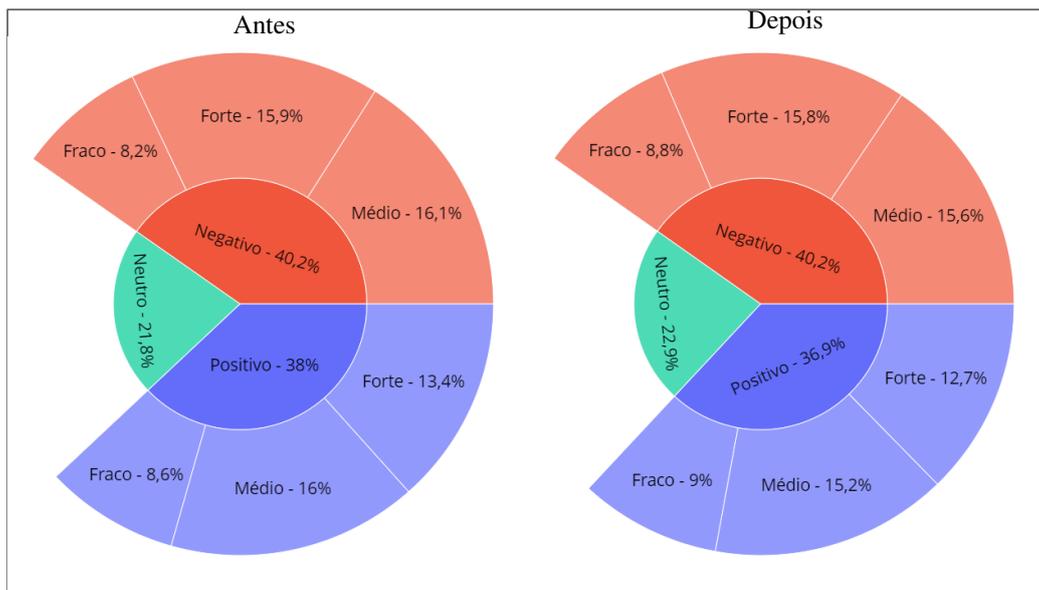
Fonte: O autor (2022).

Figura 5.36: Exemplo de tweet base contendo relato sobre diferentes entes familiares.



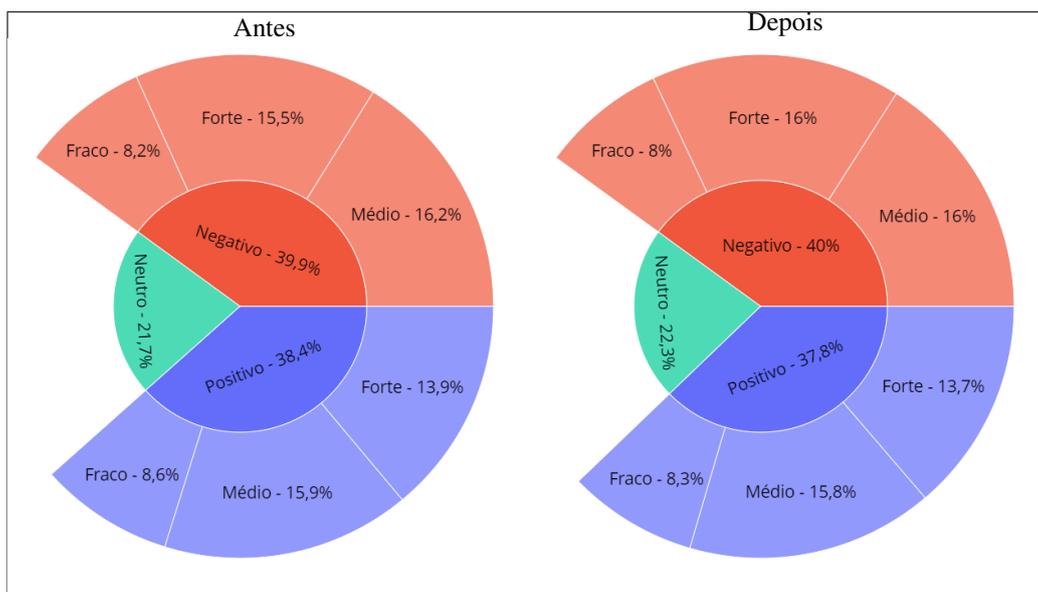
Fonte: Twitter (2022).

Figura 5.37: Intensidade dos sentimentos dos tweets x avô ou avó



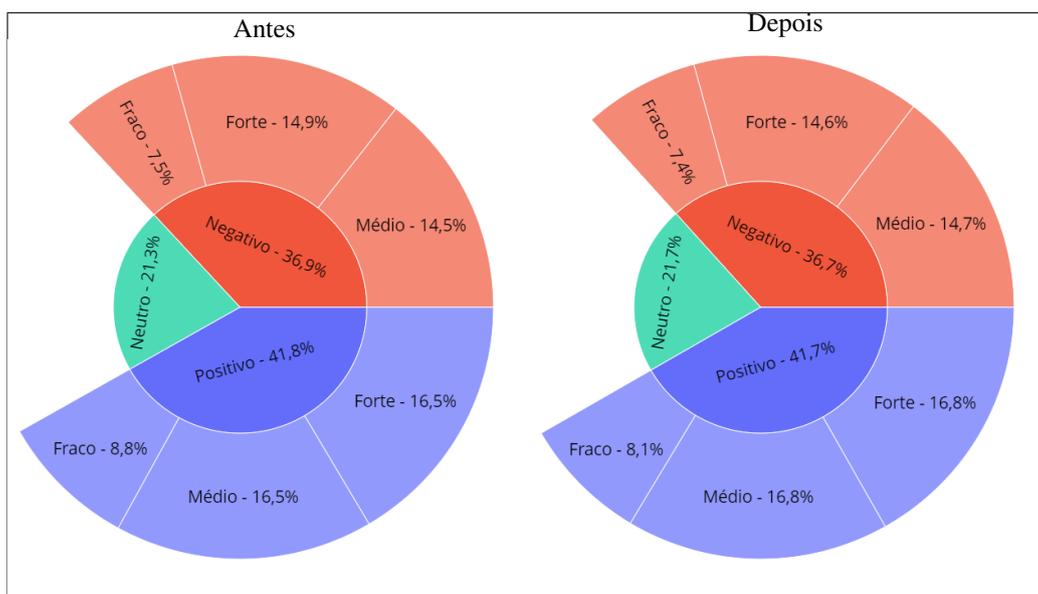
Fonte: Twitter (2022)

Figura 5.38: Intensidade dos sentimentos dos tweets x pai ou mãe



Fonte: Twitter (2022)

Figura 5.39: Intensidade dos sentimentos dos tweets x filho ou filha



Fonte: Twitter (2022)

5.3.11 Avaliação manual

Nesta seção apresentamos os resultados do processo de avaliação manual dos tweets abordado na seção 5.2.3.

Em nosso processo de avaliação manual, utilizamos uma aplicação web como instrumento de coleta dos resultados. A partir de e-mails enviados aos convidados, 86 pessoas

participaram respondendo nossa pesquisa que permaneceu disponível para preenchimento entre 15/06/2021 a 15/08/2021. Do total de 9.600 twets disponibilizados para avaliação, 2.485 foram avaliados. A média de tweets classificados por cada participante foi de 29. A tabela 5.11 apresenta o número de tweets classificados de acordo com as avaliações dos usuários.

Tabela 5.11: Quantidade de tweets classificados manualmente

	Grupos					
	Antes n (%)		Depois n (%)		Total n (%)	
Negativo	Forte		262 (21,3)		267 (21,3)	529 (21,3)
	Médio	560 (45,5)	143 (11,6)	519 (41,4)	113 (9,0)	1.079 (43,3)
	Fraco		155 (12,6)		139 (11,1)	294 (11,8)
Neutro		165 (13,4)		175 (14,0)		340 (13,7)
Positivo	Forte		139 (11,3)		141 (11,3)	280 (11,3)
	Médio	295 (23,9)	73 (5,9)	333 (26,6)	91 (7,3)	628 (25,3)
	Fraco		83 (6,7)		101 (8,1)	184 (7,4)
Sem relação com o governo		76 (6,2)		72 (5,7)		148 (6,0)
Tweets Incompreensíveis		136 (11,0)		154 (12,3)		290 (11,7)
Total		1.232 (100)	1.232 (100)	1.253 (100)	1.253 (100)	2.485 (100,0)

Fonte: O autor (2022).

5.4 Considerações finais sobre o Experimento 2

Neste capítulo, mostramos como os conhecimentos adquirido no Experimento 1 foram adicionados ao nosso segundo experimento. Apresentamos os critérios, ferramentas e procedimentos utilizados para a coleta de tweets e processamento dos dados coletados. Utilizamos análise quantitativa das intensidades de emoções e sentimentos presentes nos tweets e frequência de palavras para responder as subquestões de pesquisa, estabelecidas na seção 1.4. Apresentamos também os resultados da classificação manual de sentimentos sobre uma amostra de tweets coletados durante este segundo experimento.

No capítulo seguinte, discutiremos nossas descobertas em relação a cada uma das subquestões de pesquisa que foram exploradas neste capítulo. Além disso, comparamos as três ferramentas de análise de sentimentos entre elas e também com as classificações manuais.

6. Discussão

Nos capítulos 4 e 5, apresentamos as relações entre o fenômeno estudado e outros fatores a partir da análise dos dados obtidos por meio da execução dos Experimentos 1 e 2. No presente capítulo, interpretamos os resultados de nossas análises e discutimos nossas descobertas em relação a cada uma de nossas subquestões de pesquisa.

Esta pesquisa visou compreender as percepções das pessoas com relação ao governo Jair Bolsonaro diante de uma tragédia real que resultou em milhares de vítimas no país. A maioria dos trabalhos relatados (DUBEY, 2020), (MEDFORD et al., 2020), (GARCIA; BERTON, 2021) coletou tweets sobre Covid-19 para analisar os sentimentos das pessoas diretamente sobre a doença. Este estudo realizou uma análise indireta porque usamos tweets base como marcadores de tempo e tweets relacionados ao governo Bolsonaro agrupados antes e depois dos tweets base. Portanto, ao contrário dos trabalhos citados, o objetivo principal não foi analisar os sentimentos das pessoas em relação à pandemia, mas sim o sentimento em relação ao governo Jair Bolsonaro diante desta grande tragédia que afligiu as pessoas. Apoiamos nossas análises na seguinte questão de pesquisa: **as percepções das pessoas em relação ao governo Jair Bolsonaro mudam após elas relatarem, nas redes sociais, um familiar acometido pela Covid-19?** Para responder nossa questão de pesquisa, definimos as seguintes subquestões de pesquisa:

- **SRQ1** — Em que medida os sentimentos negativos, positivos e neutros estão presentes nos grupos de tweets sobre o governo Bolsonaro antes e após os relatos sobre um familiar acometido pela Covid-19?
- **SRQ2** — Há diferença entre as palavras positivas, negativas e neutras mais frequentemente utilizadas entre os grupos de tweets antes e após um familiar ter sido afetado pela Covid-19?
- **SRQ3** — Existe uma tendência dos sentimentos positivos e negativos ao longo do tempo entre os grupos de tweets antes e após um familiar afetado pela Covid-19?

- **SRQ4** — O quanto há de subjetividade (opinião) nas mensagens?
- **SRQ5** — Em que medida os sentimentos estão relacionados ao número de casos e mortes provocados pela Covid-19?
- **SRQ6** — Além dos sentimentos positivos, negativos e neutros, em que medida emoções como raiva, expectativa, nojo, medo, alegria, tristeza, surpresa, confiança estão presentes nos grupos de tweets postados antes e após os relatos sobre um familiar afetado pela Covid-19?
- **SRQ7** — Em que medida as mensagens positivas são ligadas a alegria, enquanto as negativas estão mais ligadas a raiva, medo ou tristeza?
- **SRQ8** — Existe uma mudança nos sentimentos entre os diferentes graus de gravidade dos relatados?
- **SRQ9** — Existe uma mudança nos sentimentos entre diferentes graus de parentesco?

A seguir, discutimos nossas descobertas em relação a cada uma das subquestões supracitadas. Na sequência, comparamos as três ferramentas de análise de sentimentos entre elas e também com as respostas manuais da pesquisa realizada no Experimento 1, na qual os participantes foram solicitados a classificar cada tweet conforme o número de termos negativos, positivos ou neutros observados. No final, comparamos as diversas ferramentas com as respostas manuais da pesquisa realizada no Experimento 2, na qual os participantes foram solicitados a classificar os tweets de acordo com o sentimento identificado no tweet do ponto de vista de quem postou a mensagem.

6.1 Sobre a intensidade dos sentimentos

Na subquestão **SRQ1** “Em que medida os sentimentos negativos, positivos e neutros estão presentes nos grupos de tweets sobre o governo Bolsonaro antes e após os relatos sobre um familiar acometido pela Covid-19?”, exploramos a intensidade dos sentimentos presentes nos tweets por meio de análises realizadas durante dois experimentos que contemplaram diferentes períodos e ferramentas.

Percebemos através dos resultados relativos à análise da intensidade dos sentimentos que realizamos durante o Experimento 1 (seção 4.3.1), uma variação discreta entre os percentuais dos sentimentos em relação ao governo Bolsonaro antes e depois do tweet base.

Os dados coletados não mostraram diferenças relevantes nos percentuais dos sentimentos ou suas subcategorias (forte, médio, fraco). Nossa análise sobre a dispersão dos dados foi desenvolvida para entendermos em que medida a polaridade dos sentimentos estaria relacionada à quantidade de tweets postados por cada usuário nos grupos de tweets sobre o governo antes e após o tweet base (seção 4.3.2). Essas análises também não apresentaram diferenças expressivas, tanto para média das polaridades dos sentimentos, quanto para a quantidade de mensagens entre os grupos de tweets antes e depois do tweet base.

A extração dos tweets base para o Experimento 1, realizada durante os meses de março a junho/2021, coincidiu com o período em que a pandemia atingiu seu ápice em números de casos e mortes no Brasil (ESTRADA; NÓBREGA, 2022). Neste período, pesquisas apontavam que grande parte dos brasileiros desaprovava a forma com que o governo enfrentava a pandemia ¹, incluindo famílias de vítimas da Covid-19 que atribuíam a culpa ao presidente da República (LEMOS, 2021). Diante deste cenário, esperávamos encontrar diferenças mais evidentes ao comparar os resultados do cálculo dos sentimentos dos tweets antes e depois do tweet base, o que não ocorreu de forma relevante. Este fato nos levou a repetir as análises sobre esta questão em nosso Experimento 2, desta vez ampliando nosso período de coleta de tweets base para todo o ano de 2021 e calculando os sentimentos contidos nas mensagens a partir de outras duas ferramentas e idiomas.

Ao analisar os resultados relativos à intensidade dos sentimentos de cada grupo em nosso Experimento 2 (seção 5.3.1), novamente não percebemos variação significativa dos sentimentos ou suas subcategorias (forte, médio, fraco) entre os grupos antes e depois do tweet base. Entretanto, notamos algumas diferenças nas tendências dos percentuais calculados pelas diferentes ferramentas de análise de sentimentos utilizadas neste segundo experimento. Por exemplo, observamos que, de forma geral, a ferramenta Textblob apresentou uma maior tendência a sentimentos neutros, enquanto o Polyglot (inglês e português) apresentou uma maior tendência ao sentimento negativo e o VADER um balanceamento entre negativos e neutros.

Alguns motivos poderiam explicar a discreta variação dos sentimentos entre os grupos antes e depois do tweet base. Entre eles: i) A incapacidade de uma captação mais precisa dos sentimentos presentes nos tweets avaliados pelas ferramentas de análise de sentimento utilizadas; ii) a ausência de associação dos dramas familiares vividos à forma como o governo Jair Bolsonaro conduziu a pandemia.

Os procedimentos de análise de sentimentos automatizada ainda enfrentam inúmeros

¹<https://g1.globo.com/politica/noticia/2021/05/14/datafolha-51percent-reprovam-desempenho-de-bolsonaro-na-pandemia-gh.html>

desafios (XU; CHANG; JAYNE, 2022), (WANKHADE; RAO; KULKARNI, 2022). Especialmente quando os dados analisados são extraídos de redes sociais (em que figuras de linguagens como ironia, sarcasmo, metáforas e gírias são amplamente utilizados) tais desafios se tornam ainda maiores e dificultam interpretar com precisão os sentimentos apropriados. Por exemplo, a presença de ironia nos tweets analisados poderia dificultar captação precisa dos sentimentos expressos nos tweets avaliados, já que a mensagem analisada significa o contrário daquilo que se quer expressar. Estudos recentes relacionados à detecção de ironia, como Turban e Kruschwitz (2022) e Ahuja e Sharma (2022), classificam a detecção automática de ironia em redes sociais como um problema desafiador da PLN. Além disso, como já exposto nesta seção, constatamos divergências em nossa análise automática de sentimentos entre as classificações realizadas pelas diferentes ferramentas que utilizamos neste estudo, o que reforça os desafios de interpretar com precisão os sentimentos apropriados. Estas divergências são discutidas na seção 7.2. No entanto, além de problemas relacionados a captação precisa dos sentimentos expressos nas mensagens, existem outros possíveis motivos que precisam ser considerados, como uma possível ausência de associação dos dramas familiares vividos à forma como governo Jair Bolsonaro conduziu o combate à pandemia.

A enorme quantidade de desinformação sobre a pandemia, potencializada pelas redes sociais, cujo governo Bolsonaro participava popularizando discursos como “vírus chinês”, “comunavírus”, “vachina”, “tratamento precoce” ganharam força entre uma parte da população. Nesse contexto de desinformação, a propagação de notícias falsas ou descontextualizadas podem ocorrer como um viés de confirmação, o que leva os indivíduos a buscarem informações que reforcem suas próprias crenças (FREIRE et al., 2021). Além disso, de acordo com o estudo publicado por Bavel e Pereira (2018) há evidências que o partidatismo pode alterar a memória, a avaliação implícita e até mesmo os julgamentos perceptivos. Consequentemente, existe a passibilidade de uma parte dos usuários analisados por esta pesquisa, não associarem seus dramas familiares vividos à forma como governo Jair Bolsonaro conduziu a pandemia, o que não tornaria este evento um fator de mudança de opinião sobre o governo.

6.2 Sobre as nuvens de palavras

Na subquestão **SRQ2** “Há diferença entre as palavras positivas, negativas e neutras mais frequentemente utilizadas entre os grupos de tweets antes e após um familiar ter sido afetado pela Covid-19?”, investigamos a frequência com que determinados termos aparecem nos tweets. A diferença entre as palavras mais utilizadas entre os grupos de

tweets antes e depois do tweet base foram analisadas durante dois experimentos que contemplaram diferentes períodos e ferramentas.

As nuvens de palavras desenvolvidas durante o Experimento 1, ilustradas pela Figura 4.7, apresentaram ligeiras variações. Ao comparar a nuvem de palavras dos tweets negativos sobre o governo Bolsonaro antes e depois do tweet base, percebeu-se o aumento no tamanho das palavras “*pandemic*”, “*protest*”, “*hate*”, “*death*”, “*hunger*” e “*shit*”.

As análises desenvolvidas em nosso segundo experimento, que considerou um recorte temporal mais amplo do que o Experimento 1, mostraram que algumas palavras permaneceram sendo utilizadas com alta frequência pelas pessoas que tiveram familiares acometido pela Covid-19, em suas mensagens relacionadas ao governo, durante todo o período que analisamos. As palavras “*hate*”, “*death*” e “*shit*” foram as mais frequentemente utilizadas em ambos experimentos. As palavras “*protest*”, “*pandemic*” e “*hunger*”, destacaram-se com maior clareza no Experimento 1, cujo período analisado coincide com o ápice de número de casos e óbitos por Covid-19 no Brasil.

As palavras negativas em destaque podem sugerir os sentimentos de pessoas que passaram por dramas ou traumas pessoais depois que um ente querido foi impactado pela doença. O aumento do tamanho da palavra “*hunger*”, por exemplo, pode ter ocorrido devido à crescente preocupação com a fome durante a pandemia. A Pesquisa Nacional de Insegurança Alimentar no contexto da pandemia Covid-19 no Brasil, realizada pela Rede Brasileira de Pesquisa em Soberania e Segurança Alimentar e Nutricional, indica que nos últimos meses de 2020, 19 milhões de brasileiros passaram fome e mais da metade das famílias do país enfrentavam algum grau de insegurança alimentar (NUTRICIONAL; PENSSAN, 2021). Uma comparação entre as nuvens de palavras de tweets positivos antes e depois dos tweets base mostrou que as palavras “*like*” e “*good*” permaneceram proeminentes com ligeira variação no tamanho antes e depois do tweet base. Observamos também um aumento no tamanho da palavra “*god*”, que não denota necessariamente a força do presidente junto aos grupos religiosos, mas pode reforçar uma posição sobre determinado assunto, como a fé na recuperação da saúde. As palavras “*celebrate*” e “*party*” também aparecem na nuvem de palavras positivas após o tweet base.

Em nosso segundo experimento, devido à inclusão de diferentes ferramentas de análise de sentimentos, quatro conjuntos de nuvens de palavras (Figuras 5.12, 5.13, 5.14 e 5.15) foram apresentados, cada um deles com a frequência das palavras de acordo com o sentimento. As nuvens de palavras geradas por ferramentas diferentes não apresentaram exatamente o mesmo conjunto de palavras. Isto pode ter ocorrido porque as ferramentas utilizam dicionários diferentes.

A nossa análise difere da maioria dos trabalhos relatados (NASEEM et al., 2021), (DUBEY, 2020), (MEDFORD et al., 2020), (KAUR; VERMA; OTOO, 2021), pois esses estudos analisaram as frequências das palavras com o propósito de inferir informações no contexto da pandemia, entretanto eles não exploraram possíveis mudanças na percepção das pessoas, especialmente comparando o antes e o depois de determinado evento relatado por elas nas redes sociais. Além disso, as nuvens de palavras analisadas por estes trabalhos foram apresentadas exclusivamente no idioma inglês. Naseem et al. (2021) utilizaram ferramentas de Processamento de Linguagem Natural (NLP) para rotular tweets relacionados à pandemia da Covid-19 na língua inglesa em classes de sentimentos positivos, negativos e neutros e apresentou a frequência das palavras mais comuns, cada classe em uma nuvem de palavras. Algumas palavras em destaque foram “*coronavirus*”, “*chinese*”, “*fears*” e “*wuhan*”.

Dubey (2020) coletou tweets em inglês de doze países com o objetivo de analisar os sentimentos das pessoas durante o surto do novo coronavírus. Algumas palavras em destaque foram “*virus*”, “*world*”, “*fight*” e “*Trump*”. A palavra “*Trump*” entre as mais frequentes sugere uma associação do vírus com o presente norte-americano. No entanto, esta análise, diferentemente das análises realizadas pela presente pesquisa, não analisou os sentimentos das pessoas em relação ao governo daquele presidente, mas em relação ao surto de Covid-19 de maneira geral.

6.3 Sobre a polaridade média dos sentimentos no período

Na subquestão **SRQ3** “Existe uma tendência dos sentimentos positivos e negativos ao longo do tempo entre os grupos de tweets antes e após um familiar afetado pela Covid-19?”, exploramos nossas amostras de tweets dos grupos antes e após um familiar afetado pela Covid-19, durante nosso segundo experimento, com o propósito de verificar se havia uma tendência a determinado sentimento durante o período analisado.

Após observar os resultados sobre a polaridade dos sentimentos no período (seção 5.3.4), ao comparar as polaridades apresentadas pelos gráficos (Figuras 5.16 5.17, 5.18 e 5.19), constatamos que todos os gráficos possuíam um comportamento de tendências bastante similares entre eles. Notamos a existência de quatro momentos evidentes, onde ocorreram pontos de mudanças de tendência em todos os gráficos. Sendo assim, separamos e analisamos individualmente cada um destes momentos, buscando os motivos que poderiam explicar as tendências observadas. Utilizamos o gráfico gerado a partir da ferramenta VADER para destacar os momentos descritos (Figura 6.1). O motivo da escolha

pelo VADER é que ele foi a ferramenta, entre todas as outras utilizadas neste estudo, que obteve maior número de correspondências quando comparamos as classificações automáticas com as manuais. A seção 7.2 apresenta uma comparação entre as classificações automáticas de sentimentos realizadas pelas diferentes ferramentas e a classificação manual.

Figura 6.1: Momentos em que ocorreram mudanças de tendências no gráfico de polaridade média dos sentimentos no período (VADER)



Fonte: O autor (2022).

O primeiro momento em destaque ocorreu entre janeiro e junho, predominando uma tendência mais negativa em relação ao restante do período analisado. Ao observarmos as polaridades médias dos sentimentos durante o ano de 2021, percebemos que o primeiro semestre apresentou uma negatividade maior que o restante do ano. Nesta fase, constatamos em alguns gráficos (5.16, 5.18 e 5.19) um sentimento mais negativo para o grupo depois do tweet base do que para o grupo antes do tweet base. A negatividade maior do grupo de tweets depois do tweet base, sugere que houve neste período um possível aumento da percepção negativa das pessoas, em relação ao governo Bolsonaro, após relatarem um familiar acometido pela Covid-19. De acordo com boletim sobre o balanço de dois anos da pandemia de Covid-19 publicado pelo Observatório da Covid-19/Fiocruz (ESTRADA; NÓBREGA, 2022), o início do ano de 2021 foi marcado pela segunda onda de transmissão do coronavírus, que iniciou no verão de 2020 e coincidiu com o período de festas de fim de ano e férias. Estes fatores favoreceram a rápida disseminação e predominância da variante Gama, que levou a pandemia a atingir seu ápice em número de casos e óbitos entre março e abril de 2021. O aumento do sentimento negativo entre os tweets após o tweets base, poderia ter sido provocado pela gravidade com que a doença atingia as pessoas durante esta fase, mediante a impossibilidade de recuperação da saúde dessas pessoas devido ao fato de que o sistema de saúde brasileiro estaria entrando em colapso.

Diferentemente do estudo publicado por Zhunis et al. (2022), em que um aumento dos sentimentos positivos foi relacionado à expectativa do princípio da vacinação, em dezembro de 2020 nos EUA, na presente pesquisa não detectamos uma positividade relacionada ao momento correspondente ao início da campanha de vacinação no Brasil, que ocorreu em janeiro de 2021.

O segundo momento analisado ocorreu entre junho e setembro, período em que observamos o início de um movimento tendendo a sentimentos mais positivos. O mês de janeiro de 2021 foi marcado pelo início da campanha de vacinação contra a Covid-19 no Brasil², contudo, apenas o início da vacinação não impediu o crescimento do número de casos, internações e óbitos durante o primeiro semestre daquele ano. Os impactos positivos da campanha da vacinação foram observados a partir do mês julho (ESTRADA; NÓBREGA, 2022). Neste cenário, constatamos também um aumento da positividade dos sentimentos dos tweets dos grupos antes e depois do tweet base, iniciado entre os meses de junho e julho, conforme pode ser observado em nossas análises apresentadas na seção 5.3.4. A partir do mês de julho, quando comparamos a polaridade entre os grupos de tweets, observamos que há uma negatividade menor no grupo de tweets depois do tweet base, o que pode sugerir um possível aumento da percepção positiva das pessoas em relação ao governo Jair Bolsonaro em suas postagens, provocado pela atenuação do grau de gravidade com que a doença atingia as pessoas devido a vacinação. Todavia, percebemos que o aumento da percepção positiva, iniciada entre os meses de junho de julho, terminaram entre os meses de setembro e outubro, onde se iniciou uma tendência negativa em ambos os grupos.

O terceiro momento analisado ocorreu durante o mês de outubro, período em que novamente observamos um aumento relativamente considerável do sentimento negativo se compararmos com o mês anterior. Em setembro de 2021, a CPI da Covid-19 caminhava para o seu estágio final diante de uma série de denúncias como a omissão do governo Bolsonaro perante a compra de vacinas, tratamento precoce e o caso da Prevent Sênior³. Várias pessoas foram indiciadas, entre elas, o presidente da república e seu ex-ministro da saúde Eduardo Pazuello. Neste contexto, observamos também uma tendência negativa dos sentimentos dos tweets dos grupos antes e depois do tweet base, iniciado entre os meses de setembro e outubro, conforme pode ser observado em nossas análises apresentadas na seção 5.3.4. No final de outubro de 2021 aconteceu a entrega do relatório final da CPI da Covid-19. A tendência negativa observada durante o mês de outubro, entre outros motivos, poderia ter sido causada por um evento público relacionado ao governo, como

²<<https://agenciabrasil.ebc.com.br/saude/noticia/2021-01/vacinacao-contra-covid-19-come%C3%A7a-em-todo-o-pais>>

³<<https://www12.senado.leg.br/noticias/materias/2021/10/20/cpi-da-pandemia-principais-pontos-do-relatorio>>

a repercussão diante da proximidade da entrega do relatório final produzido pela CPI da Covid-19.

O quarto e último momento em que dividimos nossas análises, novembro a janeiro de 2022, revelou uma tendência positiva para o grupo de tweets do grupo antes do tweet base e uma tendência negativa para os tweets do grupo após os tweets base. Durante este período o Brasil enfrentava uma nova onda de infecções causadas pela variante Ômicron (ESTRADA; NÓBREGA, 2022).

Na análise sobre a mudança de sentimentos ao longo do tempo publicado por Xue et al. (2020), os autores coletaram e calcularam o sentimento de aproximadamente 20 milhões de tweets na língua inglesa, relacionados a pandemia da Covid-19, durante janeiro e março de 2020. Assim como a presente pesquisa, a unidade de análise considerada para cálculo do sentimento foi cada tweet ao nível de mensagem. Xue et al. (2020) objetivaram compreender como os sentimentos dos usuários mudavam ao longo do tempo, entretanto não consideraram a análise da mudança de percepção dos usuários antes e após um determinado evento como consideramos na presente pesquisa.

As análises que fizemos nesta seção para compreender a existência de tendências de sentimentos em cada um dos momentos analisados poderiam ser aprofundadas por meio da aplicação de técnicas qualitativas. Examinar qualitativamente o conteúdo dos tweets dos usuários, poderia revelar, de maneira mais assertiva, os principais motivos relacionados às tendências apresentadas em cada um dos momentos analisados (WEI; LIN; YAN, 2020).

Apesar da similaridade das tendências calculadas por diferentes ferramentas que foram apresentadas (Figuras 5.16, 5.17, 5.18 e 5.19), constatamos algumas diferenças no quão negativo ou positivo foram as médias da polaridade calculadas por cada uma das ferramentas para os meses analisados. Por exemplo, o gráfico que apresenta os dados calculados pela ferramenta VADER (Figura 5.16) alternou as polaridades médias mensais em períodos negativos e positivos ao longo do tempo, enquanto o Textblob (Figura 5.17) manteve todas as polaridades médias mensais positivas e o Polyglot (Figuras 5.18 e 5.19) manteve as polaridades médias mensais negativas. Isto pode ser justificado por diferenças na classificação das palavras dos dicionários utilizados por cada uma das ferramentas. Por exemplo, em cada um dos dicionários utilizados pelas ferramentas VADER, Textblob, Polyglot (texto em inglês) e Polyglot (texto em português), a palavra “death” apresenta as respectivas pontuações: -0.5, 0, -1 e -1. Portanto, mais uma vez, assim como sugerimos durante a discussão dos resultados observados em nossas nuvens de palavras, constatamos que o cálculo do sentimento para uma mesma sentença, realizados por diferentes

ferramentas que utilizam dicionários léxicos, podem gerar resultados distintos.

6.4 Sobre a subjetividade média no período

Para responder nossa subquestão de pesquisa **SRQ4** “O quanto há de subjetividade (opinião) nas mensagens?”, analisamos sentimentos presentes em tweets que continham expressões subjetivas no discurso, conforme resultados apresentados na seção (5.3.5). Considerando que nas seções anteriores não identificamos diferenças relevantes entre os percentuais dos sentimentos dos grupos de tweets antes e depois do tweet base, nesta seção objetivamos examinar se uma análise restrita aos tweets mais subjetivos poderia revelar resultados mais evidentes. Partimos do princípio que mensagens subjetivas geralmente se referem a opiniões, emoções ou julgamentos, sendo assim, uma análise restrita aos tweets com maior grau de subjetividade poderia apresentar um resultado mais claro sobre a mudança de percepção entre os grupos. Acreditamos ser relevante neste momento abordarmos alguns aspetos sobre o conceito de subjetividade. Existem quatro formas de definir subjetividade: i) a subjetividade caracterizada como algo subjetivo; ii) a subjetividade pertencente ao campo ou domínio das atividades subjetivas; iii) a subjetividade oriunda da interpretação de um sujeito individual; iv) a subjetividade extraída de uma opinião ou atitude marcada por sentimentos, impressões ou preferências pessoais⁴. Salientamos que a subjetividade mantém relações com a subjetividade linguística relacionada à forma como o sujeito enunciador marca a sua presença no enunciado. Na presente pesquisa a subjetividade é caracterizada como a presença de opinião ou atitude marcada por sentimentos.

Observamos no gráfico (Figura 5.20) que os tweets do grupo depois do tweet base apresentaram uma tendência de subjetividade levemente maior que os tweets do grupo de antes do tweet base para a maioria dos meses apresentados no gráfico. Isto sugere que ferramentas de análise de sentimentos que utilizam mecanismos de análise léxica, como as que utilizamos nesta pesquisa, seriam capazes de calcular os sentimentos presentes a partir dos tweets do grupo depois do tweet base com uma maior precisão. De acordo com Kharde, Sonawane et al. (2016), a classificação da subjetividade é a tarefa de classificar as sentenças como opinativas ou não opinativas. As sentenças opinativas representam o conteúdo com sentimento. Sobre este aspecto, a fim de investigarmos se a análise sobre a intensidade dos sentimentos apresentadas na seção (5.3.1) deixou de captar alguma mudança de sentimento devido à ausência de subjetividade nas sentenças, repetimos as mesmas análises, entretanto consideramos somente os tweets de maior subjetividade em

⁴<<https://www.infopedia.pt/dicionarios/lingua-portuguesa/subjetividade>>

ambos grupos na seção (5.3.5).

Conforme a categorização de acordo com o grau de subjetividade apresentada na tabela 5.4, percebemos que a maioria dos tweets analisados possuía uma subjetividade fraca, sendo de aproximadamente 52% em ambos grupos. Aproximadamente 28% dos tweets foram classificados como subjetividade média em ambos grupos e 20% foram classificados como subjetividade forte, também em ambos grupos.

A tabela 6.1 apresenta alguns exemplos de tweets que, após tradução para língua inglesa, foram categorizados de acordo com o grau de subjetividade calculado pela ferramenta Textblob.

A proximidade dos percentuais de subjetividade entre os grupos antes e depois do tweet base, indica que não houve diferença expressiva entre a quantidade de opiniões que as pessoas expressavam em seus tweets antes e depois de seus relatos sobre um familiar acometido pela Covid-19. Todavia, investigamos ainda se, por meio da análise dos 20% de tweets que foram classificados com grau de subjetividade forte, seria possível detectar uma mudança de percepção das pessoas de forma mais expressiva.

Em nossa análise restrita aos tweets mais subjetivos (seção 5.3.5), esperávamos encontrar um resultado mais claro sobre a mudança de percepção entre os grupos. Entretanto, assim como a análise que realizamos sobre os tweets independentemente da subjetividade (seção 5.3.1), ao compararmos os percentuais dos sentimentos positivos, negativos e neutros dos grupos de tweets antes e depois do tweet base calculados pela mesma ferramenta, percebemos que os percentuais também apresentaram uma variação mínima.

Tabela 6.1: Exemplos de tweets categorizados de acordo com a subjetividade calculada.

Subjetividade	Tweet	
	Português	Inglês (tradução automática)
Fraca	As pessoas dizem q qm vota em Bolsonaro é facista. Não vão me convencer q 55% da nossa população é facista. Burra pode até ser	People say that those who vote for Bolsonaro are fascist.They will not convince me that 55% of our population is a phacist. Dumb can even be
	Tomei muito café nessa pandemia e não peguei COVID, achei a próxima cura milagrosa do Bolsonaro?	I had a lot of coffee in this pandemic and didn't get Covid, I found Bolsonaro's next miracle cure?
	Você é a favor de protesto nas ruas contra o governo Bolsonaro nesse momento?	Are you in favor of protest on the streets against the Bolsonaro government at this time?
Média	Coitado do governo Bolsonaro. Eles precisam roubar para acabar com o comunismo.	Poor government Bolsonaro.They need to steal to end communism.
	O governo Bolsonaro realmente acha que tudo pode ser resolvido com algum videozinho fake de whatsapp.	The Bolsonaro government really thinks everything can be solved with some whatsApp fake video.
	Povo de Deus ajude nosso presidente a construir um Brasil melhor	People of God help our president build a better Brazil
Forte	Requisito para fazer parte do governo Bolsonaro é ser idiota . tudo isso é culpa do bolsonaro, tudo da errado nesse governo	Requirement to be part of the Bolsonaro government is to be stupid. All this is Bolsonaro's fault, all wrong in this government
	Fabio Wajngarten não é o único mentiroso, é apenas mais um, dessa turma de mentirosos a que integram o governo de Bolsonaro, o maior mentiroso de todos.	Fabio Wajngarten is not the only liar, it is just one more, from this class of liars to be part of the government of Bolsonaro, the greatest liar of all.

Fonte: O autor (2022).

6.5 Sobre a relação dos sentimentos e número de casos e mortes provocados pela Covid-19

Para responder a subquestão **SRQ5** “Em que medida os sentimentos estão relacionados ao número de casos e mortes provocados pela Covid-19?”, examinamos a polaridade média dos sentimentos calculados para os grupos antes e depois do tweet base e confrontamos estes dados com os números mensais novos casos e óbitos por Covid-19 que foram divulgados pelo ministério da saúde brasileiro durante o ano de 2021.

Ao observar os gráficos desenvolvidos durante nossa análise na seção 5.3.6, que apresentou os dados relativos à polaridade dos sentimentos e os números de casos e óbitos provocados pela Covid-19 ao longo do ano de 2021, constatamos que, de maneira geral, as tendências dos sentimentos e o número de novos casos variaram de maneira oposta (gráfico 5.26). Este comportamento também ocorreu quando observamos as tendências dos sentimentos e número de óbitos mensais (gráfico 5.27).

Na seção anterior (6.3), examinamos a predominância de tendências relacionadas a um determinado sentimento ao longo do ano de 2021. Como resultado, notamos a existência de quatro momentos evidentes em que ocorreram diferentes tendências de sentimentos durante o ano, e para cada destes momentos, buscamos os motivos, baseados em eventos públicos, que poderiam explicar tais tendências, como: o colapso do sistema de saúde, os impactos positivos da vacinação, a CPI da Covid-19 e a chegada da nova variante Ômicron. Considerando que a análise dos números de casos e óbitos provocados pela Covid-19 estão relacionados aos eventos públicos destacados em nossa pesquisa, na presente seção, enriquecemos os gráficos 5.26 e 5.27 apresentados na seção 5.3.6 com os momentos em que ocorreram diferentes tendências de sentimentos explicados na seção 6.3. Desta forma, podemos examinar a relação dos sentimentos com o número de casos e óbitos, incluindo uma visão dos eventos públicos envolvidos. Sendo assim, utilizamos os gráficos 6.2 e 6.3 a fim de interpretar em que medida os sentimentos estão relacionados ao número de casos e mortes provocados pela Covid-19.

No gráfico 6.2, ao observarmos as tendências dos números de novos casos de Covid-19 e dos sentimentos dos grupos antes e depois do tweet base, percebemos que o primeiro momento em destaque, ocorrido entre janeiro e junho, apresentou o mesmo ponto de mudança de tendência dos sentimentos e dos números de novos casos provocados pela Covid-19. Neste contexto, consideramos que houve uma relação de relativa estabilidade (inversamente proporcional) entre os sentimentos dos grupos antes e depois do tweet base e os números de novos casos, onde enquanto os números de novos casos permaneceram em alta, os sentimentos se mantiveram negativos.

Ao observarmos as tendências dos números de novos óbitos e dos sentimentos dos grupos antes e depois do tweet base (Gráfico 6.3), constatamos que, assim como ocorreu com o número de casos, o número de óbitos também permaneceu em alta durante todo o primeiro momento destacado no gráfico, entretanto o número de óbitos apresentou um pico durante o mês de abril. Aparentemente o pico do número de óbitos ocorrido durante o mês de abril não se refletiu na tendência dos sentimentos, que se manteve relativamente estável. Um dos motivos que poderiam explicar tal fato seria que realizamos a comparação dos sentimentos calculados sobre os tweets dos grupos antes e depois tweet base, mas sem considerar o grau de gravidade relatado pelo usuário. Nossa hipótese é que uma análise de sentimento considerando o grau de gravidade dos relatos poderiam evidenciar resultados mais claros.

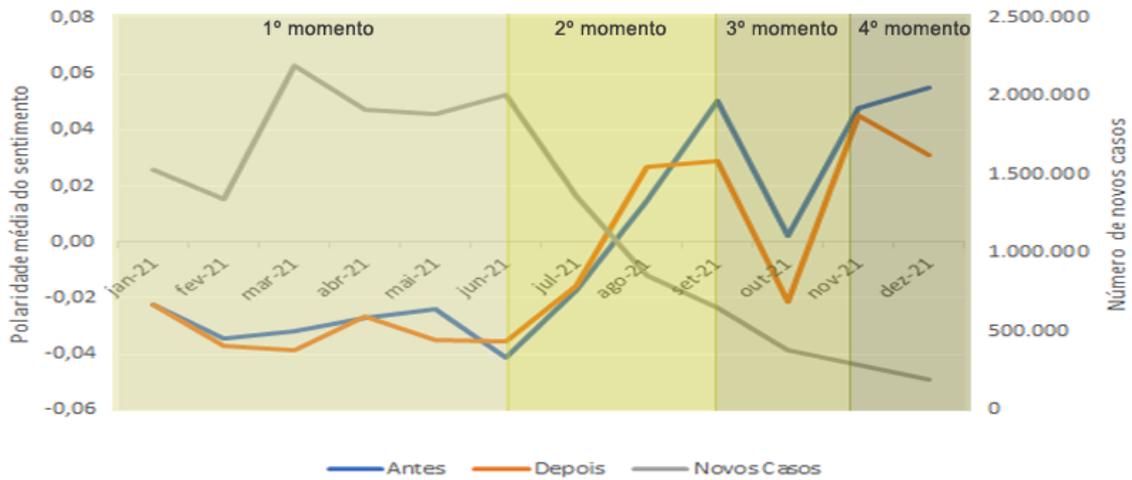
O segundo momento que destacamos nos gráficos 5.26 e 5.27, ocorrido entre junho e setembro, nos revelou uma clara inversão das tendências das curvas que representam os sentimentos e as curvas dos número de casos e mortes. Este comportamento de mudança de tendência em direções opostas reforçam a possibilidade de um relação entre a redução dos números de casos e óbitos e o aumento da positividade dos sentimentos. Portanto, entendemos que a relação existe e que este comportamento estaria ligado aos impactos positivos da vacinação no Brasil, conforme apresentado na seção 6.3.

Notadamente, no terceiro momento destacado nos gráficos 5.26 e 5.27, ocorrido durante o mês de outubro, observamos um aumento relativamente considerável do sentimento negativo. Conforme discutimos na seção 6.3, o aumento da negatividade dos sentimentos neste período não estaria relacionado ao número de casos ou óbitos, mas possivelmente às mensagens negativas ligadas aos assuntos discutidos na CPI da Covi-19.

No quarto e último momento em que dividimos nossas análises, que representa os meses de novembro e dezembro, constatamos uma positividade elevada em relação ao mês de outubro. Acreditamos que a positividade dos sentimentos que detectamos nos meses seguintes a outubro esteja relacionada ao momento posterior a entrega do relatório final da CPI da Covid-19. Zhunis et al. (2022) relatou em seu estudo, ao examinar sentimentos presentes em tweets relacionados à pandemia da Covid-19, que durante um curto prazo os usuários se concentraram seletivamente em tópicos que reforçam a emoção, posteriormente retornam a seus níveis emocionais. Neste contexto, acreditamos a conclusão da CPI da Covid-19 teria provocado a retomada dos níveis emocionais dos usuários. Entende-se que uma análise de tópicos restrita aos tweets publicados entre os meses de setembro e janeiro permitiria uma maior precisão sobre os motivos que provocaram as tendências apresentadas neste período.

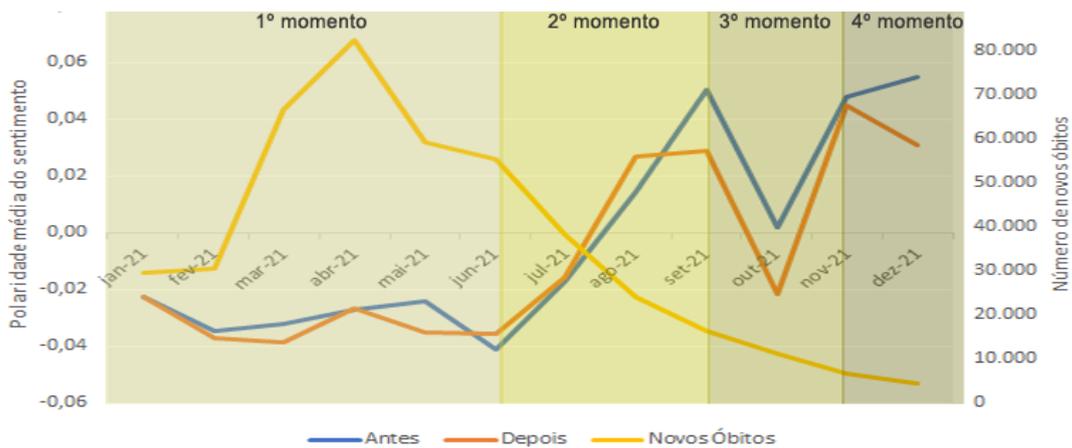
Não encontramos na literatura estudos que investigassem a relação dos números de casos ou óbitos causados pela Covid-19 e os sentimentos, em relação ao governo Bolsonaro, expressados pelas pessoas nas redes sociais durante ano de 2021. Como consequência não conseguimos comparar os achados da presente seção com os de outros autores.

Figura 6.2: Polaridade média dos sentimentos (VADER) e números de novos casos de Covid-19 por mês



Fonte: O autor (2022). Os dados relacionados aos novos casos de Covid-19 no Brasil foram retirados do site do ministério da saúde do Brasil em 06/03/2022.

Figura 6.3: Polaridade média dos sentimentos (VADER) e números de óbitos causados pela Covid-19 por mês



Fonte: O autor (2022). Os dados relacionados aos novos óbitos causados pela Covid-19 no Brasil foram retirados do site do ministério da saúde do Brasil em 06/03/2022.

6.6 Sobre as intensidades das emoções

Nas seções anteriores deste capítulo, examinamos a mudança de percepção dos usuários a partir dos sentimentos extraídos dos tweets. Entretanto, na presente seção, deixamos de explorar os sentimentos para explorar as emoções presentes nos tweets com objetivo de responder nossa subquestão **SRQ6** “Além dos sentimentos positivos, negativos e neutros, em que medida emoções como raiva, expectativa, nojo, medo, alegria, tristeza, surpresa, confiança estão presentes nos grupos de tweets postados antes e após os relatos sobre um familiar afetado pela Covid-19?”

Ao observarmos os gráficos dos grupos antes e depois do tweet base (Figura 5.29), constatamos que não ocorreram mudanças perceptíveis na força das emoções, tanto para os tweets avaliados no idioma inglês quanto para os avaliados em português. Em ambos idiomas, verificamos que as emoções que mais se destacaram foram “confiança”, “medo” e “tristeza”. A emoção “surpresa” foi a que ocorreu com menor intensidade entre todas.

Ao compararmos as tendências dos gráficos desenvolvidos a partir dos tweets do grupo “antes” no idioma inglês com o seu correspondente no idioma “português” (Figura 5.29), percebemos que a maioria das emoções apresentaram tendências relativamente próximas entre os grupos. No entanto, percebemos que as emoções “expectativa” e “alegria” apresentaram diferenças em suas intensidades em cada idioma. Atribuímos a causa destas diferenças a dois motivos: (i) problemas no processo de tradução dos tweets, conforme explicamos na seção 4.3.3; (ii) divergências na pontuação (valência da emoção) de uma mesma palavra em dicionários de idiomas diferentes, por exemplo, a classificação da palavra “president”, em relação a emoção “confiança”, tem pontuação 1 no dicionário NRC Emotion Lexicon em inglês, enquanto sua correspondência “presidente” no dicionário NRC Emotion Lexicon em português tem pontuação 2 (Figuras A.4 e A.5). Segundo, Mohammad (2021), pode haver diferenças nas emoções em diferentes culturas, por exemplo, namoro e álcool podem ser percebidos como significativamente mais negativos em algumas partes do mundo do que em outras.

Um fato nos chamou a atenção ao observar as intensidades das emoções apresentadas nos gráficos da figura 5.29: em todos os gráficos a emoção “confiança” foi a que mais se destacou. Curiosamente, observamos que outros estudos relacionados, os quais também utilizaram o dicionário NRC Emotion Lexicon para calcular as emoções presentes em sentenças, em diferentes contextos e idiomas, também relataram em suas análises uma intensidade elevada ligada a emoção “confiança” (KAUR; VERMA; OTOO, 2021), (NEHA et al., 2022), (STRACQUALURSI; AGATI, 2022), (KAUSAR; SOOSAIMANICKAM;

NASAR, 2021). Esta elevada intensidade relacionada da emoção “confiança” encontrada em diversos contextos e idiomas, sugere a possibilidade de existência de um viés relacionado à “confiança” quando utilizado o dicionário NRC Emotion Lexicon para o cálculo das emoções presentes em um texto ou sentença. Entretanto, apesar de nossa desconfiança, é preciso uma análise mais criteriosa a fim de confirmar ou rejeitar esta hipótese.

Como nesta seção não encontramos mudanças perceptíveis entre as emoções do grupo de tweets antes e depois do tweet base, em nossa próxima seção, nos aprofundamos nesta questão com o objetivo de compreender como as emoções estão predominante ligadas aos sentimentos negativos, positivos e neutros.

6.7 Sobre as emoções presentes entre os sentimentos negativos e positivos

Para responder a subquestão **SRQ7** “Em que medida as mensagens positivas são ligadas a alegria, enquanto as negativas estão mais ligadas a raiva, medo ou tristeza?”, quantificamos a intensidade das emoções presentes nos tweets positivos e negativos dos grupos antes depois do tweet base e examinamos a relação das emoções entre os sentimentos.

Considerando que a força de um sentimento está tipicamente ligada à intensidade de certas emoções (LIU, 2012) e que as emoções podem ser conceituadas em termos de pares de opostos (PLUTCHIK, 1980), na presente seção examinamos os resultados apresentados na seção 5.3.8 para responder nossa subquestão **SRQ7** “Em que medida as mensagens positivas são ligadas a alegria, enquanto as negativas estão mais ligadas a raiva, medo ou tristeza?”.

Ao observarmos os grupos antes e depois para o sentimento “Negativo” (Figura 5.30), percebemos uma tendência bastante semelhante entre ambos. As emoções mais intensas nestes grupos foram: “medo”, “confiança”, “tristeza” e “raiva”. A emoção com a menor intensidade foi “alegria”. Em relação aos tweets com sentimento “positivo”, também verificou-se uma tendência bastante semelhante entre os tweets dos grupos antes e depois do tweet base, predominando as emoções “confiança”, “expectativa”, “medo” e “alegria”, sendo “nojo” a emoção com menor intensidade. Portanto, a observação dos resultados apresentados nos revelou que a emoção “alegria” está entre as emoções predominantes nas mensagens positivas, enquanto que entre as mensagens de sentimento oposto, predominam emoções como “raiva”, “medo” e “tristeza”.

No geral, todos os gráficos apresentaram uma tendência mais forte para a emoção “confiança”, independente do sentimento e idioma, o que reforça a possibilidade de exis-

tência de um viés relacionado à “confiança” quando utilizado o dicionário NRC Emotion Lexicon para o cálculo das emoções presentes em um texto ou sentença, conforme discutido anteriormente na seção 6.6.

6.8 Sobre a intensidade dos sentimentos entre os diferentes graus de gravidade relatados

Para responder nossa subquestão de pesquisa **SRQ8** “Existe uma mudança nos sentimentos entre os diferentes graus de gravidade dos relatados?”, classificamos os tweets de acordo com o grau de gravidade extraídos dos dramas relatados pelos usuários em seus tweets base. Assim, analisamos separadamente os percentuais dos sentimentos presentes nos grupos antes e depois do tweet base dentro de cada grau de gravidade. Nossa hipótese era que quanto mais grave os relatos dos usuários, encontraríamos uma intensidade maior dos sentimentos negativos no grupo de tweets após o tweet base.

Nossos resultados, apresentados na seção 5.3.9 mostraram que os percentuais de tweets com sentimentos negativos e positivos variaram discretamente de acordo com o grau de gravidade. Os sentimentos negativos aumentaram e os positivos diminuíram à medida que o grau de gravidade aumentava. O aumento sentimento “Negativo” e a redução do sentimento “Positivo” estão presentes nos grupos de tweets após o tweet base, quando comparados entre os diferentes graus de gravidade.

Ao observarmos somente o sentimento “Negativo” nos grupos antes de depois, percebe-se um leve aumento do percentual de negatividade. O aumento da negatividade entre os grupos está presente no cálculo do sentimento realizado para os graus de gravidade “Baixo”, “Médio” e “Alto”, sendo respectivamente de 0,4%, 0,8% e 0,1%.

Em relação ao sentimento “Positivo”, nos grupos antes e depois, observou-se uma redução percentual em todos os graus de gravidade. O percentual de redução da positividade para os graus de gravidade “Baixo”, “Médio” e “Alto” foram respectivamente: 1%; 0,7%; 0,5%. A maior redução de positividade calculado ocorreu no grau de gravidade baixo, que foi de 1%, passando de 40,1% calculado no grupo de tweets antes do tweet base para 39,1% no grupo de tweets após o tweet base.

Ao comparar os resultados que obtivemos sem considerarmos o grau de gravidade da doença (seção 5.3.1) com os resultados nos quais consideramos o grau de gravidade da doença (seção 5.3.9), percebemos que existe uma diferença maior dos percentuais dos sentimentos entre os grupos antes e depois quando consideramos o grau de gravidade dos

relatos em nossa análise. Entretanto, apesar de encontrarmos uma diferença maior nos sentimentos ao considerarmos em nossa análise os diferentes graus de gravidade da doença, a diferença percentual não ocorreu de maneira proporcional aos graus de gravidades analisados, ou seja, esperávamos encontrar uma negatividade maior no grupo de tweets postados pelos usuários com relatos que classificamos como grau “Alto” e uma negatividade menor no grupo de tweets postados pelos usuários com relatos que classificamos como grau “Baixo”.

6.9 Sobre a intensidade dos sentimentos entre os diferentes graus de parentesco

Para responder nossa subquestão de pesquisa **SRQ9** “Existe uma mudança nos sentimentos entre diferentes graus de parentesco?”, classificamos os tweets de acordo com o grau de parentesco extraídos dos dramas relatados pelos usuários em seus tweets base. Assim, analisamos separadamente os percentuais dos sentimentos presentes nos grupos antes e depois do tweet base dentro de cada grau de parentesco. Nossa hipótese era que quanto mais grave os relatos dos usuário, encontraríamos uma intensidade maior dos sentimentos negativos no grupo de tweets após o tweet base.

Ao comparar os sentimentos dos grupos antes e depois do tweet base nos gráficos referentes aos entes familiares, observamos que nos gráficos que apresentam os percentuais de sentimento relacionados a “Avô e Avó” (Figura 5.37), o sentimento negativo se mantiveram com 40,2%, enquanto que o sentimento positivo reduziu levemente, passando de 38% para 36,9%; nos gráficos relacionados a “Pai e Mãe” (Figura 5.38), houve um discreto aumento do sentimento negativo, que passou de 39,9% para 40% e uma discreta redução do sentimento positivo que passou de 38,4% para 37,8%; nos gráficos relacionados a “Filho e Filha” (Figura 5.39), constatou-se uma discreta redução dos sentimentos negativo e positivos, onde o sentimento negativo passou de 36,9% para 36,7% e o sentimento positivo passou de 41,8% para 41,7%.

Quando olhamos somente para o sentimento “Negativo” nos grupos antes de depois, percebe-se um discreto aumento do percentual de negatividade somente nos gráficos que representam os percentuais de sentimento relacionados a “Pai e Mãe”, o aumento percentual para este grau de parentesco foi de 0,1%. Nos gráficos relacionados a “Avô e Avó” não houve qualquer variação e nos gráficos relacionados a “Filho e Filha”, constatou-se uma redução da negatividade de 0,2%.

Em relação ao sentimento “Positivo”, nos grupos antes de depois, observou-se uma redução percentual em todos os graus de parentesco. O percentual de redução da positi-

vidade para “Avô ou Avó”, “Pai ou Mãe” e “Filho e Filha” foram respectivamente: 1,1%; 0,6%; 0,1%. A maior redução de positividade ocorreu no segundo grau de parentesco (avô e avó), que foi de 1,1%, passando de 38% calculado no grupo de tweets antes do tweet base para 36,9% no grupo de tweets após o tweet base.

De maneira geral, percebemos que os percentuais de tweets com sentimentos negativos e positivos variaram discretamente de acordo com o grau de parentesco. Os sentimentos negativos aumentaram e os positivos diminuíram à medida que o grau de parentesco aumentava. Constatamos que o aumento sentimento “Negativo” e a redução do sentimento “Positivo” estão presentes nos grupos de tweets antes e após o tweet base, quando comparados entre os diferentes graus de parentesco.

6.10 Sobre as avaliações manuais

Nesta seção, discutimos os resultados obtidos nas duas avaliações manuais, comparando os resultados das avaliações manuais destes tweets com as classificações automáticas calculadas pelas diferentes ferramentas.

Com objetivo de compreender os motivos relacionados aos problemas de tradução e classificação automática de sentimentos observados (seção 4.3.3), em cada um dos nossos dois experimentos extraímos uma amostra de tweets e realizamos uma análise sobre estes tweets usando um aplicativo web que desenvolvemos, que permitiu que pessoas avaliassem os tweets manualmente. Conforme apresentado nas seções 4.2.3 e 5.2.3, em cada um dos experimentos, solicitamos às pessoas que classificassem os tweets, porém de maneira diferente em cada experimento. Enquanto no primeiro experimento geramos uma amostra com tweets que continham termos de difícil compreensão para os tradutores automáticos e solicitamos aos usuários que classificassem os tweets de acordo com o número de termos “positivos”, “negativos” e “neutros” que fossem observados em cada tweet, no nosso segundo experimento, selecionamos uma nova amostra aleatoriamente e solicitamos aos participantes que classificassem os tweets de acordo com o sentimento identificado no tweet, do ponto de vista de quem o postou.

Relembramos aqui que os termos de difícil compreensão para os tradutores automáticos foram percebidos em nosso primeiro experimento, durante a análise dos resultados de nossas nuvens de palavras, apresentada na seção 4.3.3. Portanto, como estes termos se destacaram entre as palavras mais frequentes, acreditamos que seria necessário quantificar a frequência em que cada um deles apareceram nas mensagens. Sendo assim, verificamos que “Genocida” foi o mais frequente, aparecendo em 192 tweets das 650 avaliações, se-

guido das palavras “Lula” e “CPI” com, respetivamente, 137 e 127 tweets. A tabela 6.2 apresenta a quantidade de tweets em que cada um dos termos estava presente.

Tabela 6.2: Quantidade de tweets para cada um dos termos de difícil compreensão considerados na amostra para classificação se sentimentos manual

Termo	Tweets
Genocida	192
Lula	137
CPI	127
ForaBolsonaro	110
Impeachment	46
Pfizer	21
29M	17
Total	650

Fonte: O autor (2022).

Após a classificação manual dos tweets executada em nosso primeiro experimento, comparamos os resultados com a classificação automática e descobrimos que dos 650 tweets, 54% obtiveram correspondência entre classificação manual e automática para os sentimentos “Negativo”, “Positivo” e “Neutro”. Ao considerarmos as intensidades “Forte”, “Médio” e “Frac” dentro de cada sentimento, constatamos que a correspondência foi de aproximadamente 18% somente. Portanto, a fim de compreender os motivos que ocasionaram uma baixa correspondência entre as classificações automáticas e manuais, inspecionamos alguns tweets e tentamos atribuir alguns prováveis motivos. A tabela 6.3 apresenta alguns exemplos de tweets em que os sentimentos calculados de forma automática não corresponderam com a avaliação manual.

Tabela 6.3: Exemplos de tweets cujos sentimentos calculados de forma automática não corresponderam com a avaliação manual

Id	Texto Original	Inglês (tradução)	Avaliação Automática (VADER)	Avaliação Manual
t1	O povo tá ofendido pq colocaram o Bolsonaro de peruca pra representar a mãe da Sarah? Se gostam dele pq estão putos ? Eu ia ficar muito feliz se colocassem o Lula de peruca pra representar minha mãe. Ela até ia rir...	Are the people offended why did they put Bolsonaro in a wig to represent Sarah's mother?If you like him why are they kids ?I was going to be very happy if they put the wig squid to represent my mother. She even laughing ...	Positivo Forte	Negativo Fraco
t2	Eu fico extremamente incomodada quando as pessoas querem igualar Lula a Bolsonaro. Para mim, a diferença entre ambos é clara: 80 milhões de vacinas em três meses x 270 mil mortes em um ano.	I get extremely uncomfortable when people want to match Lula to Bolsonaro. For me, the difference between them is clear: 80 million vaccines in three months x 270,000 deaths in one year.	Negativo Médio	Positivo Médio
t3	Bom dia pra você que sabe que mais importante do que ficar reclamando ser contra ou a favor do lockdown é pressionar o genocida a acelerar a produção/compra de vacinas. #BolsonaroGenocida	Good morning to you who knows that more important than complaining about being against or in favor of Lockdown is pressuring genocide to accelerate the production/purchase of vaccines.	Positivo Forte	Negativo Médio
t4	@BErratico @die_go_ferr @ArthurWeint @felipeneto Não estou dizendo que Bolsonaro não tem direito de processar quem o chama de genocida , mas se o fizer, tem que ser com base no Código Penal, (art. 138), e o mérito, ai vê no processo. Pode caber até, exceção da verdade (CP 138 § 3º art 141, I)	I am not saying that Bolsonaro has no right to process who calls him genocide , but if he does, it has to be based on the Penal Code, (art. 138), and the merit, he sees in the process. May fit, except for the truth (cp 138 § 3º Art 141, i)	Positivo Médio	Neutra
t5	Será q @randolfeap já ta dormindo? Espero q tenha se alimentado bem e q tenha uma ótima noite de sono pra acordar renovado e acabar com o governo na CPI	Are you already sleeping? I hope you fed well and have a great night's sleep to wake up renewed and end the government at CPI	Positivo Forte	Negativo Fraco

Fonte: O autor (2022).

A inspeção que realizamos sobre a amostra de tweets avaliados manualmente em nosso primeiro experimento, nos revelou alguns motivos que poderiam explicar a baixa correspondência que encontramos entre os sentimentos calculados de maneira automática e manual. Entre eles, observamos: (i) problemas na tradução para o inglês, em que o tradutor automático, por não identificar o contexto onde o texto estava inserido ou o correto idioma de origem, utilizou como tradução palavras que não faziam sentido para a tradução; (ii) ausência de palavras relevantes, relacionadas ao contexto pesquisado, no dicionário léxico utilizado pela ferramenta de análise de sentimentos; (iii) dificuldade dos usuários em classificarem os tweets manualmente. Inspecionamos alguns tweets e apre-

sentamos alguns exemplos na tabela 6.3. Para cada um destes tweets, levantamos motivos para a não correspondência entre a avaliação automática e manual, conforme segue:

- **t1** — O tweet contém uma mensagem que consideramos complexa até mesmo para interpretação do sentimento realizada por um humano. Além disso, devido a problemas no processo de tradução automático, percebemos que o nome do presidente Lula foi traduzido para “squid”, indicando que o tradutor não compreendeu o contexto da mensagem. Observamos também que a palavra, em português “putos” foi traduzida para “kids”, possivelmente isso ocorreu devido a ferramenta de tradução automática que utilizamos não ter conseguido diferenciar a língua portuguesa do Brasil e Portugal durante a tradução desta mensagem. Atualmente o Google-Translate API suporta mais 100 idiomas ⁵, entretanto não é possível definirmos que desejamos a tradução para um texto de origem português do Brasil ou outro país que utilize este idioma, como Portugal.
- **t2** — A avaliação manual nos pareceu incoerente, pois o tweet contém palavras que carregam o sentimento negativo, como “incomodada” e “morte”. Ressaltamos que nossa avaliação manual contou com apenas a avaliação de uma única pessoa por tweet. Destacamos a boa qualidade da tradução deste tweet para o inglês.
- **t3** — A falta da palavra “genocide” no dicionário léxico utilizado pela ferramenta de análise de sentimentos (VADER), fez com que a sentença fosse avaliada como “Positiva”. Realizamos um teste adicionando a palavra “genocide”⁶ ao dicionário do VADER e o resultado foi “Negativo médio”.
- **t4** — A falta da palavra “genocide” no dicionário léxico utilizado pela ferramenta de análise de sentimentos (VADER), fez com que a sentença fosse avaliada como “Positivo Forte”. Realizamos um teste adicionando a palavra “genocide” ao dicionário do VADER e o resultado foi “Positivo Fraco”. Isto não permitiu a correspondência entre a avaliação automática e manual, porém as aproximou.
- **t5** — Da maneira como o analisador realiza o cálculo do sentimento, ou seja, quantificando palavras negativas, positivas e neutras, esta mensagem pode ser considerada positiva. Porém, em relação ao governo Bolsonaro, trata-se de uma percepção negativa.

⁵<<https://translate.google.com/about/languages/>>

⁶Atribuimos à palavra “genocide”, que adicionamos como teste no dicionário do VADER, a mesma pontuação da palavra “killer”, já existente no dicionário. Apesar de acreditamos que “genocida” tenha uma negatividade ainda maior que “killer”, a atribuição a mesma pontuação de “killer” bastou para confirmar nossa hipótese de que a ausência de “genocida” no dicionário foi o motivo para que o tweet fosse classificado como “positivo”.

Após inspeção de uma pequena amostra de tweets que apresentaram divergências entre a classificação automática e manual dos sentimentos, constatamos que falhas de tradução, causadas pela adoção de tradutores automáticos, e a utilização de ferramentas de PLN, apoiadas em dicionários léxicos para análise de sentimentos que não contenham palavras relevantes no contexto estudado, podem contribuir para um resultado impreciso na classificação dos sentimentos presentes nas mensagens.

Constatadas as causas relacionadas aos problemas de tradução automática e classificações incorretas de termos que identificamos durante nosso primeiro experimento, observamos que os mesmos problemas ocorreriam em nosso segundo experimento. Isto porque mantivemos o processo de tradução automática e ferramentas de PLN apoiadas em dicionários léxicos como meio para calcular os sentimentos presentes nos tweets. Para compreender se, mesmo com as limitações citadas, outras ferramentas de análise de sentimentos apresentariam resultados mais expressivos relacionados à mudança de percepções dos usuários antes e depois do tweet base, em nosso segundo experimento, calculamos os sentimentos presentes nos tweets, traduzidos para o inglês, a partir de três ferramentas: VADER, Textblob e Polyglot. Além disso, também calculamos os sentimentos presentes nos tweets em português utilizando o Polyglot. O que observamos, após análise dos resultados sobre as intensidades dos sentimentos (seção 5.3.1) foi que em todas as ferramentas houve apenas discretas variações dos percentuais de cada sentimento calculados entre os grupos de tweets antes e depois do tweet base. Porém, notamos algumas diferenças perceptíveis entre as tendências dos percentuais de cada sentimento calculados por cada uma das ferramentas utilizadas neste segundo experimento.

As diferenças nas tendências dos percentuais calculados pelas ferramentas utilizadas em nosso segundo experimento, para os mesmos tweets, nos deixou em dúvida sobre qual ferramenta teria apresentado o melhor desempenho para a classificação dos sentimentos dos tweets no contexto da nossa pesquisa. Como não dispúnhamos de um dataset classificado relacionado ao contexto de nossa pesquisa para que calculássemos a acurácia dos classificadores que utilizamos (VADER, Textblob e Polyglot), consideramos o resultado das avaliações manuais para avaliar o desempenho das ferramentas, comparando os sentimentos de cada um dos tweets que foram calculados de maneira automática com os resultados que obtivemos por meio de nossa avaliação manual. Além disso, visamos compreender em que medida houve correspondência entre as classificações automáticas comparando as classificações das ferramentas entre si.

Para compreender em que medida houve correspondência entre as classificações automáticas e manuais, comparamos os sentimentos “Negativos”, “Positivos” e “Neutros” atribuídos aos tweets, por cada uma das ferramentas, com as classificações manuais que

foram atribuídas aos mesmos tweets. Apresentamos os números e os percentuais de tweets em que houve correspondência entre as classificações automáticas e manuais na tabela 6.4.

Tabela 6.4: Quantidade de tweets em que houve correspondência entre as classificações automáticas e manual realizada em nosso segundo experimento.

	n (%)
VADER	915 (45)
Polyglot (En)	858 (42)
Polyglot (Pt)	807 (39)
Textblob	705 (34)

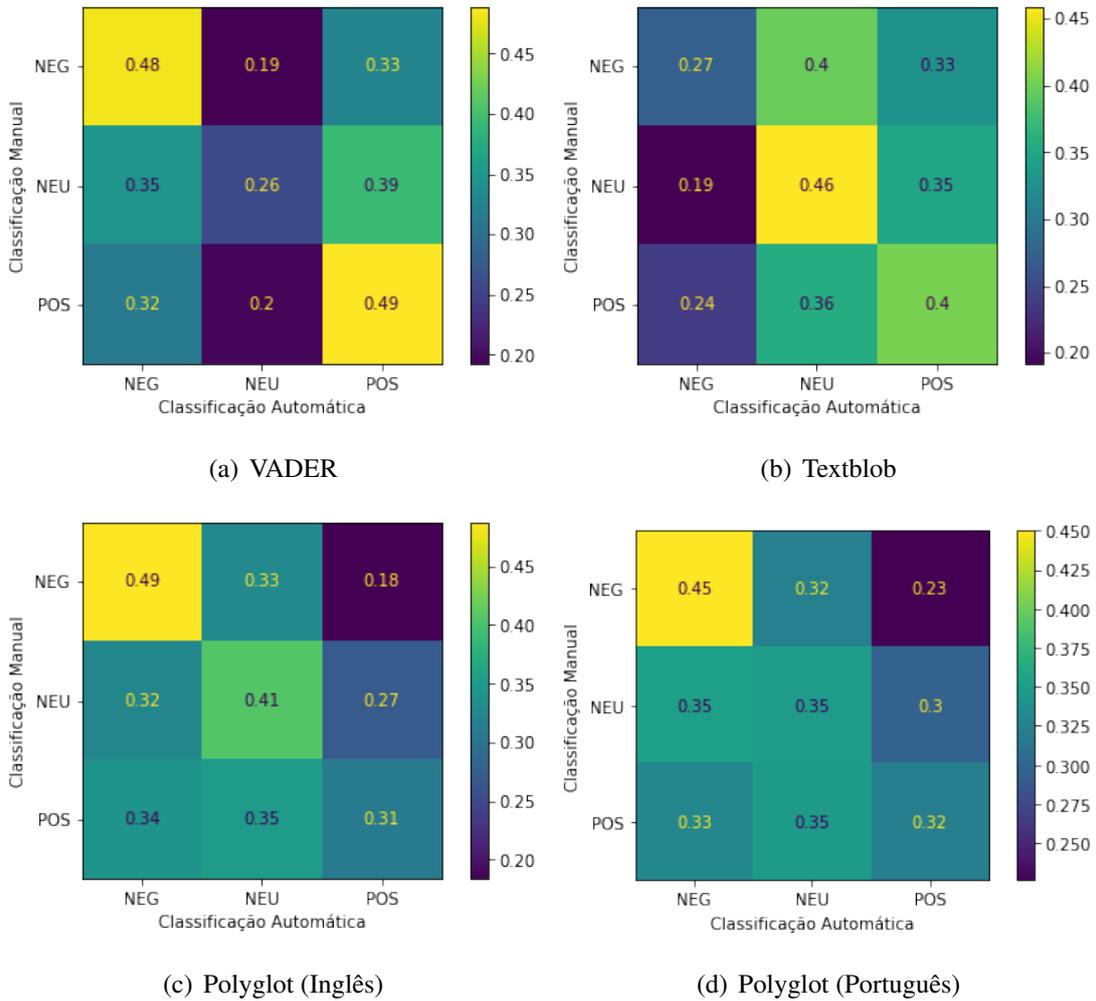
Fonte: O autor (2022).

Ao observar as correspondências entre as classificações manuais e automáticas apresentados na tabela 6.4, constatamos que, de maneira geral, a ferramenta que obteve a maior correspondência com a classificações manuais foi o VADER, que obteve com 45% de correspondência, seguido pelo Polyglot, com 42% para o texto no idioma Inglês e 39% para o texto em português. A ferramenta que obteve a menor correspondência foi o Textblob, com 34%.

Quando consideramos apenas os números de correspondências para a ferramenta Polyglot, percebemos que o idioma inglês, mesmo com os tweets traduzidos pelo processo de tradução automática, obteve uma correspondência maior que o português, este fato se alinha com o estudo de Pereira (2021), em que o autor conclui que traduzir textos para o inglês e utilizar ferramentas desenvolvidas para aquela língua é mais eficaz do que aplicar ferramentas e esforços específicos em português.

A figura 6.4 apresenta de maneira mais detalhada a correspondência entre as classificações automáticas e manuais, para os sentimentos “Negativos”, “Positivos” e “Neutros”, por meio de uma matriz de confusão, que permite a comparação da correspondência percentual entre os sentimentos calculados automaticamente por cada um dos classificadores com a classificação manual.

Figura 6.4: Correspondência entre as classificações automáticas e manuais

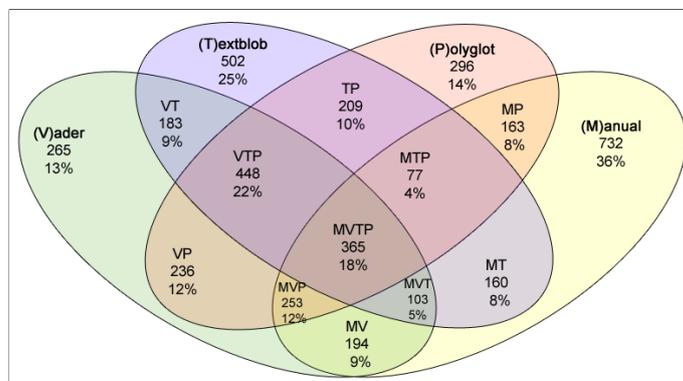


Fonte: O autor (2022).

Após a comparação dos sentimentos de cada um dos tweets, que foram calculados de maneira automática, com os resultados que obtivemos por meio de nossa avaliação manual, buscamos compreendermos o quanto as ferramentas utilizadas para classificação automática dos sentimentos convergiram entre si. Para isto, desenvolvemos um diagrama (Figura 6.5) que apresenta percentual de correspondência entre as classificações dos sentimentos realizadas por cada uma das ferramentas e também entre as classificações manuais. No diagrama, as intersecções apresentam o número e o percentual de tweets em que houve correspondência entre os sentimentos “positivos”, “negativos” e “neutros” que foram calculados pelas ferramentas VADER, Textblob e Polyglot e os sentimentos que foram classificados de forma manual, representados por cada um dos conjuntos. O conjunto que denominamos “(P)olyglot” representa as classificações dos tweets, cujos sentimentos foram calculados a partir do idioma inglês. O conjunto dos tweets, cujos sentimentos foram calculados pelo Polyglot a partir do idioma português não está representado no

diagrama, pois comparamos aqui somente as correspondências dos tweets que passaram pelo processo de tradução automática.

Figura 6.5: Correspondência entre as classificações dos sentimentos realizadas por cada uma das ferramentas e também entre as classificações manuais.



Fonte: Twitter (2022).

No diagrama (Figura 6.5), ao observarmos a intersecção “MVTP”, a qual representa o percentual de classificações correspondentes entre as ferramentas VADER, Textblob e Polyglot e também a manual, percebemos que apenas em 18% das classificações houve correspondência entre todos os meios que utilizamos para inferir o sentimento contido nos tweets analisados. Além disso, quando olhamos para a intersecção “VTP”, intersecção que representa o percentual de correspondência apenas entre classificações automáticas, percebemos também uma baixa correspondência de 22%.

Percebemos que houve uma variação quando realizamos a mesma comparação da intersecção “MVTP”, porém considerando os graus de subjetividade “Fracó”, “Médio” e “Forte”, que calculamos a partir dos tweets (seção 5.3.5), sendo respectivamente de 10%, 23% e 29%. Sendo assim, apesar de em nossa análise restrita aos tweets mais subjetivos (seção 5.3.5) não termos encontrado resultados mais claros sobre a mudança de percepção entre os grupos do que quando comparamos os sentimentos dos grupos antes e depois sem considerar a subjetividade (seção 5.3.1), o aumento da correspondência dos sentimentos classificados de maneira automática e manual considerando o grau de subjetividade, nos indicou que houve uma maior precisão na comparação dos sentimentos dos grupos antes e depois quando consideramos o grau de subjetividade dos tweets na seção (seção 5.3.5).

O alto percentual de discordância que encontramos ao compararmos as classificações de sentimentos fornecidas por diferentes ferramentas, se alinha ao estudo publicado por Jung, Salminen e Jansen (2022), em que os autores após comparar grandes ferramentas comerciais de análise de sentimentos, como Microsoft Azure, IBM Watson, Google Cloud e Amazon Web Services, constataram que as quatro ferramentas atribuíram o mesmo sen-

timento em menos da metade (48%) do conteúdo analisado. Portanto, de acordo com as elevadas taxas de divergências que encontramos entre as classificações dos sentimentos fornecidos pelas ferramentas utilizadas neste estudo e também as diferentes taxas de correspondências com as classificações realizadas por humanos, percebemos que as ferramentas selecionadas podem afetar o resultado pretendido. Além disso, considerando as ferramentas adotadas neste estudo para a análise de sentimentos (VADER, Textblob e Polyglot), entendemos que, do ponto de vista de PLN, ainda existem muitos desafios relacionados a necessidade de aprimoramentos, principalmente quando analisamos um contexto muito específico como a pandemia da Covid-19, a partir de tweets que até mesmo para avaliação feita por humanos, em alguns casos são incompreensíveis.

7. Conclusão

No presente estudo, objetivamos desenhar um processo capaz de identificar mudanças na percepção das pessoas em relação ao governo Bolsonaro durante a pandemia de Covid-19, com base em tweets e no fato de essas pessoas terem um familiar afetado pela Covid-19.

Como forma de alcançar nosso objetivo, realizamos dois experimentos, baseados na abordagem metodológica quantitativa. Em cada experimento, coletamos tweets publicados que continham relatos de dramas familiares causados pela Covid-19. A partir destes tweets, coletamos outros tweets destes mesmos usuários, antes e após o fato publicado por cada uma deles. E então, buscamos identificar se houve mudança na percepção destas pessoas em relação ao governo Jair Bolsonaro, por meio da quantificação e comparação das intensidades dos sentimentos presentes nos grupos de tweets antes e após os relatos sobre seus dramas familiares. Subsidiámos nossas análises na questão de pesquisa: "as percepções das pessoas em relação ao governo Bolsonaro mudam após elas relatarem, nas redes sociais, um familiar acometido pela Covid-19?".

Para responder nossa questão de pesquisa, nos apoiamos em subquestões de pesquisa em que analisamos não só as intensidades dos sentimentos dos grupos de tweets antes e após os relatos sobre seus dramas familiares acometido pela Covid-19, mas também comparamos termos mais frequentemente utilizados entre os dois grupos, investigamos a polarização dos sentimentos no período pesquisado, a relação dos sentimentos e o número de casos e mortes, a relação dos sentimentos com as emoções, investigamos o quão próximos os usuários eram de seus entes queridos acometidos pela Covid-19 e como gravidade da doença impactou os sentimentos dos usuários em relação ao governo Jair Bolsonaro.

Descobrimos que o sentimento geral das pessoas em relação ao governo Bolsonaro variaram muito discretamente, tanto quando analisamos o período correspondente ao ápice da pandemia da Covid-19, quanto analisamos todo o ano de 2021. Nossos resultados, não

revelaram importantes mudanças na percepção das pessoas sobre o governo Jair Bolsonaro antes e após elas relatarem no Twitter seus dramas familiares causados pela Covid-19.

Consideramos que uma das contribuições desta pesquisa está no processo de coleta e análise de tweets proposto. Além disso, alguns achados interessantes foram relatados neste estudo, como baixa correspondência entre os sentimentos dos tweets fornecidos por diferentes ferramentas, além da baixa correspondência entre os sentimentos fornecidos de maneira automática e manual. Também verificamos a dificuldade dos usuários em classificar os tweets manualmente.

7.1 Limitações do estudo

Reconhecemos algumas limitações em nosso estudo: (i) os tweets coletados para este estudo estavam em português e precisaram ser traduzidos para o inglês, uma vez que adotamos ferramentas que não possuem um dicionário lexical para a língua portuguesa, como o modelo VADER e o Textblob; (ii) as ferramentas utilizadas para análise de sentimentos não possuíam em seus dicionários léxicos algumas palavras relacionadas ao contexto estudado, embora essa limitação poderá não ocorrer em um contexto mais geral e não tão específico quanto uma pandemia; (iii) o período de coleta de dados para os tweets dos usuários também foi restrito a uma janela de tempo de 30 dias antes e 30 dias após o tweet de base. Essa janela de tempo pode ser expandida ou reduzida para investigar uma possível diferença nos sentimentos dos usuários considerando períodos mais longos ou mais curtos; (iv) em nosso processo de coleta de tweets bases, não consideramos em nossa string de busca termos que possibilitassem a identificação mais precisa sobre o momento em que o familiar relatado no tweet foi acometido pela Covid-19. Reconhecemos que durante uma inspeção visual que realizamos a fim de avaliar a qualidade dos tweets bases coletados, verificamos a presença de relatos sobre fatos ocorridos relativamente distantes da data de publicação dos relatos, como por exemplo: “Um ano que meu pai morreu pra COVID” ou “Hoje é a missa de um mês que a minha avó faleceu em decorrência da covid-19. Quem puder, mande oração.”; (v) para este estudo não consideramos nenhum mecanismo de detecção de sarcasmos nas mensagens. Mensagens sarcásticas expressam opiniões negativas usando palavras positivas (KHARDE; SONAWANE et al., 2016), consequentemente ao utilizarmos analisadores léxicos, a presença de sarcasmos poderia gerar uma imprecisão no cálculo dos sentimentos dos tweets; (vi) em nossa análise apresentada na seção 5.3.10, nos casos em que o tweet possuía mais de um termo designando entes familiares diferentes, rotulamos estes tweets com múltiplos rótulos, um para cada ente

familiar acometido pela Covid-19 identificado na mensagem contida no tweet base. No entanto, reconhecemos aqui uma limitação, visto que o tweet base poderia estar relando o problema com um familiar, mas mencionar um outro como apoio por exemplo; ou podem haver várias combinações problema x ente familiar. A superação dessa limitação poderia revelar resultados mais claros na análise de intensidade dos sentimentos entre os diferentes graus de parentesco.

7.2 Trabalhos futuros

Este estudo cria vários caminhos para pesquisas futuras. Utilizamos analisadores léxicos para extrair os sentimentos expressos nos tweets. No entanto, frente ao fato de que a análise de sentimentos é uma área em constante evolução, a metodologia proposta por esta pesquisa possibilita que novos estudos adotem diferentes abordagens para entender as opiniões das pessoas sobre governos (ou em outros contextos) antes e depois de eventos individuais vividos e relatados por estas pessoas nas redes sociais. Diante de um conjunto de tweets relacionados ao contexto pesquisado, com os sentimentos previamente rotulados, técnicas de *supervised machine learning* poderiam ser aplicados como uma alternativa para extração dos sentimentos dos usuários. Adicionalmente, incluir aspectos qualitativos peculiares possibilitariam um melhor entendimento sobre as opiniões dos usuários que ainda não foram possíveis capturar de maneira automática neste estudo.

Consideramos a investigação da mudança da percepção individual como um ponto de extensão para nosso estudo, já que observamos os grupos de tweets antes e depois do tweet base, mas não investigamos se cada usuário individual mudou de opinião sobre o governo depois de postar um relato sobre alguém próximo acometido pela Covid-19. Além disso, a análise de uma mudança de percepção dos usuários sobre perspectivas regionais ou de gênero, poderiam revelar outros resultados.

Desejamos aplicar nossa metodologia para outros tipos de eventos a fim de testar se é possível detectar mudanças nas percepções das pessoas em outros contextos. No presente estudo, buscamos identificar em que medida a percepção das pessoas mudaram em relação ao governo Jair Bolsonaro após relatarem um ente familiar que foi acometido pela Covid-19, porém nossa metodologia poderia ser utilizada, de maneira geral, para investigar a que as pessoas atribuem as causas de eventos vivenciados por elas. Nesta pesquisa, além de testarmos nossa hipótese sobre a mudança de percepção das pessoas, realizamos uma análise sobre a correspondência dos sentimentos fornecidos por diferentes ferramentas de análise de sentimentos para os mesmos tweets. Fizemos esta análise de maneira

geral, entretanto consideramos que novas pesquisas possam aprofundar esta análise para compreender também o percentual de correspondência dentro de cada um dos sentimentos “Negativos”, “Neutros” e “Positivos” separadamente.

Portanto, entendemos que do ponto de vista de processamento de linguagem natural, ainda existem muitos desafios relacionados a necessidade de aprimoramento das ferramentas disponíveis. Do ponto de vista de Sistemas de Informação, compreendemos ser necessário ressaltar à comunidade as limitações relacionadas ao que é oferecido pelas ferramentas de processamento automático, especialmente em contextos específicos, como no caso desta pesquisa.

Referências Bibliográficas

- AHUJA, R.; SHARMA, S. C. Transformer-based word embedding with cnn model to detect sarcasm and irony. **Arabian Journal for Science and Engineering**, Springer, v. 47, n. 8, p. 9379–9392, 2022.
- ALLCOTT, H.; GENTZKOW, M. Social media and fake news in the 2016 election. **Journal of Economic Perspectives**, American Economic Association, v. 31, n. 2, p. 211–236, maio 2017. Disponível em: <<https://doi.org/10.1257/jep.31.2.211>>.
- ALSAEEDI, A.; KHAN, M. Z. A study on sentiment analysis techniques of twitter data. **International Journal of Advanced Computer Science and Applications**, v. 10, n. 2, p. 361–374, 2019.
- ALSHAMMARI, T. M.; ALTEBAINAWI, A. F.; ALENZI, K. A. Importance of early precautionary actions in avoiding the spread of covid-19: Saudi arabia as an example. **Saudi Pharmaceutical Journal**, Elsevier, v. 28, n. 7, p. 898–902, 2020.
- BAKSHI, R. K.; KAUR, N.; KAUR, R.; KAUR, G. Opinion mining and sentiment analysis. In: **2016 3rd International Conference on Computing for Sustainable Global Development (INDIACom)**. [S.l.: s.n.], 2016. p. 452–455.
- BAVEL, J. J. V.; PEREIRA, A. The partisan brain: An identity-based model of political belief. **Trends in cognitive sciences**, Elsevier, v. 22, n. 3, p. 213–224, 2018.
- BOULIANNE, S.; LARSSON, A. O. Engagement with candidate posts on twitter, instagram, and facebook during the 2019 election. **new media & society**, SAGE Publications Sage UK: London, England, p. 14614448211009504, 2021.
- CAMILLE, C.; BEATRIZ, P. Internações por covid-19 duram, em média, 22 dias, aponta pesquisa. URL:<https://www.cnnbrasil.com.br/saude/2021/03/15/internacoes-por-covid-19-duram-em-media-22-dias-aponta-pesquisa>, 2021. (accessed: 06.10.2021).
- CHEN, Y.; SKIENA, S. Building sentiment lexicons for all major languages. In: **Proceedings of the 52nd Annual Meeting of the Association for Computational Linguistics (Short Papers)**. [S.l.: s.n.], 2014. p. 383–389.
- CLASSE, T. M. de; SILVA, A. V.; JUNIOR, C. D. O. P.; NARDI, L.; LOUTFI, M. S.; REMÉDIOS, S. E. L. D.; GOMES, S. V. Alinhamentos temáticos com a cibercultura:

Reflexões em uma disciplina no ciberespaço. In: **ABCIBER XIII-SIMPÓSIO NACIONAL DA ABCIBER 2020**. [S.l.: s.n.], 2021.

COLETTA, R. D.; SALDAÑA, P. 'acabou matéria no jornal nacional', diz bolsonaro sobre atraso em divulgação de boletim da covid-19. **URL:**<https://www1.folha.uol.com.br/equilibrioesaude/2020/06/acabou-materia-no-jornal-nacional-diz-bolsonaro-sobre-atraso-em-divulgacao-de-boletim-da-covid-19.shtml>, 2020. (accessed: 05.03.2022).

CROKIDAKIS, N. Covid-19 spreading in rio de janeiro, brazil: do the policies of social isolation really work? **Chaos, Solitons & Fractals**, Elsevier, v. 136, p. 109930, 2020.

DUBEY, A. D. Twitter Sentiment Analysis during COVID19 Outbreak. **SSRN Electronic Journal**, 2020. ISSN 1556-5068. Disponível em: <<https://www.ssrn.com/abstract=3572023>>.

ELBAGIR, S.; YANG, J. Twitter sentiment analysis using natural language toolkit and vader sentiment. In: **Proceedings of the international multiconference of engineers and computer scientists**. [S.l.: s.n.], 2019. v. 122, p. 16.

ENDSUY, R. D. Sentiment analysis between vader and eda for the us presidential election 2020 on twitter datasets. **Journal of Applied Data Sciences**, v. 2, n. 1, p. 08–18, 2021.

ESTRADA, C. D.; NÓBREGA, L. Covid-19: balanço de dois anos da pandemia aponta vacinação como prioridade. **URL:**<https://www.fiocruzbrasil.fiocruz.br/covid-19-balanco-de-dois-anos-da-pandemia-aponta-vacinacao-como-prioridade>, 2022. (accessed: 05.03.2022).

FELDMAN, R. Techniques and applications for sentiment analysis. **Communications of the ACM**, ACM New York, NY, USA, v. 56, n. 4, p. 82–89, 2013.

FERNANDO, S.; LÓPEZ, J. A. D.; ŞERBAN, O.; GÓMEZ-ROMERO, J.; MOLINA-SOLANA, M.; GUO, Y. Towards a large-scale twitter observatory for political events. **Future Generation Computer Systems**, Elsevier, v. 110, p. 976–983, 2020.

FILHO, C. F. R.; DANIEL-RIBEIRO, C. T.; TABAK, D. G.; SILVA, D. C. Baia-da-TEMPORÃO, J. G.; LACERDA, M. V. G.; DALCOLMO, M. P.; SCHECHTER, M.; TASCHNER, N. P.; BRASIL, P. et al. Nota sobre o uso da cloroquina/hidroxicloroquina para o tratamento da covid-19. ENSP/Fiocruz, 2020.

FREIRE, N. P.; CUNHA, I. C. K. O.; NETO, F. R. G. X.; MACHADO, M. H.; MINAYO, M. C. d. S. A infodemia transcende a pandemia. **Ciência & Saúde Coletiva**, SciELO Public Health, v. 26, p. 4065–4068, 2021.

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, 2021. ISSN 1568-4946. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S1568494620309959>>.

HETTIACHCHI, D.; ARORA, T.; GONCALVES, J. Us vs. them—understanding the impact of homophily in political discussions on twitter. In: SPRINGER. **IFIP Conference on Human-Computer Interaction**. [S.l.], 2021. p. 476–497.

HITESH, M.; VAIBHAV, V.; KALKI, Y. A.; KAMTAM, S. H.; KUMARI, S. Real-time sentiment analysis of 2019 election tweets using word2vec and random forest model. In: IEEE. **2019 2nd International Conference on Intelligent Communication and Computational Techniques (ICCT)**. [S.l.], 2019. p. 146–151.

JOCKERS, M. Package ‘syuzhet’. URL: <https://cran.r-project.org/web/packages/syuzhet>, 2017.

JUNG, S.-G.; SALMINEN, J.; JANSEN, B. J. Engineers, aware! commercial tools disagree on social media sentiment: Analyzing the sentiment bias of four major tools. **Proceedings of the ACM on Human-Computer Interaction**, ACM New York, NY, USA, v. 6, n. EICS, p. 1–20, 2022.

KAUR, M.; VERMA, R.; OTOO, F. N. K. Emotions in leader’s crisis communication: Twitter sentiment analysis during covid-19 outbreak. **Journal of Human Behavior in the Social Environment**, Routledge, v. 31, n. 1-4, p. 362–372, 2021. Disponível em: <<https://doi.org/10.1080/10911359.2020.1829239>>.

KAUSAR, M. A.; SOOSAIMANICKAM, A.; NASAR, M. Public sentiment analysis on twitter data during covid-19 outbreak. **International Journal of Advanced Computer Science and Applications**, Science and Information (SAI) Organization Limited, v. 12, n. 2, 2021.

KHARDE, V.; SONAWANE, P. et al. Sentiment analysis of twitter data: a survey of techniques. **arXiv preprint arXiv:1601.06971**, 2016.

KIM, S.-M.; HOVY, E. Automatic identification of pro and con reasons in online reviews. In: **Proceedings of the COLING/ACL 2006 Main Conference Poster Sessions**. Sydney, Australia: Association for Computational Linguistics, 2006. p. 483–490. Disponível em: <<https://www.aclweb.org/anthology/P06-2063>>.

KISSLER, S. M.; TEDIJANTO, C.; GOLDSTEIN, E.; GRAD, Y. H.; LIPSITCH, M. Projecting the transmission dynamics of sars-cov-2 through the postpandemic period. **Science**, American Association for the Advancement of Science, v. 368, n. 6493, p. 860–868, 2020.

KRIPPENDORFF, K. **Content analysis: An introduction to its methodology**. [S.l.]: Sage publications, 2018.

LAURENCE, B. Análise de conteúdo. **São Paulo: Edições**, v. 70, p. 276, 2011.

LEMOS, V. Famílias de vítimas da covid-19 recorrem à pgr para responsabilizar bolsonaro por conduta na pandemia. URL: <https://www.bbc.com/portuguese/brasil-57575497>, 2021. (accessed: 15.04.2022).

LIU, B. Sentiment analysis and opinion mining. **Synthesis lectures on human language technologies**, Morgan & Claypool Publishers, v. 5, n. 1, p. 1–167, 2012.

LORIA, S. textblob documentation. **Release 0.15**, v. 2, 2018.

LOUTFI, M.; TIBAU, M.; SIQUEIRA, S. W. M.; NUNES, B. P. Covidtrends: Identifying behaviors during the covid-19 pandemic: An analysis based on google trends and news. In: **XVII Brazilian Symposium on Information Systems**. [S.l.: s.n.], 2021. p. 1–8.

- MALIK, M.; MALIK, M. M. Critical technical awakenings. **Journal of Social Computing**, TUP, v. 2, n. 4, p. 365–384, 2021.
- MEDFORD, R. J.; SALEH, S. N.; SUMARSONO, A.; PERL, T. M.; LEHMANN, C. U. An “*Infodemic* ”: Leveraging High-Volume Twitter Data to Understand Public Sentiment for the COVID-19 Outbreak. [S.l.], 2020. Disponível em: <<http://medrxiv.org/lookup/doi/10.1101/2020.04.03.20052936>>.
- MISURACA, M.; FORCINITI, A.; SCEPI, G.; SPANO, M. Sentiment analysis for education with r: packages, methods and practical applications. **arXiv preprint arXiv:2005.12840**, 2020.
- MOHAMMAD, S.; TURNEY, P. Emotions evoked by common words and phrases: Using mechanical turk to create an emotion lexicon. In: **Proceedings of the NAACL HLT 2010 workshop on computational approaches to analysis and generation of emotion in text**. [S.l.: s.n.], 2010. p. 26–34.
- MOHAMMAD, S. M. Sentiment analysis: Automatically detecting valence, emotions, and other affectual states from text. In: MEISELMAN, H. (Ed.). **Emotion Measurement (Second Edition)**. [S.l.]: Elsevier, 2021.
- MONARI, A. C. P.; ARAÚJO, K. M. de; SOUZA, M. R. de; SACRAMENTO, I. Legitimando um populismo anti ciência: análise dos argumentos de bolsonaro sobre vacinação contra covid-19 no twitter. **Liinc em revista**, v. 17, n. 1, p. e5707, 2021.
- NASEEM, U.; RAZZAK, I.; KHUSHI, M.; EKLUND, P. W.; KIM, J. Covidsentiment: A large-scale benchmark twitter data set for covid-19 sentiment analysis. **IEEE Transactions on Computational Social Systems**, IEEE, v. 8, n. 4, p. 1003–1015, 2021.
- NEHA, K.; AGRAWAL, V.; KUMAR, V.; MOHAN, T.; CHOPRA, A.; BUDURU, A. B.; SHARMA, R.; KUMARAGURU, P. A tale of two sides: Study of protesters and counter-protesters on# citizenshipamendmentact campaign on twitter. In: **14th ACM Web Science Conference 2022**. [S.l.: s.n.], 2022. p. 279–289.
- NUTRICIONAL, R. B. D. P. E. S. E. S. A. E.; PENSSAN, R. **Insegurança alimentar e Covid-19 no Brasil**. 2021.
- PEREIRA, D. A. A survey of sentiment analysis in the portuguese language. **Artificial Intelligence Review**, Springer, v. 54, n. 2, p. 1087–1115, 2021.
- PLUTCHIK, R. A general psychoevolutionary theory of emotion. In: **Theories of emotion**. [S.l.]: Elsevier, 1980. p. 3–33.
- RECUERO, R.; SOARES, F. # vachina: How politicians help to spread disinformation about covid-19 vaccines. **Journal of Digital Social Research**, v. 4, n. 1, p. 73–97, 2022.
- RICARD, J.; MEDEIROS, J. Using misinformation as a political weapon: Covid-19 and bolsonaro in brazil. **Harvard Kennedy School Misinformation Review**, v. 1, n. 3, 2020.
- RIFF, D.; LACY, S.; FICO, F. **Analyzing media messages: Using quantitative content analysis in research**. [S.l.]: Routledge, 2014.

ROESSLEIN, J. Tweepy: Twitter for python! URL: <https://github.com/tweepy/tweepy>, 2020.

SHUGARS, S.; BEAUCHAMP, N. Why keep arguing? predicting engagement in political conversations online. **Sage Open**, SAGE Publications Sage CA: Los Angeles, CA, v. 9, n. 1, p. 2158244019828850, 2019.

SINGH, M.; JAKHAR, A. K.; PANDEY, S. Sentiment analysis on the impact of coronavirus in social life using the bert model. **Social Network Analysis and Mining**, Springer, v. 11, n. 1, p. 1–11, 2021.

STRACQUALURSI, L.; AGATI, P. Tweet topics and sentiments relating to distance learning among italian twitter users. **Scientific Reports**, Nature Publishing Group, v. 12, n. 1, p. 1–11, 2022.

TURBAN, C.; KRUSCHWITZ, U. Tackling irony detection using ensemble classifiers. In: **Proceedings of the Thirteenth Language Resources and Evaluation Conference**. [S.l.: s.n.], 2022. p. 6976–6984.

VOSOUGHI, S.; ROY, D.; ARAL, S. The spread of true and false news online. **science**, American Association for the Advancement of Science, v. 359, n. 6380, p. 1146–1151, 2018.

WANKHADE, M.; RAO, A. C. S.; KULKARNI, C. A survey on sentiment analysis methods, applications, and challenges. **Artificial Intelligence Review**, Springer, p. 1–50, 2022.

WEI, K.; LIN, Y.-R.; YAN, M. Examining protest as an intervention to reduce online prejudice: A case study of prejudice against immigrants. In: **Proceedings of The Web Conference 2020**. [S.l.: s.n.], 2020. p. 2443–2454.

XU, Q. A.; CHANG, V.; JAYNE, C. A systematic review of social media-based sentiment analysis: Emerging trends and challenges. **Decision Analytics Journal**, Elsevier, p. 100073, 2022.

XUE, J.; CHEN, J.; CHEN, C.; ZHENG, C.; LI, S.; ZHU, T. Public discourse and sentiment during the covid 19 pandemic: Using latent dirichlet allocation for topic modeling on twitter. **PloS one**, Public Library of Science San Francisco, CA USA, v. 15, n. 9, p. e0239441, 2020.

YAQUB, U. Tweeting during the covid-19 pandemic: Sentiment analysis of twitter messages by president trump. **Digital Government: Research and Practice**, ACM New York, NY, USA, v. 2, n. 1, p. 1–7, 2020.

YUAN, X.; SCHUCHARD, R. J.; CROOKS, A. T. Examining emergent communities and social bots within the polarized online vaccination debate in twitter. **Social media+ society**, SAGE Publications Sage UK: London, England, v. 5, n. 3, p. 2056305119865465, 2019.

ZHUNIS, A.; LIMA, G.; SONG, H.; HAN, J.; CHA, M. Emotion bubbles: Emotional composition of online discourse before and after the covid-19 outbreak. In: **Proceedings of the ACM Web Conference 2022**. [S.l.: s.n.], 2022. p. 2603–2613.

A. Apêndices

A.1 Experimento 1 - Número de tweets avaliados

Categoria		Antes		Depois	
Negativo	Forte	4.926 (40,9%)	1.672 (13,9%)	4.261(39,9%)	1.334 (12,5%)
	Médio		2.093 (17,4%)		1.855 (17,4%)
	Fraco		1.161 (9,6%)		1.072 (10%)
Neutro		3.885 (32,2%)		3.572(33,5%)	
Positivo	Forte	3.246(26,9%)	756 (6,3%)	2.837(26,6%)	639 (6%)
	Médio		1.594 (13,2%)		1.309 (12,3%)
	Fraco		896 (7,4%)		889 (8,3%)

Fonte: O autor (2022).

A.2 Experimento 1 - Resultados dos testes de Wilcoxon e Vargha & Delaney's realizado na análise de Intensidades dos Sentimentos

Tabela A.1: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.007	0.15	0.12	0.13	0.12	FALSE	0.556
A_NFR e D_NFR	0.935	0.11	0.1	0.11	0.11	TRUE	NA
A_NME e D_NME	0.477	0.17	0.11	0.18	0.13	TRUE	NA
A_NEU e D_NEU	0.779	0.3	0.16	0.3	0.17	TRUE	NA
A_PFO e D_PFO	0.168	0.07	0.08	0.06	0.08	TRUE	NA
A_PFR e D_PFR	0.010	0.07	0.08	0.09	0.09	FALSE	0.453
A_PME e D_PME	0.395	0.13	0.1	0.13	0.1	TRUE	NA

Fonte: O autor (2022).

A.3 Experimento 2 - Resultados dos testes de Wilcoxon e Vargha & Delaney's

Tabela A.2: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.514	0.16	0.12	0.16	0.12	TRUE	NA
A_NFR e D_NFR	0.504	0.08	0.08	0.08	0.08	TRUE	NA
A_NME e D_NME	0.884	0.16	0.11	0.16	0.11	TRUE	NA
A_NEU e D_NEU	0.252	0.22	0.13	0.23	0.14	TRUE	NA
A_PFO e D_PFO	0.949	0.14	0.12	0.14	0.12	TRUE	NA
A_PFR e D_PFR	0.407	0.08	0.08	0.08	0.08	TRUE	NA
A_PME e D_PME	0.141	0.16	0.1	0.16	0.11	TRUE	NA

Fonte: O autor (2022).

Tabela A.3: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (Textblob)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.584	0.03	0.05	0.03	0.05	TRUE	NA
A_NFR e D_NFR	0.138	0.16	0.11	0.16	0.11	TRUE	NA
A_NME e D_NME	0.360	0.07	0.08	0.07	0.08	TRUE	NA
A_NEU e D_NEU	0.676	0.41	0.16	0.41	0.16	TRUE	NA
A_PFO e D_PFO	0.824	0.04	0.06	0.04	0.06	TRUE	NA
A_PFR e D_PFR	0.244	0.21	0.13	0.21	0.12	TRUE	NA
A_PME e D_PME	0.857	0.08	0.08	0.08	0.08	TRUE	NA

Fonte: O autor (2022).

Tabela A.4: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (Polyglot - EN)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.039	0.31	0.15	0.31	0.15	FALSE	0.49
A_NFR e D_NFR	0.017	0.01	0.03	0.01	0.03	FALSE	0.50
A_NME e D_NME	0.194	0.08	0.08	0.08	0.08	TRUE	NA
A_NEU e D_NEU	0.180	0.37	0.15	0.38	0.15	TRUE	NA
A_PFO e D_PFO	0.062	0.17	0.12	0.17	0.12	TRUE	NA
A_PFR e D_PFR	0.323	0.01	0.02	0.01	0.02	TRUE	NA
A_PME e D_PME	0.278	0.04	0.06	0.04	0.06	TRUE	NA

Fonte: O autor (2022).

Tabela A.5: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (Polyglot - PT)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.393	0.27	0.14	0.26	0.14	TRUE	NA
A_NFR e D_NFR	0.506	0.02	0.04	0.02	0.04	TRUE	NA
A_NME e D_NME	0.733	0.1	0.09	0.1	0.09	TRUE	NA
A_NEU e D_NEU	0.319	0.35	0.15	0.35	0.15	TRUE	NA
A_PFO e D_PFO	0.417	0.18	0.12	0.18	0.12	TRUE	NA
A_PFR e D_PFR	0.901	0.02	0.03	0.02	0.04	TRUE	NA
A_PME e D_PME	0.973	0.06	0.07	0.06	0.07	TRUE	NA

Fonte: O autor (2022).

A.4 Experimento 2 - Resultados dos testes de Wilcoxon e Vargha & Delaney's realizado na análise de intensidade dos sentimentos entre os diferentes graus de gravidade relatados

Tabela A.6: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Grau de gravidade: baixo)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.514	0.16	0.12	0.16	0.12	TRUE	NA
A_NFR e D_NFR	0.504	0.08	0.08	0.08	0.08	TRUE	NA
A_NME e D_NME	0.884	0.16	0.11	0.16	0.11	TRUE	NA
A_NEU e D_NEU	0.252	0.22	0.13	0.23	0.14	TRUE	NA
A_PFO e D_PFO	0.949	0.14	0.12	0.14	0.12	TRUE	NA
A_PFR e D_PFR	0.407	0.08	0.08	0.08	0.08	TRUE	NA
A_PME e D_PME	0.141	0.16	0.1	0.16	0.11	TRUE	NA

Fonte: O autor (2022).

Tabela A.7: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Grau de gravidade: Médio)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.065	0.18	0.13	0.16	0.12	TRUE	NA
A_NFR e D_NFR	0.343	0.08	0.09	0.08	0.08	TRUE	NA
A_NME e D_NME	0.162	0.16	0.11	0.17	0.11	TRUE	NA
A_NEU e D_NEU	0.456	0.22	0.14	0.23	0.14	TRUE	NA
A_PFO e D_PFO	0.268	0.12	0.11	0.12	0.1	TRUE	NA
A_PFR e D_PFR	0.032	0.09	0.08	0.07	0.07	FALSE	0.536
A_PME e D_PME	0.312	0.16	0.11	0.16	0.11	TRUE	NA

Fonte: O autor (2022).

Tabela A.8: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Grau de gravidade: Alto)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.988	0.16	0.12	0.16	0.12	TRUE	NA
A_NFR e D_NFR	0.271	0.08	0.08	0.08	0.08	TRUE	NA
A_NME e D_NME	0.504	0.17	0.11	0.17	0.11	TRUE	NA
A_NEU e D_NEU	0.399	0.22	0.14	0.23	0.14	TRUE	NA
A_PFO e D_PFO	0.363	0.13	0.11	0.13	0.11	TRUE	NA
A_PFR e D_PFR	0.159	0.09	0.08	0.08	0.08	TRUE	NA
A_PME e D_PME	0.989	0.15	0.1	0.15	0.1	TRUE	NA

Fonte: O autor (2022).

A.5 Experimento 2 - Resultados dos testes de Wilcoxon e Vargha & Delaney's realizado na análise de intensidade dos sentimentos entre os diferentes graus de parentesco

Tabela A.9: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Parentesco: Avô / Avó)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.960	0.16	0.11	0.16	0.13	TRUE	NA
A_NFR e D_NFR	0.949	0.09	0.09	0.09	0.09	TRUE	NA
A_NME e D_NME	0.785	0.17	0.12	0.17	0.12	TRUE	NA
A_NEU e D_NEU	0.645	0.22	0.14	0.23	0.14	TRUE	NA
A_PFO e D_PFO	0.206	0.12	0.1	0.11	0.1	TRUE	NA
A_PFR e D_PFR	0.236	0.08	0.07	0.09	0.09	TRUE	NA
A_PME e D_PME	0.361	0.15	0.11	0.15	0.11	TRUE	NA

Fonte: O autor (2022).

Tabela A.10: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Parentesco: Pai / Mãe)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.829	0.16	0.12	0.16	0.12	TRUE	NA
A_NFR e D_NFR	0.987	0.09	0.09	0.08	0.08	TRUE	NA
A_NME e D_NME	0.921	0.17	0.11	0.17	0.11	TRUE	NA
A_NEU e D_NEU	0.587	0.22	0.14	0.22	0.14	TRUE	NA
A_PFO e D_PFO	0.282	0.12	0.11	0.13	0.11	TRUE	NA
A_PFR e D_PFR	0.129	0.09	0.08	0.08	0.08	TRUE	NA
A_PME e D_PME	0.723	0.15	0.11	0.15	0.11	TRUE	NA

Fonte: O autor (2022).

Tabela A.11: Resultado dos testes de Mann-Whitney e Vargha & Delaney's entre os pares de amostras de tweets (VADER - Parentesco: Filho / Filha)

grupos	pvalue	mediaA	desvA	mediaD	desvD	wilcox_H0	tam_efeito
A_NFO e D_NFO	0.818	0.15	0.11	0.15	0.1	TRUE	NA
A_NFR e D_NFR	0.686	0.07	0.07	0.07	0.06	TRUE	NA
A_NME e D_NME	0.225	0.14	0.09	0.15	0.09	TRUE	NA
A_NEU e D_NEU	0.109	0.22	0.13	0.23	0.14	TRUE	NA
A_PFO e D_PFO	0.267	0.17	0.13	0.16	0.12	TRUE	NA
A_PFR e D_PFR	0.011	0.09	0.08	0.08	0.08	FALSE	0.538
A_PME e D_PME	0.630	0.16	0.09	0.16	0.1	TRUE	NA

Fonte: O autor (2022).

A.6 Experimento 2 - E-mail convite enviado aos participantes da pesquisa para classificação manual dos tweets

Figura A.1: E-mail convite enviado aos participantes



A.7 Experimento 2 - TCLE disponibilizado aos participantes da pesquisa para classificação manual dos tweets

Figura A.2: TCLE disponibilizado aos participantes da pesquisa para classificação manual dos tweets

TERMO DE CONSENTIMENTO LIVRE E ESCLARECIDO (TCLE)

A presente pesquisa está sendo proposta com o intuito de desenvolver um processo capaz de identificar a percepção das pessoas em relação ao governo Jair Bolsonaro durante a pandemia de Covid-19, antes e depois de essas pessoas terem relatado, por meio da rede social Twitter, um ente familiar acometido pela Covid-19.

Nesta pesquisa, você será solicitado(a) a interagir com uma aplicação web, em que serão exibidos tweets publicados ao longo do ano de 2021, durante a pandemia da Covid-19, previamente selecionados pelos pesquisadores. Para cada tweet exibido, você deverá ler o conteúdo e avaliar qual sentimento aquele tweet expressa em relação ao governo Jair Bolsonaro. Em seguida, deverá selecionar uma das opções de sentimento disponíveis na tela. Não serão coletados dados pessoais ou demográficos do participante. A coleta de dados de avaliação de sentimento dos tweets ocorrerá por meio do armazenamento das respostas indicadas pelos participantes em um banco de dados, de maneira anônima.

É possível que aconteçam os seguintes desconfortos ou riscos em sua participação, tais como tweets contendo palavras de baixo calão ou conteúdo impróprio para menores de 18 anos. Para minimizar tais riscos, o participante precisará confirmar que possui idade igual ou superior a 18 anos.

Em caso de dúvidas, você pode entrar em contato por e-mail.

Celso de Oliveira Pacheco Junior – celsojunior@edu.unirio.br
Lattes: <http://lattes.cnpq.br/3626407260102186>

Sean Wolfgang Matsui Siqueira – sean@uniriotec.br
Lattes: <http://lattes.cnpq.br/2562652838103607>

Você terá a opção de parar a qualquer momento.

A.8 Experimento 2 - Número de tweets avaliados

Tabela A.12: Experimento 2 - Número de tweets avaliados categorizados de acordo com o sentimento calculado.

Tweets Avaliados									
Categoria		VADER		TextBlob		Polyglot EN		Polyglot PT	
		Antes	Depois	Antes	Depois	Antes	Depois	Antes	Depois
Negativo	Forte	21.057	21.496	3.392	3.357	40.499	41.551	35.374	35.642
	Médio	20.969	21.371	9.083	8.957	10.952	10.840	13.992	14.169
	Fraco	10.650	10.752	21.065	21.760	1.489	1.416	2.907	2.833
Neutro		29.175	30.030	54.787	55.447	49.967	51.135	46.056	46.812
Positivo	Forte	19.441	19.307	5.710	5.786	24.332	23.763	24.599	24.683
	Médio	21.401	21.460	10.911	11.063	5.862	5.787	8.951	9.075
	Fraco	11.467	11.064	29.212	29.110	1.059	988	2.281	2.266

Fonte: O autor (2022).

A.9 Experimento 2 - Cálculo para extrair a quantidade de subjetividade presente nas mensagens

Figura A.3: Exemplo do cálculo de subjetividade presente no texto

```
▶ from textblob import TextBlob

testimonial = TextBlob("What do you think about Textblob?")
print(testimonial.sentiment)

testimonial = TextBlob("I think Textblob is the best")
print(testimonial.sentiment)

Sentiment(polarity=0.0, subjectivity=0.0)
Sentiment(polarity=1.0, subjectivity=0.3)
```

Adaptado do site <https://textblob.readthedocs.io/>.

A.10 Experimento 2 - Cálculo para extrair as emoções presentes nas mensagens

Figura A.4: Exemplo do processamento do cálculo da emoção presente em uma sentença na língua inglesa

```
1 library(syuzhet)
2 library(RColorBrewer)
3 library(wordcloud)
4 library(tm)
5 library(readr)
6
7 sentence = "People of God help our president build a better Brazil"
8 df_en = get_nrc_sentiment(sentence, language = "english")
9 print(df_en)
10
11      anger anticipation disgust fear joy sadness surprise trust negative positive
12 1         0           1         0   1   1         0         0         2         0         3
13
14 df <- data.frame(texto = c(sentence))
15
16 for(i in strsplit(sentence, " ")){
17   df <- data.frame(texto = c(i))
18
19   emotions = get_nrc_sentiment(df$texto, language = "portuguese")
20
21   n = names(emotions)
22
23   for (nn in n) df[, nn] = emotions[nn]
24
25   print(df)
26
27 }
28
29
30      texto anger anticipation disgust fear joy sadness surprise trust negative positive
31 1  People      0           0         0   0   0         0         0         0         0         0
32 2    of        0           0         0   0   0         0         0         0         0         0
33 3   God        0           1         0   1   1         0         0         1         0         1
34 4  help        0           0         0   0   0         0         0         0         0         0
35 5   our        0           0         0   0   0         0         0         0         0         0
36 6 president    0           0         0   0   0         0         0         1         0         1
37 7   build      0           0         0   0   0         0         0         0         0         1
38 8    a         0           0         0   0   0         0         0         0         0         0
39 9  better      0           0         0   0   0         0         0         0         0         0
40 10 Brazil     0           0         0   0   0         0         0         0         0         0
41
```

Fonte: O autor (2022).

