



**UFOP**

Universidade Federal  
de Ouro Preto

**Universidade Federal de Ouro Preto  
Instituto de Ciências Exatas e Aplicadas  
Departamento de Computação e Sistemas**

**Análise de sentimentos das postagens  
e comentários dos principais  
candidatos à presidência durante a  
corrida eleitoral de 2018**

**Rafael Francisco de Oliveira**

**TRABALHO DE  
CONCLUSÃO DE CURSO**

**ORIENTAÇÃO:  
Prof. Dr. Filipe Nunes Ribeiro**

**Abril, 2021  
João Monlevade–MG**

**Rafael Francisco de Oliveira**

**Análise de sentimentos das postagens e  
comentários dos principais candidatos à  
presidência durante a corrida eleitoral de 2018**

Orientador: Prof. Dr. Filipe Nunes Ribeiro

Monografia apresentada ao curso de Engenharia de Computação do Instituto de Ciências Exatas e Aplicadas, da Universidade Federal de Ouro Preto, como requisito parcial para aprovação na Disciplina “Trabalho de Conclusão de Curso II”.

**Universidade Federal de Ouro Preto**

**João Monlevade**

**Abril de 2021**

## SISBIN - SISTEMA DE BIBLIOTECAS E INFORMAÇÃO

O482a Oliveira, Rafael Francisco de .  
Análise de sentimentos das postagens e comentários dos principais  
candidatos à presidência durante a corrida eleitoral de 2018.  
[manuscrito] / Rafael Francisco de Oliveira. - 2021.  
88 f.: il.: color., gráf., tab..

Orientador: Prof. Dr. Filipe Nunes Ribeiro.  
Monografia (Bacharelado). Universidade Federal de Ouro Preto.  
Instituto de Ciências Exatas e Aplicadas. Graduação em Engenharia de  
Computação .

1. Classificação. 2. Percepção social - Análise . 3. Facebook (Rede  
social on-line) . 4. Mineração de dados (Computação). 5. Polaridade. 6.  
Presidentes - Brasil - Eleições, 2018. I. Ribeiro, Filipe Nunes. II.  
Universidade Federal de Ouro Preto. III. Título.

CDU 316.473:025.4.036

Bibliotecário(a) Responsável: Flavia Reis - CRB6-2431



## FOLHA DE APROVAÇÃO

**Rafael Francisco de Oliveira**

**Análise de sentimentos das postagens e comentários dos principais candidatos à presidência durante a corrida eleitoral de 2018**

Monografia apresentada ao Curso de Engenharia de Computação da Universidade Federal de Ouro Preto como requisito parcial para obtenção do título de Bacharel em Engenharia de Computação

Aprovada em 29 de abril de 2021

### Membros da banca

Doutor - Filipe Nunes Ribeiro - Orientador (Universidade Federal de Ouro Preto)  
Mestre - Helen de Cássia Sousa da Costa Lima - (Universidade Federal de Ouro Preto)  
Doutor - Vicente José Peixoto de Amorim - (Universidade Federal de Ouro Preto)

Filipe Nunes Ribeiro, orientador do trabalho, aprovou a versão final e autorizou seu depósito na Biblioteca Digital de Trabalhos de Conclusão de Curso da UFOP em 02/06/2021



Documento assinado eletronicamente por **Filipe Nunes Ribeiro, PROFESSOR DE MAGISTERIO SUPERIOR**, em 02/06/2021, às 15:56, conforme horário oficial de Brasília, com fundamento no art. 6º, § 1º, do [Decreto nº 8.539, de 8 de outubro de 2015](#).



A autenticidade deste documento pode ser conferida no site [http://sei.ufop.br/sei/controlador\\_externo.php?acao=documento\\_conferir&id\\_orgao\\_acesso\\_externo=0](http://sei.ufop.br/sei/controlador_externo.php?acao=documento_conferir&id_orgao_acesso_externo=0), informando o código verificador **0178440** e o código CRC **A0858EBC**.

*Este trabalho é dedicado primeiramente a Deus. O maior orientador da minha vida. Ele nunca me abandonou nos momentos de necessidade.*

*Aos meus pais, irmãos e a toda minha família que, com muito carinho e apoio, não mediram esforços para que eu chegasse até esta etapa de minha vida. Eles são os pilares da minha formação como ser humano.*

*A todos os professores que de alguma maneira me influenciaram na minha trajetória transmitindo seus conhecimentos.*

*Ao espírito de colaboração demonstrado por todos meus colegas de turma e amigos de república por todo apoio, risadas, dicas de estudos e conselhos.*

*Dedico a todos aqueles que de alguma forma contribuíram com meu desenvolvimento tanto direta e indiretamente em todos os momentos de minha formação.*

# Agradecimentos

Agradeço a Deus, por ter permitido que eu tivesse saúde e determinação para não desanimar durante a realização deste trabalho.

Aos meus pais Márcia e José, meus irmãos Jaqueline, Marcelo, Andréia e Flávia (*in memoriam*) e todos os familiares que me incentivaram nos momentos difíceis e compreenderam a minha ausência enquanto eu me dedicava à realização deste trabalho e deste curso.

Aos professores, em especial Filipe Ribeiro, pelas correções e ensinamentos que me permitiram apresentar um melhor desempenho durante a realização deste trabalho e os que de alguma forma ajudaram no meu processo de formação profissional ao longo do curso.

Aos meus colegas de turma, especialmente Arthur Felipe, Arthur Bernardo, e Edgar Alves, membros do Triviais Works que me acompanharam durante essa jornada nos incontáveis trabalhos e provas realizados juntos.

Aos colegas e irmãos da República Bino, Edgar, Rhivison, Guilherme, Douglas e Mateus pelas incontáveis risadas, discussões, apoios, conselhos de vida (estampados na cozinha, claro) e muitas diversões nas sextas-feiras (sempre calorosas).

Ao amigo Renan, por toda perturbação causada rrsrrs, que parcialmente fez parte desta caminhada mas que infelizmente desistiu desta guerra e foi travar batalhas em outros caminhos!!!).

A toda comunidade *stackoverflow*, que sem vocês, este curso seria bem mais difícil.

E ao meu companheiro e melhor amigo Frances, que sempre acreditou em mim e me apoiou em todos os momentos. Obrigado por estar junto, me apoiar, dar conselhos e me ajudar nos momentos de estresse durante o curso. O modo difuso fez milagres!!!

*“It’s not that I’m so smart, it’s just that I stay with problems longer.”*

— Albert Einstein (1879 – 1955)

# Resumo

O número de usuários conectados em redes sociais online cresceu de forma significativa. *Facebook*, *LinkedIn*, *YouTube*, *TikTok*, *Instagram* e *Twitter* são exemplos claros dessa evolução na comunicação social contemporânea. A interação das pessoas nas redes sociais gera dezenas de milhares de informações (dados) possibilitando sua análise em estudos diversificados. Uma das características das redes sociais é a possibilidade de expressar opiniões e posicionamentos a determinados assuntos e notícias a qualquer momento e em qualquer lugar. A detecção e análise dos dados permitem inferir e mensurar a polaridade de ideias a determinado assunto. O objetivo deste trabalho visa analisar os sentimentos das postagens e comentários antes, durante e após a eleição presidencial brasileira de 2018 na rede social *Facebook* dos candidatos Jair Bolsonaro e Fernando Haddad. A análise compreende os dados coletados durante os anos de 2018 e 2019. A detecção de sentimentos dos dados coletados foram realizados através do classificador *Sentistrength*. Após a obtenção da avaliação do programa, os resultados mostraram que apesar da dificuldade apresentada pela complexidade semântica do idioma português, foi possível perceber uma mudança na polaridade dos sentimentos após a eleição presidencial brasileira de 2018, caracterizada por uma negatividade nos comentários referentes a Fernando Haddad e por uma positividade nos comentários relacionados a Jair Bolsonaro.

**Palavras-chaves:** Análise de sentimentos. *Sentistrength*. Polaridade. Classificação. Rede Social.

# Abstract

The number of connected users in online social media has been grown significantly. Facebook, LinkedIn, Youtube, Instagram, and Twitter are examples of this evolution in contemporary social communication. The interaction of people on social media creates hundreds of thousands of information (data) that enable its analysis in various studies. One of the facets of social media is the possibility to give your own opinions, and positions on specific subjects and news anytime, and anywhere. The detection and data analysis allows to infer and measure the polarity of ideas of some subject. The main goal of this work is to analyze the sentiments of the posts and comments before, during, and after 2018 Brazilian presidential election on social media Facebook about candidates Jair Bolsonaro and Fernando Haddad. The analysis comprises the data collected during the years 2018 and 2019. The detection of sentiments was conducted with SentiStrength. After obtaining the evaluation of the algorithm, the results showed that despite challenges imposed by the semantic complexity of the Portuguese language, it was possible to perceive a change in the polarity of sentiments after the 2018 Brazilian presidential election, characterized by negativity in Fernando Haddad's posts' comments and by a positivity increase in the Jair Bolsonaro's posts' comments.

**Key-words:** Sentiment Analysis. *SentiStrength*. Polarity. Classification. Social Media.

# Lista de ilustrações

Figura 1 – Análise Léxica de Classificação de Sentimentos . . . . .	21
Figura 2 – Classificações da Abordagem Baseada em Análise Léxica . . . . .	22
Figura 3 – Grafo representativo da plataforma <i>Facebook</i> . . . . .	29
Figura 4 – Informações ( <i>fields</i> ) de um objeto representativo da plataforma <i>Facebook</i>	30
Figura 5 – Fluxo da coleta de dados . . . . .	31
Figura 6 – <i>Fields</i> coletados referentes à postagem . . . . .	31
Figura 7 – <i>Fields</i> coletados referentes ao comentário . . . . .	32
Figura 8 – Diagrama do fluxo do processamento de dados . . . . .	33
Figura 9 – Diagrama do fluxo da análise de sentimentos . . . . .	34
Figura 10 – Diagrama do fluxo de ampliação dos termos relacionados aos candidatos	37
Figura 11 – Número de postagens mensais . . . . .	40
Figura 12 – Gráfico do somatório de engajamentos por mês . . . . .	45
Figura 13 – Gráfico do somatório de engajamentos por dia . . . . .	46
Figura 14 – Gráfico da distribuição do engajamento LIKE . . . . .	47
Figura 15 – Gráfico da distribuição do engajamento ANGRY . . . . .	48
Figura 16 – Gráfico da distribuição da <i>tag status_type</i> . . . . .	50
Figura 17 – Nuvens de palavras das postagens do período P1 referente a Bolsonaro	51
Figura 18 – Nuvens de palavras das postagens do período P2 referente a Bolsonaro	52
Figura 19 – Nuvens de palavras das postagens do período P3 referente a Bolsonaro	52
Figura 20 – Nuvens de palavras das postagens do período P1 referente a Haddad .	53
Figura 21 – Nuvens de palavras das postagens do período P2 referente a Haddad .	54
Figura 22 – Nuvens de palavras das postagens do período P3 referente a Haddad .	54
Figura 23 – Gráfico da distribuição dos <i>scores</i> das postagens . . . . .	56
Figura 24 – Distribuição dos <i>scores</i> das postagens de Bolsonaro por polaridade . . .	57
Figura 25 – Distribuição dos <i>scores</i> das postagens de Haddad por polaridade . . . .	57
Figura 26 – Gráfico do percentual dos <i>scores</i> das mensagens por período eleitoral .	58
Figura 27 – Nuvens de palavras dos comentários do período P1 referente a Bolsonaro	61
Figura 28 – Nuvens de palavras dos comentários do período P2 referente a Bolsonaro	61
Figura 29 – Nuvens de palavras dos comentários do período P3 referente a Bolsonaro	62
Figura 30 – Nuvens de palavras dos comentários do período P1 referente a Haddad	63
Figura 31 – Nuvens de palavras dos comentários do período P2 referente a Haddad	63
Figura 32 – Nuvens de palavras dos comentários do período P3 referente a Haddad	64
Figura 33 – Média dos <i>scores</i> dos comentários de cada postagem . . . . .	66
Figura 34 – Recorte no intervalo de tempo das médias dos <i>scores</i> dos comentários de cada postagem . . . . .	67

Figura 35 – Média diária a partir da média dos <i>scores</i> dos comentários de cada postagem . . . . .	67
Figura 36 – Mapa de calor ( <i>heatmap</i> ) dos comentários relacionados a Haddad . . . . .	69
Figura 37 – Mapa de calor ( <i>heatmap</i> ) dos comentários relacionados a Bolsonaro . . . . .	69
Figura 38 – Percentual da média dos <i>scores</i> dos comentários por período eleitoral . . . . .	71
Figura 39 – Moda dos <i>scores</i> dos comentários de cada postagem . . . . .	72
Figura 40 – Moda dos <i>scores</i> dos comentários de cada postagem desconsiderando os sentimentos neutros . . . . .	73
Figura 41 – Moda diária dos <i>scores</i> dos comentários de cada postagem desconsiderando os sentimentos neutros . . . . .	73
Figura 42 – Percentual da moda dos <i>scores</i> dos comentários por período eleitoral desconsiderando os sentimentos neutros . . . . .	74
Figura 43 – Nuvens de palavras dos comentários negativos relacionados às postagens negativas . . . . .	80
Figura 44 – Nuvens de palavras dos comentários negativos relacionados às postagens positivas . . . . .	80
Figura 45 – Média dos <i>scores</i> dos comentários de cada postagem . . . . .	81

# Lista de tabelas

Tabela 1 – Exemplos de Análise e Classificação do método <i>SentiStrength</i> . . . . .	24
Tabela 2 – Matriz de confusão . . . . .	35
Tabela 3 – Configuração da saída da análise de sentimentos do <i>SentiStrength</i> . . . . .	36
Tabela 4 – Exemplos de termos adicionados ao <i>SentiStrength</i> . . . . .	37
Tabela 5 – Conjunto dos dados coletados . . . . .	38
Tabela 6 – Conjunto dos dados processados . . . . .	39
Tabela 7 – Detalhamento do <i>dataframe</i> <code>df_posts</code> . . . . .	41
Tabela 8 – Detalhamento do <i>dataframe</i> <code>df_comments</code> . . . . .	42
Tabela 9 – Descrição do tamanho de caracteres das postagens e comentários . . . . .	43
Tabela 10 – <i>Fields</i> representativos de engajamento no <i>Facebook</i> . . . . .	44
Tabela 11 – Valores da <i>tag</i> <code>status-type</code> . . . . .	49
Tabela 12 – Divisão do conjunto de dados em períodos . . . . .	51
Tabela 13 – Desvio padrão e erro padrão em relação à média dos comentários . . . . .	65
Tabela 14 – Performance da análise de sentimentos . . . . .	76
Tabela 15 – Percentual dos <i>scores</i> das mensagens por período eleitoral . . . . .	78
Tabela 16 – Percentual da média dos <i>scores</i> dos comentários por período eleitoral . . . . .	81
Tabela 17 – Percentual da moda dos <i>scores</i> dos comentários por período desconsiderando sentimentos neutros . . . . .	82

# Lista de abreviaturas e siglas

**API** Application Programming Interface

**HTTP** Hypertext Transfer Protocol

**JSON** JavaScript Object Notation

**URL** Uniform Resource Locator

**NLTK** Natural Language ToolKit

# Sumário

<b>1</b>	<b>INTRODUÇÃO</b>	<b>15</b>
1.1	O Problema de Pesquisa	16
1.2	Objetivos	16
1.3	Organização do Trabalho	17
<b>2</b>	<b>REVISÃO BIBLIOGRÁFICA</b>	<b>18</b>
2.1	Discurso de Ódio	18
2.2	Análise de Sentimentos	19
2.2.1	Estratégias de Análise	20
2.2.2	Métodos de Análise de Sentimentos	23
2.2.3	<i>SentiStrength</i>	23
2.3	Trabalhos Relacionados	25
<b>3</b>	<b>METODOLOGIA</b>	<b>28</b>
3.1	Coleta dos Dados	28
3.2	Processamento do Texto	32
3.3	Análise de Sentimentos	34
3.3.1	Escolha do Método	34
3.3.2	Validação do Método	35
3.3.3	Classificação de Sentimentos	36
<b>4</b>	<b>CARACTERIZAÇÃO DOS DATASETS</b>	<b>38</b>
4.1	Caracterização dos Dados	38
4.2	Entendendo as Reações (Engajamentos)	43
4.2.1	Caracterização dos Conteúdos com Maiores Engajamentos no <i>Field LIKE</i>	46
4.2.2	Caracterização dos Conteúdos com Maiores Engajamentos no <i>Field ANGRY</i>	47
4.3	Avaliando as Mensagens das Postagens	49
4.3.1	Caracterização do <i>Field STATUS_TYPE</i>	49
4.3.2	Conteúdo das Postagens	50
4.3.3	Analisando os Sentimentos das Postagens	55
4.3.3.1	<i>Overview</i> da Classificação de Sentimentos	55
4.3.3.2	Analisando os Sentimentos por Período	57
4.3.3.3	Analisando os Conteúdos das Postagens mais Negativas	58
4.3.3.4	Analisando os Conteúdos das Postagens mais Positivas	59
4.4	Avaliando os Comentários das Postagens	60
4.4.1	Conteúdo dos Comentários das Postagens	60

4.4.2	Analisando os Sentimentos dos Comentários . . . . .	64
4.4.2.1	Utilizando a Média dos <i>Scores</i> . . . . .	64
4.4.2.2	Utilizando a moda dos <i>scores</i> . . . . .	71
<b>5</b>	<b>RESULTADOS . . . . .</b>	<b>76</b>
<b>5.1</b>	<b>Validação do <i>SentiStrength</i> . . . . .</b>	<b>76</b>
<b>5.2</b>	<b>Análise de Sentimentos . . . . .</b>	<b>77</b>
5.2.1	Classificação das Postagens . . . . .	77
5.2.2	Classificação dos Comentários . . . . .	78
<b>6</b>	<b>CONSIDERAÇÕES FINAIS . . . . .</b>	<b>83</b>
	<b>REFERÊNCIAS . . . . .</b>	<b>85</b>

# 1 Introdução

O número de usuários conectados em redes sociais online, tema principal deste trabalho, cresceu de forma significativa nos últimos anos. *Facebook, LinkedIn, Reddit, YouTube, Instagram, Whatsapp, Snapchat, TikTok* e *Twitter* são alguns dos exemplos claros dessa evolução na comunicação social contemporânea. A interação das pessoas nas redes sociais gera dezenas de milhares de informações (dados) de seus usuários todos os dias.

Uma das características das redes sociais é a possibilidade de expressar opiniões e posicionamentos a determinados assuntos e notícias a qualquer momento e em qualquer lugar. A funcionalidade de permitir os seus usuários de criar e compartilhar conteúdos envolvendo assuntos pessoais, tais como fotos, mensagens de texto e vídeo é outra atratividade que permitiu a popularidade das redes sociais. As estatísticas mostram essa popularidade.

Segundo [Tankovska \(2021b\)](#), o *Facebook*<sup>1</sup> tinha mais de 2.7 bilhões de usuários ativos mensalmente a partir do segundo trimestre de 2020. No último trimestre de 2020, o *Facebook* relatou que 3.3 bilhões de usuários estavam utilizando pelo menos um de seus produtos (*Facebook, WhatsApp, Instagram, ou Messenger*) ([TANKOVSKA, 2021](#)). No quesito audiência, a Índia lidera os países com maiores números de usuários ativos no *Facebook* em 2021 com 320 milhões de usuários ativos, seguida pelos Estados Unidos e Indonésia com 190 milhões e 140 milhões de usuários ativos, respectivamente. O Brasil aparece na quarta posição com 130 milhões de usuários ativos ([TANKOVSKA, 2021a](#)).

Com esta popularidade, a detecção e análise de dados permite inferir e mensurar a polaridade de ideias a determinado assunto. As redes sociais tornaram-se um meio para que as pessoas sintam-se livres para expressar suas opiniões e ideias, o que acarreta o surgimento de discussões inflamadas polarizando o “nós” contra “eles”. [Mondal, Silva e Benevenuto \(2017\)](#) destacam que em muitos casos, essas discussões tornam-se em discursos de ódio, insultos e uso de linguagem ofensiva.

A partir desse contexto, é notável que esforços estão sendo implementado para a identificação de tais discursos, utilizando-se de diferentes técnicas de análise, como análise de sentimentos e aprendizado de máquina. Algumas empresas, o *Facebook* por exemplo, tem implementados ações, como detecção de *fake news* e manifestação de ódio e racismo ([FACEBOOK, 2020](#)).

---

<sup>1</sup> <https://www.facebook.com/>

## 1.1 O Problema de Pesquisa

A possibilidade de interação nas redes sociais torna-se perceptível como assuntos polêmicos tais como política, religião, futebol e sexualidade geram discussões inflamadas que conseqüentemente levam a discursos de ódio, racismo, violência verbal, xingamentos e humilhações geralmente direcionados a uma minoria. Tais comportamentos descrevem a influência das redes sociais na vida das pessoas e em seus relacionamentos fora dela.

Diante dos cenários abordados anteriormente, surgiu a proposta de utilizar técnicas de análise de sentimentos presentes na literatura para identificar as polaridades dos sentimentos dos comentários. Essa técnica de detecção de sentimentos torna-se mais necessária no idioma português, uma vez a maioria das ferramentas foram desenvolvidas e baseadas no idioma inglês. Isto pode ser justificado pela complexidade sintática e semântica do idioma português e de sua respectiva utilização informal e sem padrão em mídias sociais, como destacado por [Silva e Barbosa \(2019\)](#).

Com uso das redes sociais como meio de compartilhamento de assuntos diversos, este trabalho visa a análise de sentimentos no cenário político brasileiro durante a eleição presidencial de 2018 na plataforma *Facebook*. A escolha pela plataforma do *Facebook* deu-se pela popularidade da mesma e pela existência de uma API que permite coletar dados da plataforma por um período mais longo.

Uma das motivações do trabalho deu-se pela grande polarização política marcante deste período no cenário político brasileiro. Por isso, a análise será baseada nas páginas do *Facebook* dos dois candidatos que disputaram a eleição presidencial no segundo turno, Jair Bolsonaro e Fernando Haddad, por meio da coleta e análise dos comentários realizados pelos usuários.

## 1.2 Objetivos

O objetivo principal do trabalho é comparar as polaridades de sentimentos nos comentários das postagens realizadas antes, durante e após a eleição presidencial de 2018, referentes aos dois candidatos, Jair Bolsonaro e Fernando Haddad, através da técnica de análise de sentimentos. A partir disso, pretende-se analisar como essa técnica de análise se comporta no idioma português. A técnica a ser utilizada será a análise léxica através de uma ferramenta de classificação de sentimentos denominada *SentiStrength*.

Espera-se que com essa ferramenta seja possível realizar um estudo abrangente através da análise de sentimentos, pois há o desafio de adaptação da ferramenta ao idioma português. A contribuição será de grande utilidade para o contexto brasileiro, inclusive no cenário político. Esse tipo de análise pode ser adaptada em aplicações reais na rede social, como por exemplo, monitoramento do comportamento de um determinado público diante

a um determinado assunto ou notícia em diversos contextos.

Este trabalho possui aos seguintes objetivos específicos:

- Definir um conjunto de dados relevante que será utilizado na análise de sentimentos.
- Selecionar a técnica de análise de sentimentos mais adequada ao contexto.
- Comparar os resultados nos períodos antes, depois e após a eleição presidencial de 2018.
- Avaliar o desempenho da técnica utilizada no idioma português.

### 1.3 Organização do Trabalho

O restante deste trabalho é organizado como se segue:

- O [Capítulo 2](#) apresenta a revisão dos trabalhos correlatos à técnica utilizada.
- O [Capítulo 3](#) apresenta a metodologia utilizada no trabalho, bem como o conjunto de dados e a descrição da técnica escolhida.
- O [Capítulo 4](#) apresenta a caracterização dos dados e as análises de sentimentos.
- O [Capítulo 5](#) mostra os resultados obtidos no trabalho.
- O [Capítulo 6](#) são apresentadas as considerações finais.

## 2 Revisão Bibliográfica

A fim de embasar o contexto deste trabalho, esta seção busca abordar trabalhos relacionados à análise de sentimentos, bem como as principais técnicas e ferramentas disponíveis na literatura.

### 2.1 Discurso de Ódio

Silva et al. (2016) definem discurso de ódio ou *hate speech* como qualquer comunicação ofensiva que tem como alvo uma pessoa ou um determinado grupo. Segundo Brown (2017), as causas dessa comunicação ofensiva baseia-se de acordo com determinadas características, como raça, cor, etnia, gênero, religião, deficiência, ou orientação sexual. No meio digital, Blaya (2019) refere este meio de comunicação como ódio cibernético, do inglês *cyber-hate* e Salawu, He e Lumsden (2017) como *cyber-bullying*.

O discurso de ódio é difícil de ser identificado. Segundo Al-Hassan e Al-Dossari (2019), um dos obstáculos enfrentados pelas plataformas de rede sociais é responder perguntas como: “O que constitui um discurso de ódio?”, “Que tipo de discurso de ódio precisa ser identificado?”. Trabalhos procuram desenvolver técnicas de detecção de discurso de ódio nas redes sociais utilizando as mais variadas características e métodos.

Segundo Schmidt e Wiegand (2017) há oito grupos de métodos de detecção de ódio disponíveis na literatura:

1. *Simple Surface Features*: técnica de detecção que utiliza características de nível de superfícies (*surface-level features*) como unigramas, n-gramas, tokenização, *Bag Of Words*, frequência de menções e pontuação, tamanho de comentário e *tokens*. Burnap e Williams (2016) utilizam *Bag Of Words* para extrair dependências sintáticas e gramaticais entre palavras com o objetivo de identificar discurso de ódio com o auxílio de modelos classificatórios de aprendizado de máquina.
2. *Word Generalization*: técnica que utiliza agrupamento de palavras através de clusterização. Recentemente alguns trabalhos utilizam um modelo baseado em redes neurais chamado de *word embeddings*, que são representações de similaridades entre palavras através de vetores. Djuric et al. (2015) utilizam *word embeddings* para treinar um classificador binário para distinguir entre comentários ofensivos e limpos.
3. *Sentiment Analysis*: utilização de classificadores de polaridades (negativas e positivas) para extração de sentimentos através, por exemplo, de identificação de palavras-chaves

ou análise léxica. [Thelwall et al. \(2010\)](#) propõem um classificador de sentimentos chamado *SentiStrength* baseado em análise léxica.

4. *Lexical Resources*: utilização da análise léxica pela presença de determinadas palavras-chaves utilizando dicionários de palavras pré-determinadas com em [Nobata et al. \(2016\)](#).
5. *Linguistic Features*: utiliza recursos linguísticos como relações entre palavras na mesma sentença, tempo de verbal, presença de palavras polidas ou não ou expressões regulares. [Zhong et al. \(2016\)](#) utilizam essa abordagem na análise de comentários e legendas de fotos do *Instagram*. Adicionalmente, os autores utilizam redes neurais para detecção de *cyberbullying* através da análise dos *pixels* das imagens.
6. *Knowledge-Based Features*: utiliza informações adicionais (conhecimento do mundo) para implementar uma característica de contexto para refinar a detecção de discurso de ódio como em [Dinakar et al. \(2012\)](#).
7. *Meta-Information*: utilização de meta-informações diversas provenientes de postagens e mensagens como número de postagens por usuário, número de seguidores, localização da postagem ou o número de réplicas de comentários. [Hosseinmardi et al. \(2015\)](#) utilizam essas características para analisar *cyberbullying* em imagens do *Instagram*.
8. *Multimodal Information*: utilização de outras fontes de mídias além do texto, como imagens, vídeos e áudio para complementar a identificação de discurso de ódio como em [Zhong et al. \(2016\)](#), onde os autores analisam o discurso de ódio em imagens do *Instagram*.

Diante da relação entre análise de sentimentos e manifestação de ódio, a primeira sendo utilizada como uma classificação auxiliar, este trabalho utilizará a abordagem de análise de sentimentos nas postagens e nos comentários dos candidatos Jair Bolsonaro e Fernando Haddad.

## 2.2 Análise de Sentimentos

Análise de sentimentos ou *Opinion Mining* faz parte de uma área da computação que estuda e visa identificar as opiniões, sentimentos e emoções em textos. Segundo [Indurkha e Damerou \(2010\)](#), as informações analisadas no texto podem ser fatos, que são expressões claras sobre algo, ou opiniões, que são expressões subjetivas que declaram os sentimentos das pessoas.

### 2.2.1 Estratégias de Análise

Ferramentas e métodos têm sido propostos para fazer análise de sentimentos, acompanhado de diferentes tipos de estratégias, tais como aprendizagem de máquina (*machine learning*), dicionários léxicos ou uma combinação delas, segundo [Gonçalves et al. \(2013\)](#).

[Benevenuto, Ribeiro e Araújo \(2015\)](#) e [Ribeiro et al. \(2016\)](#) realizam comparações entre métodos com estratégias diferentes, apresentando suas vantagens, desvantagens, características, aplicações e limitações. Essas comparações são importantes para se ter uma visão geral das possibilidades presentes na literatura.

[Thelwall, Buckley e Paltoglou \(2011\)](#) dividem as estratégias atuais em três categorias principais:

- Aprendizado de máquina, que utilizam um treinamento de um modelo com sentenças previamente rotuladas;
- Dicionários léxicos ou análise léxica, que utilizam arquivos com sentenças previamente rotuladas sem a criação de um modelo;
- Análise linguística que utiliza a estrutura gramatical dos textos para classificar os sentimentos, algumas vezes em conjunto com a análise léxica.

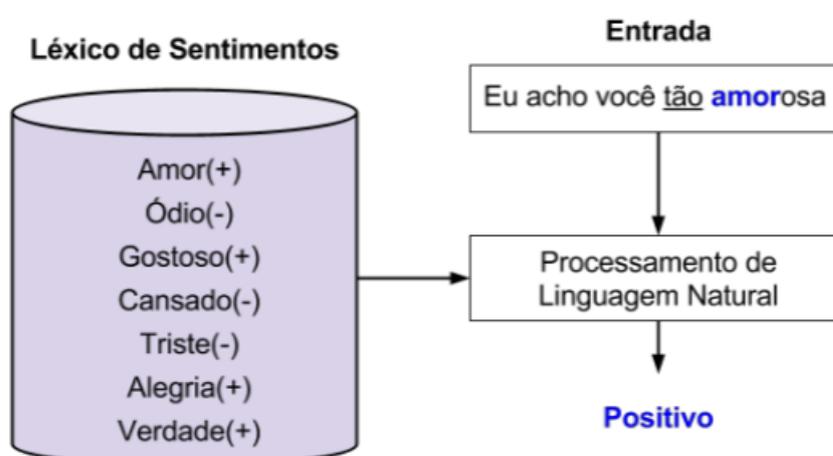
Na abordagem de aprendizado de máquina, um conjunto de textos rotulados com polaridades são utilizados para treinar um algoritmo de inteligência artificial a fim de detectar características destas polaridades, as quais podem ser negativas, neutras e positivas. Segundo [Benevenuto, Ribeiro e Araújo \(2015\)](#), o processo de aprendizado de máquina compreende quatro etapas principais: obtenção de dados rotulados para uso no processo de treino e testes, definição das características para auxiliar a distinção entre os dados, treinamento de um modelo computacional e aplicação do modelo.

No conjunto de dados para qual foi treinado, a estratégia de aprendizado de máquina pode ser considerada eficaz. Entretanto, uma desvantagem desta estratégia é que o desempenho do modelo fica reduzida ao conjunto de dados utilizado. Uma avaliação de sentimento em dados de tempo real (*streaming*), por exemplo, pode ser problemática devido ao alto custo computacional de processamento deste tipo de estratégia, segundo [Benevenuto, Ribeiro e Araújo \(2015\)](#).

A abordagem léxica utiliza uma lista de palavras com polaridades e classifica o texto de acordo com as ocorrências dessas palavras. [Taboada et al. \(2011\)](#) consideram nesta abordagem duas suposições: a orientação semântica é independente de contexto e pode ser expressada com valores numéricos.

Segundo Benevenuto, Ribeiro e Araújo (2015), a análise de sentimento baseada em análise léxica é atualmente umas das estratégias mais eficientes na utilização de recursos computacionais e na capacidade de predição. Os autores descrevem o processo em três passos. O primeiro passo é receber uma sentença de entrada. O segundo passo é realizar um processamento de linguagem natural com uma pesquisa no léxico dos termos que formam a mensagem. Por último, o método é capaz de resultar na polaridade ou sentimento da sentença de entrada. A Figura 1 resume o funcionamento de um método de análise de sentimentos utilizando análise léxica.

Figura 1 – Análise Léxica de Classificação de Sentimentos



Fonte: Benevenuto, Ribeiro e Araújo (2015)

Liu (2012) divide a abordagem léxica em dois grupos principais: técnica baseada em dicionário e técnica baseada em *corpus* (Figura 2). A técnica de dicionários, a qual é utilizada neste trabalho, é baseada na técnica de *bootstrapping*, que segundo Hemmatian e Sohrabi (2019), consiste em criar um pequeno conjunto de palavras que são identificadas manualmente de acordo com suas polaridades (negativas ou positivas). O aumento destes dicionários pode ocorrer de maneira manual ou com auxílio de ferramentas online como, por exemplo, o *WordNet*<sup>1</sup>.

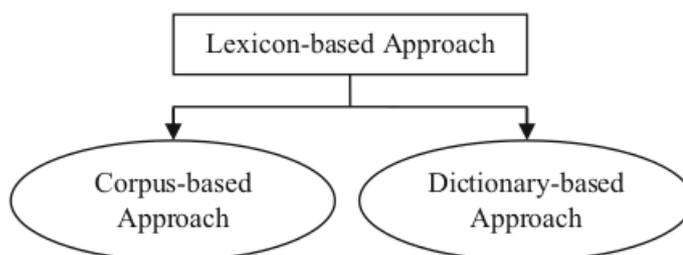
Qiu et al. (2011) utilizaram a técnica de *bootstrapping* para balancear a performance dos modelos de análise de sentimentos para todas as classes envolvidas no estudo enquanto Hassan, Abbasi e Zeng (2013) sugeriram técnica de propagação utilizando *bootstrapping* para solucionar problemas de expansão de vocabulário (*opinion lexicon expansion*) e extração de alvo (*opinion target extraction*) na área de análise de sentimentos (*opinion mining*).

<sup>1</sup> <http://wordnet.princeton.edu/>

A técnica de *corpus* consiste em formar um conjunto de dados composto por textos, palavras, discursos, debates em mídias digitais, frases, trechos, diálogos de um determinado domínio (culinária, análise de debates, culturas sociolinguísticas, traduções literárias, etc.) em um determinado idioma como o português, alemão, espanhol, italiano, etc. Posteriormente, esses conjuntos são rotulados com sentimentos e podem ser aumentados de acordo com as regras semânticas e sintáticas do idioma. Conseqüentemente, esse conjunto está sujeito à dependência das regras semânticas e sintáticas do domínio em estudo.

Na área de análise de sentimentos (*opinion mining*), que predomina o idioma inglês, o tipo *corpus* permite uma criação maior de léxicos em vários outros idiomas, segundo Hemmatian e Sohrabi (2019). Como em Molina-González et al. (2015), que utilizaram essa abordagem na análise de *reviews* de hotéis, filmes e produtos no idioma espanhol. Liao et al. (2016) também utilizaram essa abordagem, porém em um método híbrido no problema de extração de alvo em opinião (*opinion target extraction*) no idioma chinês.

Figura 2 – Classificações da Abordagem Baseada em Análise Léxica



Fonte: Hemmatian e Sohrabi (2019)

Por fim, a abordagem linguística, que utiliza a estrutura gramatical dos textos para classificar os sentimentos, algumas vezes em conjunto com a análise léxica. Wilson, Wiebe e Hoffmann (2009) argumentam que algoritmos linguísticos podem tentar identificar o contexto, negações, superlativos e expressões idiomáticas como parte do processo de previsão de polaridade.

Gamon (2004) obteve resultados significativos para a classificação de documentos usando uma ampla variedade de recursos. O autor incluiu recursos linguísticos, como por exemplo, recursos que capturam características da estruturas do texto, recursos que combinam relações gramaticais e semânticas (por exemplo, assunto da frase ou contexto negado) e recursos que capturam informações de tensão.

Dentre as três abordagens apresentadas, a análise léxica foi utilizada neste trabalho com o auxílio da ferramenta de análise de sentimentos *SentiStrength*. Os dicionários originais em português fornecidos pela ferramenta foram aprimorados para se obter uma

maior abrangência de análise.

## 2.2.2 Métodos de Análise de Sentimentos

Há vários métodos de análise de sentimentos presentes na literatura com diferentes estratégias, sendo as mais utilizadas o aprendizado de máquina e o dicionário léxico. Devido à grande disponibilidade de métodos de análise de sentimentos, esforços são criados para comparar todos os métodos e tentar entender suas limitações, vantagens e desvantagens, como em [Gonçalves et al. \(2013\)](#). Com o intuito de preencher essa lacuna, um *benchmark* comparativo de métodos foi desenvolvido em [Ribeiro et al. \(2016\)](#).

Utilizando-se de vários conjuntos de dados (*datasets*), [Benevenuto, Ribeiro e Araújo \(2015\)](#) realizaram testes comparativos entre vinte e um métodos diferentes. Apesar de não ter um método que apresentou a melhor predição entre todos os *datasets*, os autores constataram que o *SentiStrength*, *Vader* e *Umigon* permaneceram no *top 5* dos melhores métodos analisados.

Tanto *SentiStrength* quanto *Vader* e *Umigon* utilizam a estratégia de análise de sentimentos de dicionários léxicos. Apenas o *SentiStrength* é aprimorado com o uso de aprendizado de máquina. Segundo [Benevenuto, Ribeiro e Araújo \(2015\)](#), alguns métodos fazem uso de heurísticas, *Vader* e *Umigon* por exemplo, com o propósito de aumentar a eficiência da classificação. Essas heurísticas fazem uso de regras gramaticais e semânticas para mudar a intensidade do sentimento, como por exemplo, pontuações, capitalização de palavras, conjunções, negações e intensificadores.

## 2.2.3 *SentiStrength*

O *SentiStrength* utiliza um dicionário léxico anotado por seres humanos e melhorado com o uso de aprendizado de máquina. Ele atribui pontuações a *tokens* de um dicionário, onde *emoticons* também estão incluídos. Palavras com emoções positivas são atribuídos valores entre 1 e 5 e palavras com emoções negativas são atribuídos valores entre -5 e -1. Quanto mais o valor for extremo mais forte são as emoções analisadas. O *SentiStrength* divide o texto em trechos de uma ou mais sentenças e atribui valores positivos ou negativos para cada sentença, informando a pontuação máxima ou mínima entre todas as palavras de uma sentença, como mencionado em [Benevenuto, Ribeiro e Araújo \(2015\)](#). A [Tabela 1](#) apresenta exemplos da análise do *SentiStrength* em sentenças.

Tabela 1 – Exemplos de Análise e Classificação do método *SentiStrength*

Sentença	Análise	Polaridade	Sentimento
Eu amo ir ao cinema	Eu amo[4] ir ao cinema sentence:[4,-1]	[4,-1]	Positivo
Fiquei na cama ontem	Fiquei na cama ontem sentence:[1,-1]	[1,-1]	Neutro
Eu odeio pessoas	Eu odeio[-4] pessoas sentence:[-4,1]	[-4,1]	Negativo

Fonte – Modificado de [Melo \(2017\)](#)

O *SentiStrength* possui alguns dicionários em outros idiomas além do seu idioma nativo inglês como: finlandês, alemão, holandês, espanhol, italiano, russo. O dicionário em português, apesar de estar disponível no site<sup>2</sup> do método, é limitado e precisa ser ampliado para análises. Os arquivos disponibilizados contém as palavras, *emoticons*, palavras de negação, gírias, palavras de intensidade juntamente com seus respectivos rótulos de classificação (polaridade). São quatro os arquivos principais: *EmoticonLookupTable.txt*, *EmotionLookupTable.txt*, *NegatingWordList.txt* e *BoosterWordList.txt*.

*EmoticonLookupTable.txt* descreve os *emoticons* com as suas respectivas emoções, por exemplo, o emoticon “:-)” (carinha feliz) apresenta peso positivo 1. *EmotionLookupTable.txt* tem como objetivo relacionar uma palavra com um peso positivo ou negativo. Esses pesos ficam entre -5 e -1, para palavras negativas e entre 1 e 5 para palavras positivas. Zero indica neutralidade. Por exemplo, a palavra “especial” apresenta peso 3, enquanto a palavra “hipócrita” apresenta peso -4. O *NegatingWordList.txt* tem como propósito identificar palavras de negação. Por exemplo, “não amo”, o “não” presente na frase estaria negando o sentimento de amor. E *BoosterWordList.txt* que tem como objetivo intensificar as emoções, por exemplo, “muito ódio”, o “muito” presente na frase estaria intensificando a emoção amor, aumentando assim o seu peso positivo.

A proposta deste classificador foi realizada em [Thelwall et al. \(2010\)](#), os quais realizaram testes comparativos com outros métodos de classificação. A versão padrão do *SentiStrength* mostrou resultados melhores em comparação com métodos de aprendizado de máquina. Ele foi capaz de identificar sentimentos negativos um pouco melhor (1,8%) do que os outros métodos.

Segundo o autor, o desempenho do método foi aumentada com procedimentos de pré-processamento. Como o uso de algoritmo de correção ortográfica que identifica a grafia padrão de palavras que foram digitadas incorretamente pela inclusão de letras repetidas. Ou ainda uma lista de palavras de reforço que contém palavras que aumentam ou reduzem a emoção das palavras subsequentes, sejam positivas ou negativas. Cada palavra pode

<sup>2</sup> <http://sentistrength.wlv.ac.uk/>

aumentar a força da emoção em 1 ou 2 (por exemplo, muito, extremamente) ou diminuir em 1 (por exemplo, alguns).

A criatividade da linguagem, expressões de sentimento sem palavras que carregam emoção em si e diferenças entre as interpretações dos humanos com o codificador são alguns dos fatores que significam que não existe genuinamente uma classificação correta para a maioria dos textos.

O classificador de sentimentos *SentiStrength* tem sido utilizado em inúmeros trabalhos e testado e avaliado em diferentes contextos. O *SenticNet* em [Cambria e Hussain \(2015\)](#) foi comparado com *SentiStrength* de [Thelwall \(2017\)](#) com um conjunto de dados específico relacionado à opiniões de pacientes. O *Stanford Recursive Deep Model* em [Socher et al. \(2013\)](#) e o *SentiStrength* de [Thelwall \(2017\)](#) foram comparados com técnicas padrões de aprendizado de máquina.

A característica de seu desenvolvimento é a distinção de qualquer tipo de relevância em relação a um evento, ou seja, seu método de análise não leva em consideração o contexto nem análise de semântica ou ambiguidade. Por isso, esse classificador utiliza-se de dicionários com palavras classificadas com polaridades para realizar a análise de acordo com as ocorrências de tais palavras.

Diversas aplicações podem ser encontradas em vários trabalhos, como a detecção de tensão em comunidades online do Twitter em [Burnap et al. \(2015\)](#), detecção do impacto da política no cenário espanhol em [Vilares, Thelwall e Alonso \(2015\)](#), avaliação do desempenho em contexto árabe em [Rabab'Ah et al. \(2016\)](#), análise de sentimento automatizada para turismo e medição de hospitalidade em [Kirilenko et al. \(2018\)](#).

Apesar da dificuldade em detectar sarcasmos, ironia, contexto, como mencionado em [Thelwall \(2017\)](#), o classificador *SentiStrength* mostrou resultados significativos e uma alta versatilidade de aplicações, podendo ter sua acurácia aumentada de acordo com a análise léxica e o aumento do conjunto de dicionários. Por isso, um dos desafios é analisar o desempenho deste método diretamente do idioma português, idioma caracterizado pela complexidade semântica.

A aplicabilidade em vários contextos, resultados satisfatórios em trabalhos diversos como em [Reis et al. \(2015\)](#) e [Araújo et al. \(2013\)](#), versatilidade e disponibilidade para pesquisas acadêmicas foram atrativos para a sua escolha.

## 2.3 Trabalhos Relacionados

A versatilidade de análise de sentimentos mostra-se bem variada. Há aplicações em áreas diversas, como em produtos comerciais, produtos de propaganda, redes sociais, mercados de ações e área política. Esta última área sendo o tema deste trabalho.

Os candidatos a cargos políticos podem utilizar esse tipo de aplicação para tomar decisões durante as campanhas eleitorais. [Silva e Barbosa \(2019\)](#) mencionaram que o espaço nas redes sociais para divulgação de campanhas tem tornado mais ativo em comparação com o espaço do horário eleitoral<sup>3</sup> pela emissoras de rádio e TV.

Utilizando-se da técnica de análise de sentimentos, o *SentiStrength*, [Silva e Barbosa \(2019\)](#) avaliaram a aceitação dos candidatos à eleição presidencial brasileira de 2018, Jair Bolsonaro e Fernando Haddad, combinada com a detecção de posicionamentos nos comentários de usuários na plataforma YouTube<sup>4</sup>. Os autores obtiveram *F1-scores* de 86.7% para a detecção de posicionamentos e 77.8% para análise de sentimentos.

O que difere o trabalho de [Silva e Barbosa \(2019\)](#) deste trabalho refere-se à base dados utilizada. Os autores utilizaram comentários dos usuários no *YouTube* enquanto este trabalho utilizou comentários provenientes do *Facebook*. Outra diferença foi que os autores analisaram a aceitação dos candidatos Jair Bolsonaro e Fernando Haddad no *YouTube*.

Além das polaridades negativas e positivas, [Mohammad et al. \(2015\)](#) mencionaram que as informações expressas de forma mais sutil podem auxiliar nas análises, como emoções (alegria, tristeza, raiva, etc.), intenção (apontar um erro, apoiar, ridicularizar, etc.) e estilo (declaração simples, sarcasmo, hipérbole, etc.). Enquanto [Unankard et al. \(2014\)](#) incorporaram características de geo-localização, período de tempo e tópicos políticos na análise de predição política.

Com dados coletados do *Twitter*<sup>5</sup> durante a eleição presidencial dos Estados Unidos de 2012, [Mohammad et al. \(2015\)](#) utilizaram questionários para rotular os *tweets*<sup>6</sup> de acordo com as informações propostas no trabalho, constatando que as emoções predominantes foram repugnação seguida de confiança. Perceberam também que os *tweets* eleitorais transmitem emoções negativas duas vezes mais que emoções positivas.

Aumentando a acurácia de detecção de sentimentos e diminuindo a taxa de erro com a combinação de séries temporais e pesquisas de opiniões eleitorais, [Tsakalidis et al. \(2015\)](#) analisaram *tweets* nas eleições de 2014 nos países da Alemanha, Grécia e Países Baixos. Os resultados mostraram a importância de incorporar características de sentimentos nas análises, evidenciando o potencial uso dessas na predição de eleições em redes sociais.

[Reis et al. \(2015\)](#) realizaram uma abordagem para detecção e análise de sentimentos para mensagens compartilhadas em aplicações da Web. Nessa abordagem, eles traduziram bases de dados rotuladas em outros nove idiomas (português, francês, espanhol, italiano, turco, russo, árabe, holandês e alemão) para o idioma inglês e executaram treze métodos de análise de sentimentos em sua versão original (inglês). Os resultados mostraram que a

<sup>3</sup> Horário reservado por lei para propaganda eleitoral de candidatos à eleição em emissoras de rádio e televisão.

<sup>4</sup> <https://www.youtube.com/>

<sup>5</sup> <https://twitter.com/>

<sup>6</sup> Postagem realizada na rede social *Twitter* contendo textos, fotos, *GIF* e/ou vídeo.

eficácia dos métodos analisados teve consistência mesmo em bases de dados de diferentes idiomas, mas desde que fossem traduzidas para o idioma original do método, o inglês.

Apesar de terem analisado o método *SentiStrength* e traduzido o idioma português para o inglês, Reis et al. (2015) não o analisaram diretamente no idioma português, como é um dos objetivos deste trabalho. A colaboração de Reis et al. (2015) para este trabalho permitiu a análise de alguns classificadores disponíveis na literatura e seus desempenhos durante a análise de sentimentos.

Araújo et al. (2013) também realizaram testes comparativos entre classificadores da literatura permitindo uma análise abrangente dos melhores classificadores enquanto Guzman, Azócar e Li (2014) utilizaram o classificador *SentiStrength* para analisar comentários dos *commits* na plataforma do *Github*<sup>7</sup>, mas também no idioma inglês. Logo, se faz necessário a análise de sentimentos explorando diretamente o método em texto português.

---

<sup>7</sup> <https://github.com/>

## 3 Metodologia

O objeto de pesquisa deste trabalho está relacionado a análise de sentimentos dos comentários extraídos das páginas do *Facebook* de Jair Bolsonaro e Fernando Haddad. Para a execução deste trabalho, as etapas podem ser definidas como:

1. Revisão da literatura, bem como trabalhos correlatos na análise de sentimentos.
2. Coleta de dados para a formação do conjunto de dados.
3. Processamento e análise exploratória dos dados.
4. Caracterização dos dados.
5. Análise e extração de *insights*.
6. Análise e discussão dos resultados obtidos e identificação de possíveis melhorias.

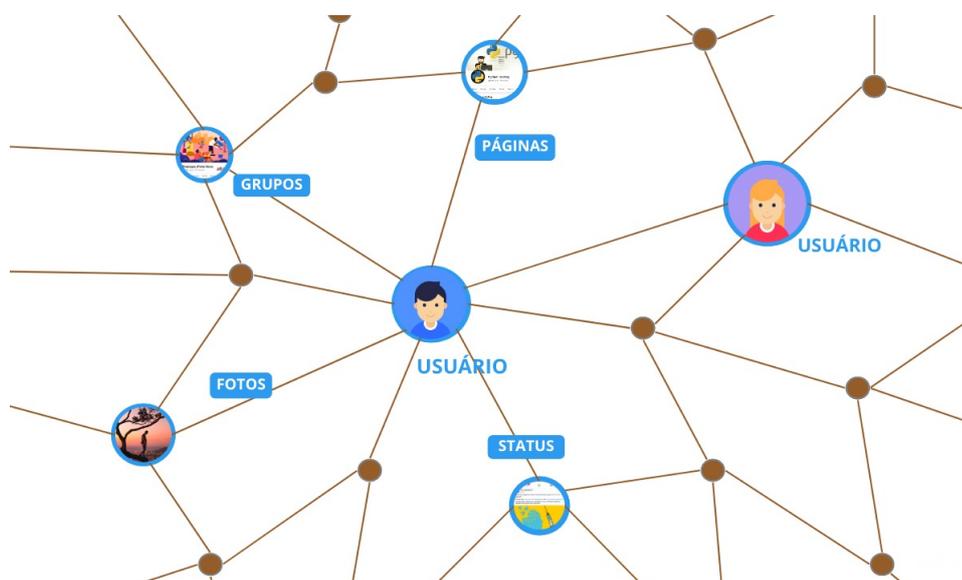
### 3.1 Coleta dos Dados

A coleta dos dados foi realizada utilizando a *Graph API*<sup>1</sup> da plataforma *Facebook*. A *Graph API* é a principal maneira de aplicações inserirem e retirarem dados da plataforma do *Facebook*. É uma Application Programming Interface (*API*) baseada em Hypertext Transfer Protocol (*HTTP*) (protocolo de comunicação baseada em requisição/resposta em um modelo cliente-servidor, por exemplo, o *web-browser*) na qual é possível consultar/publicar dados no *Facebook* programaticamente tais como postar novas histórias, gerenciar anúncios, fazer *upload* de fotos e realizar várias outras tarefas.

As informações geradas no *Facebook* são estruturadas na forma de um grafo, que são estruturas para modelar a relação entre pares de objetos através do uso de nós e arestas. A [Figura 3](#) mostra a representação da estrutura das informações contidas no *Facebook* em forma de um grafo.

---

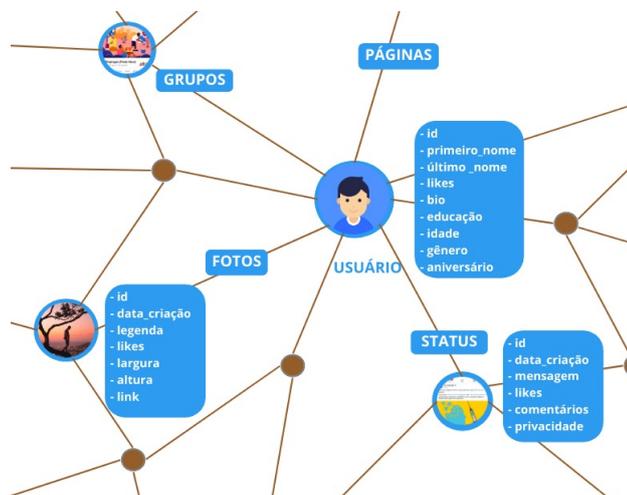
<sup>1</sup> <https://developers.facebook.com/docs/graph-api/>

Figura 3 – Grafo representativo da plataforma *Facebook*

Fonte: elaborado pelo autor

A composição na *Graph API* tem três elementos básicos:

- Nós (*nodes*): objetos individuais como usuário, foto, postagem, comentário ou uma página;
- Arestas (*edges*): coleção de conexões de objetos com um objeto individual, como as fotos de uma página ou os comentários de uma foto;
- Campos (*fields*): informações de um objeto como aniversário de um usuário, nome de uma página, data de criação de uma postagem (Figura 4).

Figura 4 – Informações (*fields*) de um objeto representativo da plataforma *Facebook*

Fonte: elaborado pelo autor

A *Graph API* pode ser utilizada através de qualquer linguagem de programação que tenha suporte para bibliotecas HTTP. Neste trabalho, a linguagem de programação utilizada foi *Python3*<sup>2</sup> na versão 3.7 para a realização da coleta dos dados dos perfis analisados.

A *Figura 5* exemplifica o fluxo de coleta dos dados. Por padrão, o formato das informações coletadas pela *Graph API* são fornecidas em formato JavaScript Object Notation (*JSON*) bastante popular em transferências de dados entre aplicações devido sua alta legibilidade exemplificado na *Figura 6*.

A *Graph API* possibilita a coleta de várias informações (*fields*) referentes às postagens, algumas sendo irrelevantes neste trabalho. A *Figura 6* mostra os *fields* selecionados referentes às postagens e na *Figura 7* os *fields* selecionados referentes aos comentários.

Para a realização da coleta de dados do *Facebook* através da *Graph API* é necessário a criação de chaves de acesso, os *access tokens*. Toda aplicação que tem como objetivo coletar informações do *Facebook* necessitará a geração desses *tokens*. A *Graph API* utiliza esses *tokens* para identificar cada aplicação e o tipo de informação que a aplicação pode ter acesso. Há uma interface<sup>3</sup> da própria *Graph API* que permite a realização de testes de coleta através dos *tokens* gerados na plataforma.

A *Graph API* estipula taxas limites de coleta por aplicação, a qual é calculada pelo número de usuários que cada aplicação possui. Segundo a *Graph API*, a taxa limite é calculada pela fórmula: chamadas em uma hora = 200\**número de usuários*<sup>4</sup>. Ou seja, se

<sup>2</sup> <https://www.python.org/>

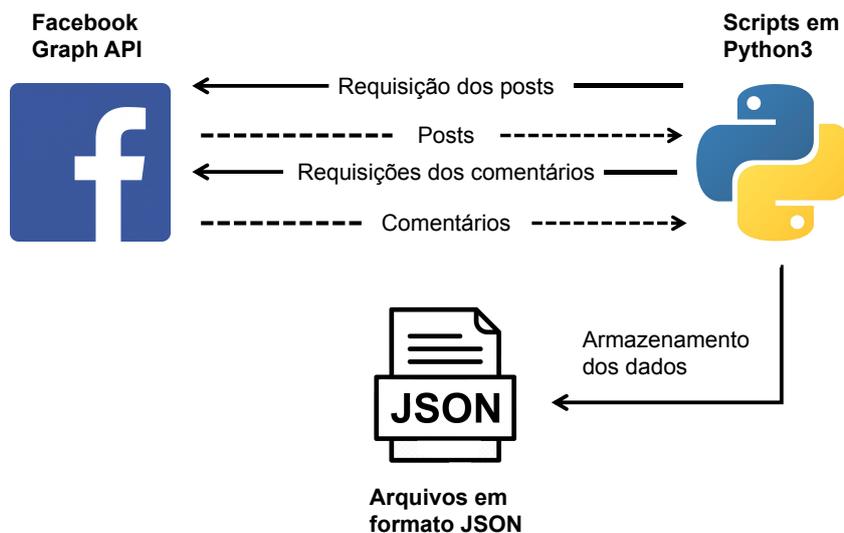
<sup>3</sup> <https://developers.facebook.com/tools/explorer/>

<sup>4</sup> <https://developers.facebook.com/docs/graph-api/overview/rate-limiting/>

uma aplicação tem 100 usuários, a aplicação poderá realizar 200.000 chamadas por hora.

A *Graph API* permite utilizar o recurso de paginação durante as requisições. Essa característica é importante para a coleta, uma vez que a requisição não retorna todos os resultados em apenas uma resposta. Esse recurso permite que a aplicação navegue entre as páginas do resultado através de *links*.

Figura 5 – Fluxo da coleta de dados



Fonte: Modificado de [Silva e Barbosa \(2019\)](#)

Figura 6 – *Fields* coletados referentes à postagem

```

1  {
2    "created_time": "2019-12-28T10:22:13+0000",
3    "id": "904277726319518_2743657325714873",
4    "message": "Coluna da semana sobre os ataques de Bolsonaro à universidade pública.",
5    "shares": {"count": 324},
6    "status_type": "shared_story",
7    "full_picture": "https://external-gru1-1.xx.fbcdn.net/safe_image.php?d=AQCc5dvfpXJ",
8    "reactions_like": {"data": [], "summary": {"total_count": 1793}},
9    "reactions_haha": {"data": [], "summary": {"total_count": 59}},
10   "reactions_wow": {"data": [], "summary": {"total_count": 10}},
11   "reactions_sad": {"data": [], "summary": {"total_count": 225}},
12   "reactions_angry": {"data": [], "summary": {"total_count": 35}},
13   "reactions_love": {"data": [], "summary": {"total_count": 27}}
14 }
  
```

Fonte: elaborado pelo autor

Figura 7 – *Fields* coletados referentes ao comentário

```
1  {
2    "created_time": "2018-09-27T12:58:25+0000",
3    "id": "155342452069908_155351528735667",
4    "message": "Eu quero ver um ótimo governo seu meu presidente.",
5    "comment_count": 8,
6    "like_count": 30,
7    "reactions_haha": {"data": [], "summary": {"total_count": 2}},
8    "reactions_wow": {"data": [], "summary": {"total_count": 0}},
9    "reactions_sad": {"data": [], "summary": {"total_count": 0}},
10   "reactions_angry": {"data": [], "summary": {"total_count": 0}},
11   "reactions_love": {"data": [], "summary": {"total_count": 3}}
12 }
```

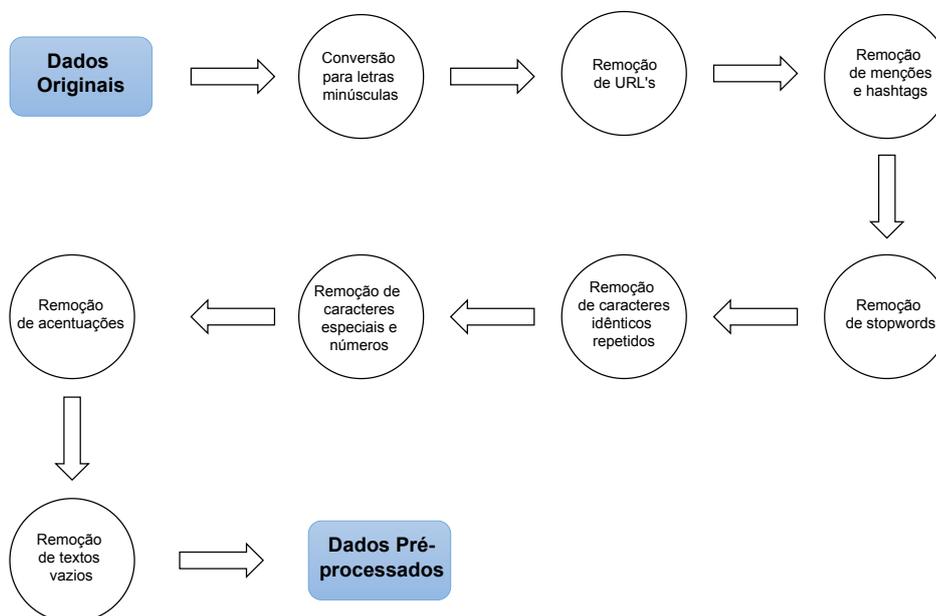
Fonte: elaborado pelo autor

Com o código (*script*) em *Python* estruturado, o período de coleta no *Facebook* foi realizado considerando o período entre Janeiro de 2018 a Dezembro de 2019 de acordo com os *fields* mencionados anteriormente, formando assim o conjunto de dados deste trabalho.

## 3.2 Processamento do Texto

Com os dados coletados, a primeira etapa é o processamento dos dados. Esta etapa consiste em aplicar métodos de processamento e filtros para remoção de informações desnecessárias e/ou irrelevantes para a aplicação do classificador de sentimentos *SentiStrength* posteriormente. Como o *Sentistrength* utiliza palavras-chaves para realizar sua classificação, palavras sem valor podem ser removidas. Os métodos aplicados à base de dados seguem o diagrama da [Figura 8](#).

Figura 8 – Diagrama do fluxo do processamento de dados



Fonte: Modificado de [Silva e Barbosa \(2019\)](#)

O processamento ao todo consiste em oito passos, partindo da conversão de todas as letras para minúsculas, remoção de endereços web, remoção de menções (palavras precedidas de @) e *hashtags* (palavras precedidas de #), remoção de *stopwords* (palavras que não agregam nenhum valor para o classificador de sentimentos, como por exemplo, do, de, a, o, em, é, que, com, se, por, etc...), remoção de caracteres idênticos repetidos (por exemplo, “bommmmm” → “bom”, “goodd” → “good”), remoção de caracteres especiais e números e remoção de acentuações. Todos esses passos foram aplicados tanto nos textos dos comentários quanto no texto da mensagem das postagens utilizando a biblioteca Natural Language ToolKit (NLTK) de [Bird, Klein e Loper \(2009\)](#). A documentação completa está disponível no site<sup>5</sup> da biblioteca.

O último passo, remoção de textos vazios, foi aplicado em ambos os casos (nos comentários e nas mensagens) mas com algumas diferenças. Quando aplicado o fluxo até o último passo, comentários que possuem apenas *stopwords*, URL's, menções, *hashtags* e/ou caracteres especiais ficam vazios, gerando comentários sem representatividade significativa para o classificador de sentimentos. Conseqüentemente, esses comentários geram *scores* (valores) iguais a zero. Por isso, a razão de suas remoções. No caso da remoção de textos vazios nas mensagens das postagens, esta foi apenas realizada quando a análise era dedicada aos sentimentos gerados. Caso fosse realizada outra análise que não envolvesse análise de

<sup>5</sup> <https://www.nltk.org/>

sentimentos, os dados desta postagem era considerados.

### 3.3 Análise de Sentimentos

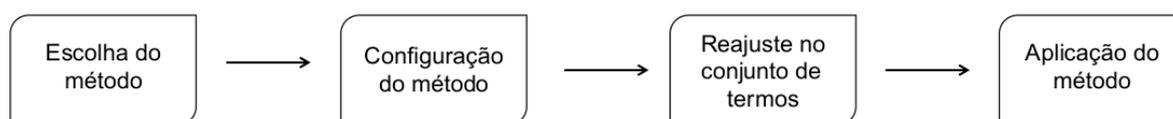
Nesta seção será apresentado o classificador escolhido para a etapa de classificação de sentimentos, bem como a validação do método escolhido e sua configuração.

#### 3.3.1 Escolha do Método

A classificação de sentimentos e o discurso de ódio são intimamente relacionados. Schmidt e Wiegand (2017) relatam que essa relação permite que algumas abordagens incorporem a primeira como uma classificação auxiliar. Na literatura, há várias abordagens envolvendo técnicas de classificação de sentimentos, as quais foram abordadas no Capítulo 2. Neste trabalho, será utilizado o classificador de polaridades chamado *SentiStrength*.

O algoritmo *SentiStrength* analisa o sentimento de um determinado texto utilizando a análise léxica, ou seja, a classificação é realizada a partir de um conjunto de termos (dicionários) com sentimentos previamente classificados e assim predizer o sentimento de um determinado texto a partir da ocorrência desses termos. O fluxo de classificação de sentimentos utilizado neste trabalho segue na Figura 9.

Figura 9 – Diagrama do fluxo da análise de sentimentos



Fonte: Modificado de Silva e Barbosa (2019)

Esse método permite a utilização de aprendizado de máquina (*machine learning*) no aprimoramento de seu conjunto de dicionários, mas essa abordagem não foi utilizada neste trabalho. Apenas a abordagem léxica foi utilizada.

No site oficial do classificador *SentiStrength*<sup>6</sup> é possível fazer o *download* da versão *Windows Version*, porém essa versão não permite automatização do processo de análise de sentimento. Há uma outra versão denominada *Java Version* que permite essa automatização.

<sup>6</sup> <http://sentistrength.wlv.ac.uk/>

Sua disponibilidade está presente no site oficial mediante contato com o responsável da ferramenta. Neste trabalho foi utilizado a última versão apenas para fins acadêmicos.

### 3.3.2 Validação do Método

A análise de sentimentos dos candidatos Jair Bolsonaro e Fernando Haddad a ser realizada a partir da metodologia proposta precisa ser validada para que seja confiável.

Para medir o desempenho da metodologia, 500 comentários da base de dados dos comentários foram selecionados de forma aleatória para comporem um conjunto de dados amostrais, o qual posteriormente foi rotulado pelo autor deste trabalho quanto aos sentimentos dos comentários.

Tabela 2 – Matriz de confusão

		<i>Observação real</i>	
		<b>Positivo</b>	<b>Negativo</b>
<i>Predição</i>	<b>Positivo</b>	tp	fp
	<b>Negativo</b>	fn	tn

Fonte – elaborado pelo autor

tp = *true positive*, fp = *false positive*, fn = *false negative* e tn = *true negative*

Após a rotulação dos comentários, quatro métricas de desempenho tradicionais de métodos de classificação baseadas no trabalho de Sokolova e Lapalme (2009) foram calculadas com o auxílio da biblioteca Scikit-learn<sup>7</sup> para a validação da metodologia de acordo com a matriz apresentada na Tabela 2, sendo elas:

- Precisão (*precision*) ( $P = tp/tp + fp$ ): calculada para cada classe individualmente e evidencia o percentual de sentenças corretamente classificadas para aquela classe, ou seja, é a fração de resultados relevantes.
- Revocação (*recall*) ( $R = tp/tp + fn$ ): calculada para dar indícios do resultado mostrado pela precisão e é calculada justamente pelo total de sentenças corretamente classificadas para uma classe sobre o total de sentenças desta classe na base de dados, ou seja, é a fração de resultados relevantes corretamente classificados.
- Acurácia (*accuracy*) ( $A = tp + tn/tp + fn + fp + tn$ ): indica o percentual de sentenças corretamente classificadas, isto é, a soma acertos de todas as classes dividido pelo número total sentenças classificadas, ou seja, é a fração de comentários classificados corretamente.
- *F1-Score* ( $F = 2(P * R)/P + R$ ): média harmônica entre a precisão e a revocação.

<sup>7</sup> <https://scikit-learn.org/stable/index.html>

### 3.3.3 Classificação de Sentimentos

Após a aplicação do método *Sentistrength* nos textos dos comentários, a classificação gerada pelo método consiste em valores positivos que estimam a polaridade positiva variando de 1 a 5 e valores negativos que estimam a polaridade negativa variando de -1 a -5. Em ambos os casos quanto maior o valor, maior sua expressividade em relação ao sentimento analisado. O método *Sentistrength* permite o controle da saída do resultado esperado. Neste trabalho será utilizado a saída do tipo *scale*. A [Tabela 3](#) resume as possibilidades de saída da análise.

Tabela 3 – Configuração da saída da análise de sentimentos do *SentiStrength*

Saída	Formato	Intervalo
Dual	[positivo, negativo]	[(1,5),(-1,-5)]
Binary	[valor único]	[1 = positivo/ -1 = negativo]
Trinary	[positivo, negativo, neutro]	[(1,5),(-1,-5),0]
Scale	[valor único]	[-4,4]

Fonte – elaborado pelo autor

Os conjuntos de termos ou dicionários podem ser adaptados de acordo com o idioma desejado. Pelo programa ser nativo do inglês, os dicionários disponíveis em português fornecido pelo próprio site do programa apresentam uma pequena quantidade de palavras, o que ocasionaria uma fraca classificação. Neste trabalho foram utilizados dicionários ampliados utilizados e disponibilizados por [Silva e Barbosa \(2019\)](#).

Os autores ampliaram os dicionários originais adicionando termos abreviados, femininos, no plural, tradução dos termos em inglês, mantendo os graus de polaridade originais além de termos relacionados aos candidatos analisados, Jair Bolsonaro e Fernando Haddad, onde os graus de polaridade foram atribuídos de acordo com o fluxo apresentado na [Figura 10](#).

A primeira etapa foi a criação de dicionários de palavras e *hashtags* recorrentemente utilizados para fazer referência a cada um dos candidatos, sem levar em consideração a opinião dos autores. Após a criação dos dicionários, cada termo foi acrescido de pesos entre 1 e 5 através da média aritmética calculada a partir da classificação por 10 voluntários, onde 1 corresponde a uma baixa relação com o candidato e 5 corresponde a uma alta relação com o candidato.

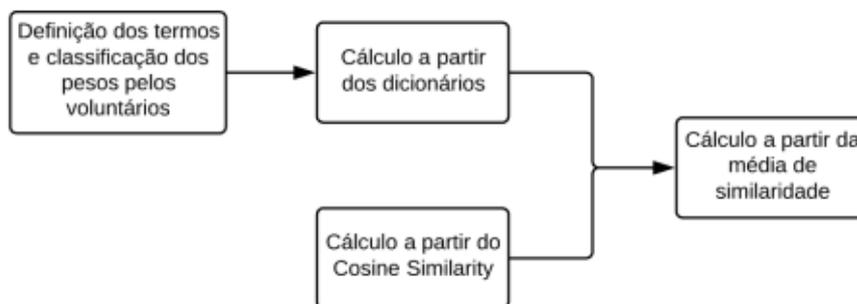
Após essa etapa, um peso relacionado a cada candidato foi atribuído a cada comentário da base de dados seguido de uma normalização por valor máximo. Posteriormente, um texto relacionado com cada candidato foi criado exatamente com os mesmos termos definidos na primeira etapa, os quais foram separados por um espaço. O método *Cosine Similarity* foi utilizado no cálculo da similaridade, variando de 0 a 1, entre vetores projeta-

dos em um espaço multidimensional ao medir o cosseno do ângulo formado entre eles, no caso entre os textos criados e o texto dos comentários.

Na última etapa, foi calculado a média aritmética entre os resultados provenientes da etapa de similaridade classificada por voluntários e a etapa relacionada à frequência e a relevância dos termos.

O conjunto final após as adições dos termos totalizou 4065, sendo 222 termos relacionados aos candidatos Jair Bolsonaro e Fernando Haddad. Alguns destes termos são apresentados na [Tabela 4](#).

Figura 10 – Diagrama do fluxo de ampliação dos termos relacionados aos candidatos



Fonte: [Silva e Barbosa \(2019\)](#)

Tabela 4 – Exemplos de termos adicionados ao *SentiStrength*

Bolsonaro		Haddad	
Termos	Sentimento	Termos	Sentimento
bolsomito	5	comunista	-3
fascista	-5	doutor	2
machista	-4	humilddad	3
mito	4	malddad	-5

Fonte: [Silva e Barbosa \(2019\)](#)

Após o processamento dos dados, definição e configuração do programa *SentiStrength*, a análise de sentimentos foi realizada nos comentários e nas mensagens das postagens.

## 4 Caracterização dos *Datasets*

Este capítulo está dividido da seguinte maneira: na Seção 4.1 será realizada a caracterização dos dados utilizados, na Seção 4.2 será realizada a descrição e análise das reações (engajamentos) nos perfis analisados, e na Seção 4.3 será realizada a análise dos sentimentos gerados a partir das postagens e na Seção 4.4 em relação aos comentários.

### 4.1 Caracterização dos Dados

Com os dados coletados e utilizando a linguagem de programação *Python*, foram criados dois *datasets* (conjunto de dados), um para os dados referentes às postagens e outro para os dados referentes aos comentários das postagens. Em ambos os casos, os dados foram convertidos para o formato tabular/*dataframe* (semelhante às tabelas criadas no Microsoft Excel com linhas e colunas) por questões de desempenho de análise computacional. Para simplificar referências futuras, o *dataset* de dados das postagens será renomeado como `df_posts` e o *dataset* de dados dos comentários como `df_comments`. A Tabela 7 detalha as respectivas colunas do `df_posts` e a Tabela 8 detalha as colunas do `df_comments`.

Os dados coletados dos perfis de Jair Bolsonaro e Fernando Haddad estão compreendidos entre o período de Janeiro de 2018 a Dezembro de 2019. A Tabela 5 resume o conjunto de dados coletado.

Tabela 5 – Conjunto dos dados coletados

	<b>Bolsonaro</b>	<b>Haddad</b>	<b>Total</b>
<b>Postagens</b>	1185	1169	2.354
<b>Comentários</b>	6.804.829	3.332.335	10.137.164

Fonte – Elaborada pelo autor

Nesse período o número de postagens de Jair Bolsonaro totalizou 1185 postagens e Fernando Haddad totalizou 1169 postagens, contabilizando no total 2.354 postagens coletadas.

A partir dessas postagens foram coletados todos os respectivos comentários, totalizando 6.804.829 comentários para Jair Bolsonaro e 3.332.335 comentários para Fernando Haddad. No total, há 10.137.164 comentários de ambos candidatos, os quais foram processados e analisados.

Ao final da etapa do processamento do texto, conforme a Tabela 6, a base de dados de Jair Bolsonaro reduziu de 6.804.829 para 5.515.330 comentários e a base de dados de

Fernando Haddad reduziu de 3.332.335 para 2.336.881 comentários. A redução na base de dados de Jair Bolsonaro e Fernando Haddad foram de 18.95% e 29.87%, respectivamente, totalizando no final 7.852.211 comentários de ambos candidatos. Quanto às postagens, a redução foi de 11.65% na base de dados de Jair Bolsonaro e 5.3% na base de dados de Fernando Haddad.

Tabela 6 – Conjunto dos dados processados

	<b>Bolsonaro</b>	<b>Haddad</b>	<b>Total</b>
<b>Postagens</b>	1047 (-11.65%)	1107 (-5.3%)	2154
<b>Comentários</b>	5.515.330 (-18.95%)	2.336.881 (-29.87%)	7.852.211

Fonte – Elaborada pelo autor

Observa-se que a diferença entre postagens no conjunto original foi pequena, apenas de 16 postagens, com Jair Bolsonaro apresentando mais postagens. O número de comentários relacionado às postagens de Jair Bolsonaro são expressivas, totalizando mais que o dobro em relação às postagens de Fernando Haddad. Isto indica uma interação maior dos usuários do *Facebook* nas postagens de Bolsonaro do que nas postagens de Haddad.

Vale ressaltar que a contagem dos comentários não leva em consideração as respostas de comentários, denominadas *replies*. Devido o escopo do trabalho em analisar a postagem e seus comentários, as respostas de comentários perdem um pouco da relevância devido sua relação direta com o comentário e não com o assunto da postagem.

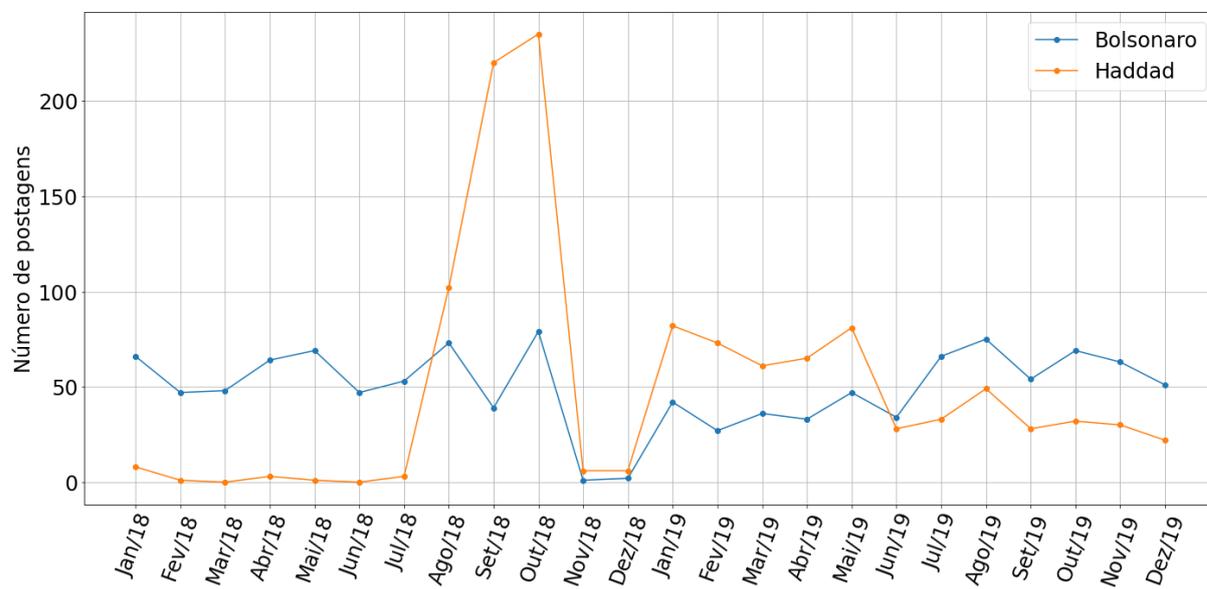
Realizando um comparativo no número de postagens mensais entre Bolsonaro e Haddad, como mostrado na [Figura 11](#) em uma linha temporal, nota-se que antes de Julho/2018 ambos apresentaram uma linha de postagens quase constante, Bolsonaro dispondo de uma média de 56 postagens mensais e Haddad uma média de 2 postagens mensais. Por ser o ano da eleição presidencial brasileira, foi um diferença considerável.

A partir de Julho/2018 há uma mudança no comportamento no número de postagens. Enquanto Bolsonaro permanece com pouca variação no número de postagens, Haddad mostrou-se bastante ativo no *Facebook*, com um pico na linha temporal, indo de 2 postagens mensais em Julho/2018 para mais de 230 postagens em Outubro/2018, mês da eleição presidencial. Um aumento bastante significativo.

Após a eleição presidencial, há uma queda no gráfico temporal nos meses de Outubro e Novembro/2018 para ambos candidatos, o que seria justificado pela pausa das atividades políticas do fim do ano. Em seguida, a linha temporal apresenta poucas variações no ano de 2019, apresentando Haddad mais ativo no *Facebook* até o mês de Maio/2019. Posteriormente, Haddad diminui sua atividade na rede social, enquanto, por outro lado, observamos Bolsonaro apresentar uma atividade crescente na rede social ao

longo do ano de 2019.

Figura 11 – Número de postagens mensais



Fonte: elaborado pelo autor

Tabela 7 – Detalhamento do dataframe `df_posts`

Coluna	Descrição	Tipo
<code>created_time</code>	data de criação do post (formato <code>datetime</code> )	categórico
<code>day</code>	dia extraído da data de criação	numérico
<code>month</code>	mês extraído da data de criação	numérico
<code>year</code>	ano extraído da data de criação	numérico
<code>hour</code>	hora extraído da data de criação	numérico
<code>minute</code>	minuto extraído da data de criação	numérico
<code>seconds</code>	segundos extraído da data de criação	numérico
<code>id</code>	identificação (sequências de números)	categórico
<code>message</code>	texto correspondente a mensagem	categórico
<code>shares</code>	número de compartilhamento	numérico
<code>status_type</code>	tipo de atualização do status	categórico
<code>full_picture</code>	endereço web - Uniform Resource Locator ( <b>URL</b> )	categórico
<code>reactions_like</code>	número de reação like	numérico
<code>reactions_haha</code>	número de reação haha	numérico
<code>reactions_wow</code>	número de reação wow	numérico
<code>reactions_sad</code>	número de reação sad	numérico
<code>reactions_angry</code>	número de reação angry	numérico
<code>reactions_love</code>	número de reação love	numérico
<code>processed_message</code>	mensagem processada	categórico
<code>score_dual_positive</code>	score do tipo dual do <code>sentistrength</code> (positivo)	numérico
<code>score_dual_negative</code>	score do tipo dual do <code>sentistrength</code> (negativo)	numérico
<code>score_binary</code>	score do tipo binary do <code>sentistrength</code>	numérico
<code>score_trinary_positive</code>	score do tipo trinary do <code>sentistrength</code> (positivo)	numérico
<code>score_trinary_neutral</code>	score do tipo trinary do <code>sentistrength</code> (neutro)	numérico
<code>score_trinary_negative</code>	score do tipo trinary do <code>sentistrength</code> (negativo)	numérico
<code>score_scale</code>	score do tipo scale do <code>sentistrength</code>	numérico

Fonte – Elaborada pelo autor

Nota – **Datetime**: objeto na linguagem *Python* que armazena informações de datas e tempo em diversos formatos.

**Tipo numérico**: atributos quantitativos que podem sofrer operações matemáticas e representam quantidades.

**Tipo categórico**: atributos qualitativos que representam qualidades e podem ser associados a categorias.

Tabela 8 – Detalhamento do dataframe df\_comments

Coluna	Descrição	Tipo
created_time	data de criação do post (formato datetime)	categórico
day	dia extraído da data de criação	numérico
month	mês extraído da data de criação	numérico
year	ano extraído da data de criação	numérico
hour	hora extraído da data de criação	numérico
minute	minuto extraído da data de criação	numérico
seconds	segundos extraído da data de criação	numérico
id	identificação (sequências de números)	categórico
message	texto correspondente a mensagem	categórico
comment_count	número de comentário	numérico
like_count	número de likes	numérico
reactions_haha	contagem de reação haha	numérico
reactions_wow	contagem de reação wow	numérico
reactions_sad	contagem de reação sad	numérico
reactions_angry	contagem de reação angry	numérico
reactions_love	contagem de reação love	numérico
processed_message	mensagem processada	categórico
score_dual_positive	score do tipo dual do sentistrength (positivo)	numérico
score_dual_negative	score do tipo dual do sentistrength (negativo)	numérico
score_binary	score do tipo binary do sentistrength	numérico
score_trinary_positive	score do tipo trinary do sentistrength (positivo)	numérico
score_trinary_neutral	score do tipo trinary do sentistrength (neutro)	numérico
score_trinary_negative	score do tipo trinary do sentistrength (negativo)	numérico
score_scale	score do tipo scale do sentistrength	numérico

Fonte – Elaborada pelo autor

Outra caracterização foi a geração das principais métricas estatísticas em relação ao tamanho das postagens e dos comentários através do número de caracteres. Pelos resultados da [Tabela 9](#) percebe-se que o tamanho das postagens de Bolsonaro apresentaram uma dispersão maior em relação a média do que as postagens de Haddad. Essa dispersão é medida pelo desvio padrão. Isto mostra que as postagens de Haddad são mais uniformes no tamanho do que as postagens de Bolsonaro.

A média do tamanho dos comentários não ficaram muito distantes entre Bolsonaro e Haddad. Bolsonaro apresentou uma média 181.51 caracteres nas postagens enquanto Haddad apresentou uma média de 138.50 caracteres nas postagens. Uma diferença de aproximadamente 25 caracteres. Quanto à mediana, medida que divide o conjunto de dados em 50%, apresentou valores bem próximos no tamanho das postagens. Bolsonaro apresentou 113 caracteres nas postagens contra 104 caracteres de Haddad. Destaque para os maiores comentários de cada candidato, com Bolsonaro apresentando comentário com mais de 40 mil caracteres e Haddad com comentário com quase 8 mil caracteres. Devido ao

grande valor de caracteres em relação ao comentário de Bolsonaro, o mesmo foi analisado e a justificativa é que a palavra “BOLSONARO” foi repetida inúmeras vezes no mesmo comentário. Quanto ao comentário de Haddad, a justificativa é que há uma pegadinha de uma contagem de números de linha por linha de 1 a 1000.

Tabela 9 – Descrição do tamanho de caracteres das postagens e comentários

Métricas	Bolsonaro		Haddad	
	Postagens	Comentários	Postagens	Comentários
Média	181.51	73.95	138.50	48.75
Desvio padrão	309.71	139.61	175.64	97.35
Mínimo	9	1	6	1
1º Quartil (25%)	61	21	75	14
2º Quartil (50%)	113	43	104	27
3º Quartil (75%)	220.50	84	158	27
Máximo	5560	40.671	3688	7.970

Fonte: elaborado pelo autor

## 4.2 Entendendo as Reações (Engajamentos)

Com a grande popularização das redes sociais, a palavra engajamento adquiriu tanta notoriedade que se tornou quase um termômetro, um indicador crucial na eficácia de certas ações, tanto no mercado profissional quanto para fins pessoais. Nas redes sociais, esse engajamento mostra-se quando alguém realiza uma postagem gerando comentários, *likes*, compartilhamentos, dislikes, marcações e reações diversas. Isso permite medir o quão receptivo ou não o assunto foi recebido por parte dos seguidores.

A análise dos engajamentos dos candidatos analisados, Jair Bolsonaro e Fernando Haddad, será feita primeiramente estabelecendo quais *fields* foram considerados nas informações coletadas. A [Tabela 10](#) resume os *fields* coletados sobre as postagens e comentários realizados no *Facebook*.

Tabela 10 – *Fields* representativos de engajamento no *Facebook*

<b><i>Fields</i></b>	<b>Descrição</b>	<b><i>Emoji</i></b>
reactions_like	total de reações like (gostei)	
reactions_haha	total de reações haha (engraçado)	
reactions_wow	total de reações wow (surpreso)	
reactions_sad	total de reações sad (triste)	
reactions_angry	total de reações angry (bravo)	
reactions_love	total de reações love (amei)	
shares	total de compartilhamento	

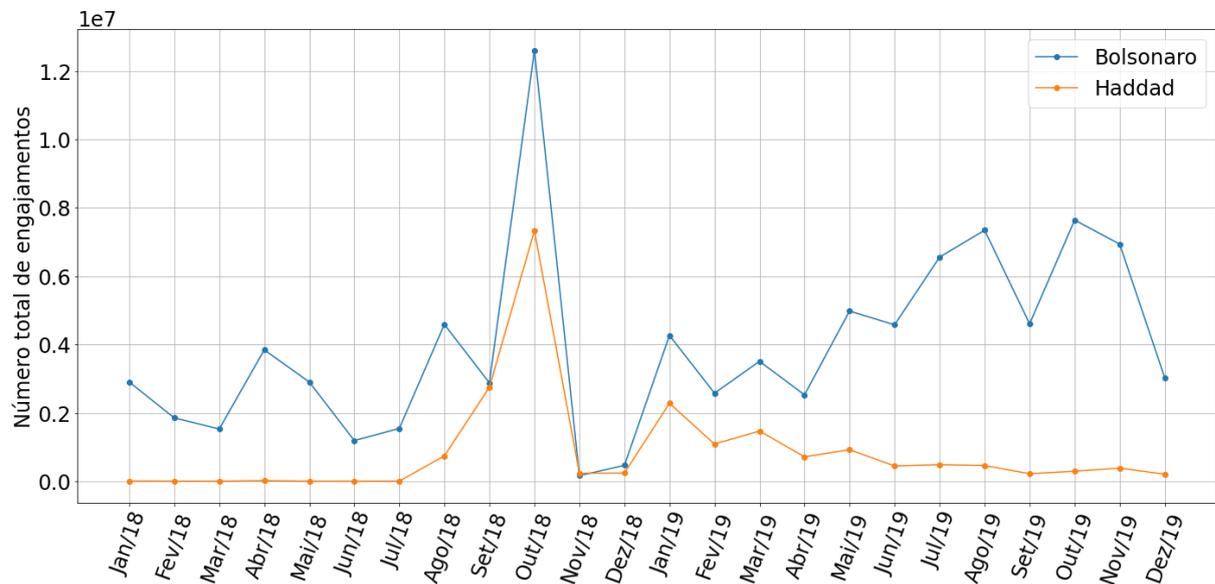
Fonte: elaborado pelo autor

Realizando um somatório de todas as *fields* (like, haha, wow, sad, angry, love, shares) descritos anteriormente e analisando o total em cada mês, tem-se a distribuição da [Figura 12](#). Verifica-se que o comportamento da linha do gráfico é bem similar à apresentada na [Figura 11](#) referente ao número de postagens mensais dos candidatos. Há pouca atividade no *Facebook* em relação a Haddad dentro do intervalo de Janeiro/2018 e Julho/2018, surgindo apenas um aumento no número total de engajamentos próximo aos meses que antecedem a eleição presidencial em Outubro/2018. Ao longo do ano de 2019, percebe-se uma diminuição no total de engajamentos de Haddad.

Observando à linha temporal de Jair Bolsonaro, observa-se que no período de Janeiro/2018 e Julho/2018, Bolsonaro apresenta valores mais expressivos em relação a Haddad. No mês de Outubro/2018, ambos candidatos apresentam um pico no número total de engajamentos com Bolsonaro apresentando o maior valor. Logo após a eleição, nos meses de Novembro e Dezembro de 2018, há uma queda de engajamentos, justificada pela diminuição de atividades políticas nos meses finais do ano. Ao longo do ano de 2019, Bolsonaro manteve um aumento crescente, o que poderia ser justificado pela vitória na eleição presidencial de 2018 enquanto Haddad apresenta uma diminuição no número de engajamentos ao longo do ano de 2019.

Esse aumento indica uma maior popularidade de Jair Bolsonaro no *Facebook*, o que conseqüentemente geraria mais interações do público em sua página na rede social. A análise do engajamento mede tanto interações favoráveis, como gostei, amei, engraçado, quanto interações contrárias, como indagação, raiva, tristeza.

Figura 12 – Gráfico do somatório de engajamentos por mês

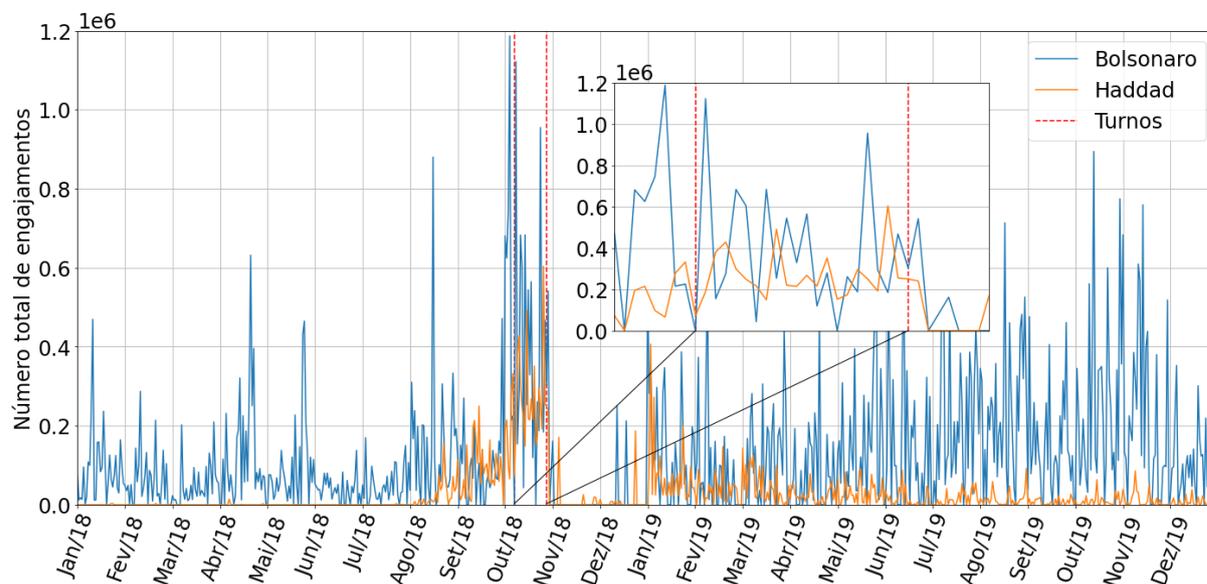


Fonte: elaborado pelo autor

A mesma análise do somatório dos engajamentos, desta vez por dia, é mostrada na [Figura 13](#). Verifica-se que Bolsonaro apresenta valores mais altos em relação a Haddad novamente.

O comportamento permanece semelhante ao da [Figura 12](#), com Haddad apresentando valores mais baixos até os meses próximos de Outubro, maior atividade próximo à eleição e pouca atividade nos meses finais de 2018. Uma constante atividade na rede social é mostrada ao longo de 2019 sem grandes valores. Bolsonaro, por outro lado, apresenta grandes valores antes, durante e após a eleição. O destaque (gráfico menor) da [Figura 13](#) mostra o período compreendido entre o primeiro e segundo turnos da eleição. Bolsonaro durante esse período manteve ativo no *Facebook* gerando altos valores de engajamentos, com destaque para um pico logo após o primeiro turno.

Figura 13 – Gráfico do somatório de engajamentos por dia



Fonte: elaborado pelo autor

#### 4.2.1 Caracterização dos Conteúdos com Maiores Engajamentos no *Field LIKE*

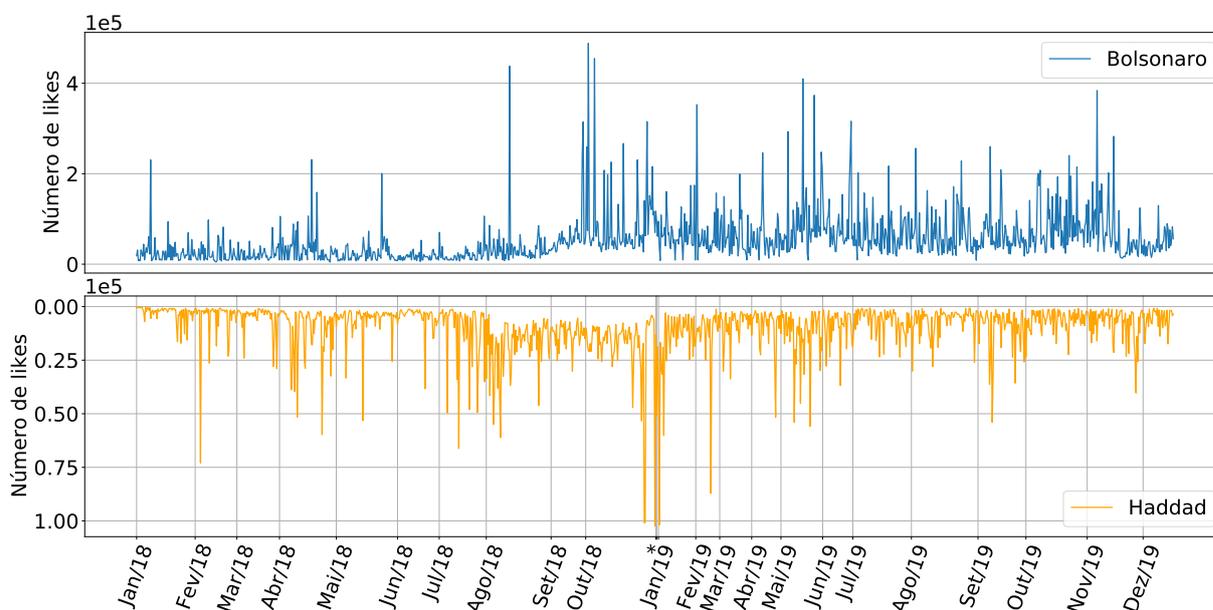
Analisando a distribuição do engajamento *like* ao longo do tempo (Figura 14), percebe-se uma diferença nos valores entre Bolsonaro e Haddad. Nota-se que Bolsonaro apresenta maiores valores em comparação com Haddad. Diante deste fato, a análise será baseada na caracterização dos conteúdos das postagens *top 5* com maiores valores no engajamento *like* de cada candidato.

Relacionado ao candidato Bolsonaro, a postagem que aparece na primeira posição foi uma transmissão ao vivo (*live*) realizada no dia 04 de Outubro de 2018 com Silas Malafaia e Cláudio Duarte totalizando quase meio milhão de *likes*. Na segunda posição, aparece novamente uma transmissão ao vivo (*live*) realizada no dia 07 de Outubro de 2018 referente à ida para o segundo turno. Na terceira posição refere-se a um vídeo do depoimento de um morador dos Estados Unidos que iria votar em Bolsonaro. Na quarta posição aparece uma postagem sobre as felicitações ao casamento do filho de Bolsonaro, Eduardo Bolsonaro. Por último, uma postagem sobre a saída de Bolsonaro do seu partido, o Partido Social Liberal (PSL) e a criação de um novo partido, o “Aliança pelo Brasil”.

Quanto a Haddad, a primeira posição refere-se a uma postagem no dia 24 de Dezembro de 2018 desejando amor a seus eleitores, totalizando mais de 100 mil *likes*. Na segunda posição aparece uma foto mostrando Haddad lendo um livro do escritor Anísio Teixeira. Na terceira posição, há uma declaração de Haddad dizendo que está à disposição

do Brasil. Na quarta posição, aparece a atualização da foto de perfil. Por fim, na quinta posição, uma foto de Haddad com Jean Wyllys.

Figura 14 – Gráfico da distribuição do engajamento LIKE



Fonte: elaborado pelo autor

\* – Os meses Novembro/2018 e Dezembro/2018 apresentaram poucas postagens. Por motivo de clareza, a legenda foi omitida.

#### 4.2.2 Caracterização dos Conteúdos com Maiores Engajamentos no *Field ANGRY*

Seguindo a mesma metodologia do *field LIKE*, a análise será de acordo com as postagens *top 5* com maiores valores no engajamento *angry* de cada candidato. Diferentemente do engajamento *like*, o qual identificou Bolsonaro apresentando maiores valores de engajamentos em relação a Haddad, o engajamento *angry* mostrou valores maiores para Haddad em alguns períodos como, por exemplo, entre Agosto/2018 e Outubro/2018 e entre Janeiro/2019 e Julho/2019, conforme a [Figura 15](#). Observa-se também uma maior concentração de valores no período compreendido entre Agosto/2018 e Agosto/2019, principalmente em relação ao Haddad.

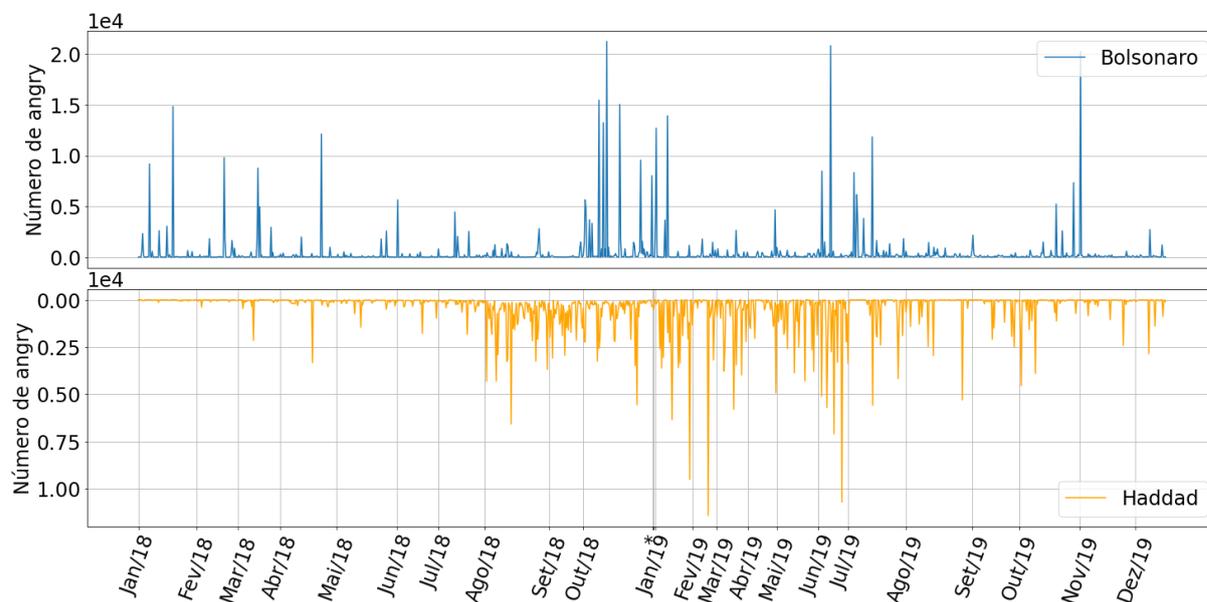
Começando por Bolsonaro, a postagem com maior engajamento *angry*, com mais de 21 mil *angry*, foi relacionada a um vídeo de uma passeata de Guilherme Boulos discursando contra Bolsonaro. A segunda posição está um vídeo sobre criminosos sendo soltos em delegacia sobre a morte de um sargento da polícia. A terceira postagem com maior engajamento *angry* refere-se a um vídeo sobre jornal Globo News referindo Bolsonaro

como ex-presidente em reportagem. Na quarta posição há um vídeo contra Haddad e seu apoiador Johnny Hooker. E na última posição há novamente um vídeo contra Haddad mostrando apoio a Lula.

Quanto a Haddad, a postagem com maior engajamento *angry* foi a reportagem da declaração da ministra Damares Alves sobre atos de pais holandeses com mais de 11 mil *angry*. Na segunda posição, uma reportagem sobre o Planalto divulgar vídeo em defesa ao golpe militar de 1964. A terceira posição é uma reportagem sobre suspensão da investigação de Fabrício Queiroz. Na quarta posição, há uma postagem sobre um vídeo contra Bolsonaro. Por último uma transmissão ao vivo *live* de Haddad para rádios da Bahia.

Percebe-se que pelos conteúdos deste engajamento *angry*, os conteúdos normalmente são direcionados ao outro candidato, diferentemente do engajamento *like*, o qual apresentou conteúdos relacionados ao próprio candidato. Isso é mais evidente durante as disputas políticas, onde os candidatos discutem entre si, direcionam seus conteúdos aos atos do outro mas também geram conteúdos relacionados a si mesmo. Consequentemente, este tipo de comportamento gera engajamentos diversos nas redes sociais.

Figura 15 – Gráfico da distribuição do engajamento ANGRY



Fonte: elaborado pelo autor

\* – Os meses Novembro/2018 e Dezembro/2018 apresentaram poucas postagens. Por motivo de clareza, a legenda foi omitida.

## 4.3 Avaliando as Mensagens das Postagens

Nesta seção será realizada a análise das postagens, bem como os conteúdos das postagens através de nuvens de palavras e os sentimentos gerados.

### 4.3.1 Caracterização do *Field STATUS\_TYPE*

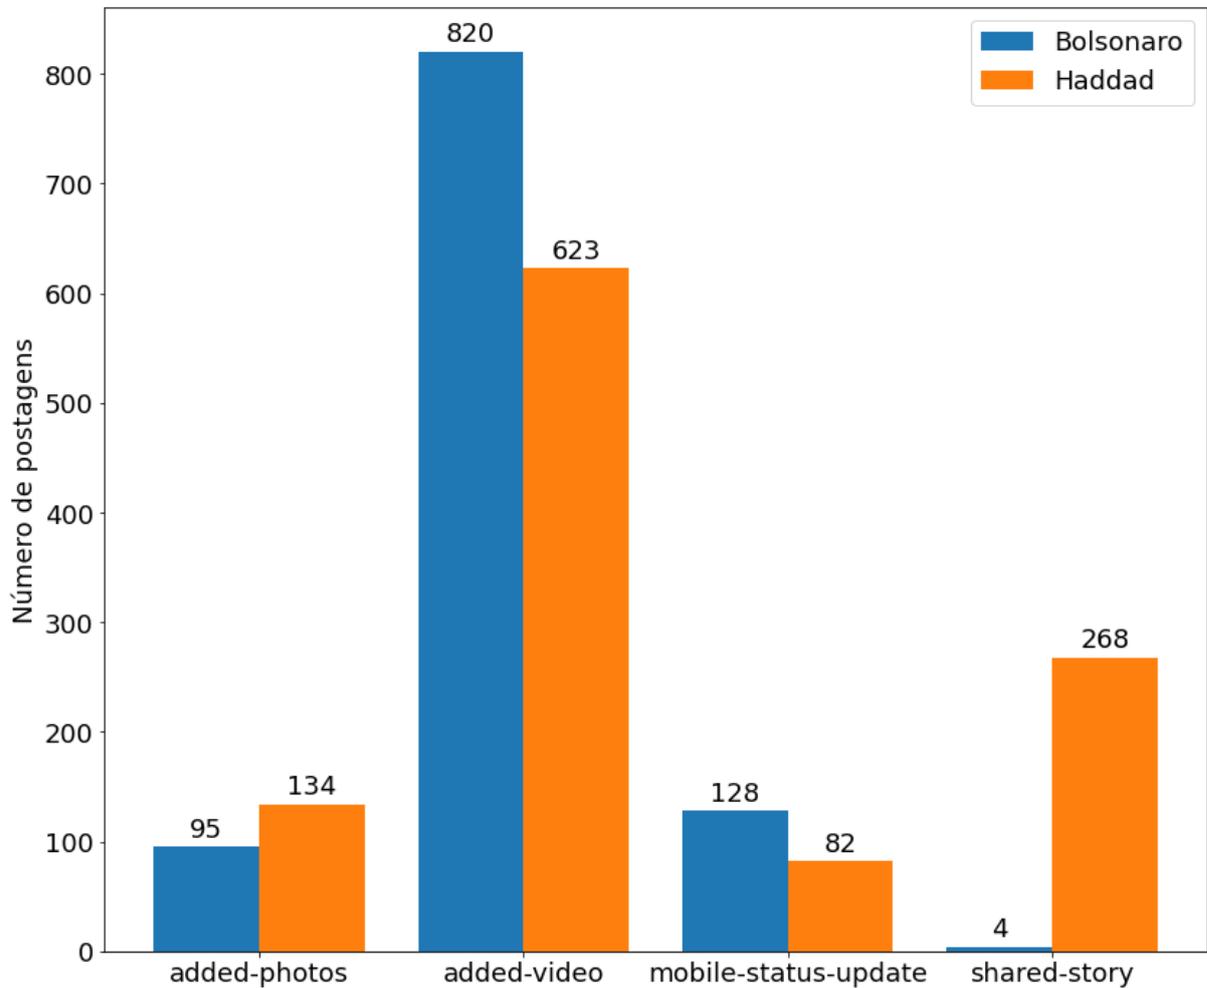
Essa *tag* permite verificar a forma que cada postagem foi realizada dentro da plataforma *Facebook*. A *Graph API* refere-se a esta como um tipo de update do status, do inglês *type of a status update*. A [Tabela 11](#) resume todas as possibilidades dos valores para essa *tag* na plataforma do *Facebook*.

Tabela 11 – Valores da *tag* status-type

added_photos	added_video
app_created_story	approved_friend
created_event	created_group
created_note	mobile_status_update
published_story	shared_story
tagged_in_photo	wall_post

Fonte: ([FACEBOOK, 2021](#))

Analisando a *tag* status\_type dos candidatos Jair Bolsonaro e Fernando Haddad, gerou-se o gráfico da [Figura 16](#). Nota-se que apenas quatro dos doze tipos da [Tabela 11](#) apareceram no conjunto de dados. O tipo de postagem mais utilizado por Bolsonaro e Haddad foi no formato de vídeo (*added\_video*). No formato de fotos (*added\_photos*), ambos fizeram uso bem próximos, com destaque para o formato *shared\_story*, compartilhamento de *stories*, onde Bolsonaro utilizou apenas em 5 postagens enquanto Haddad fez uso em 276 postagens. Resumidamente, o recurso mais utilizado por ambos foi vídeo como forma de interação na rede social.

Figura 16 – Gráfico da distribuição da *tag status\_type*

Fonte: elaborado pelo autor

### 4.3.2 Conteúdo das Postagens

Uma das formas de realizar análise e visualizar dados em formato de texto é verificar quais palavras foram mais utilizadas no texto, no caso deste trabalho, nas postagens e nos comentários. Isto significa criar um reconhecimento das palavras-chaves (*keywords*) de um texto. A nuvem de palavras mostra a quantidade de utilização (frequência) de cada palavra pelo seu tamanho, ou seja, quanto maior for a palavra na nuvem de palavras maior foi sua utilização no texto e vice-versa.

A geração das nuvens de palavras foram separadas em três períodos para ambos candidatos de acordo com a [Tabela 12](#).

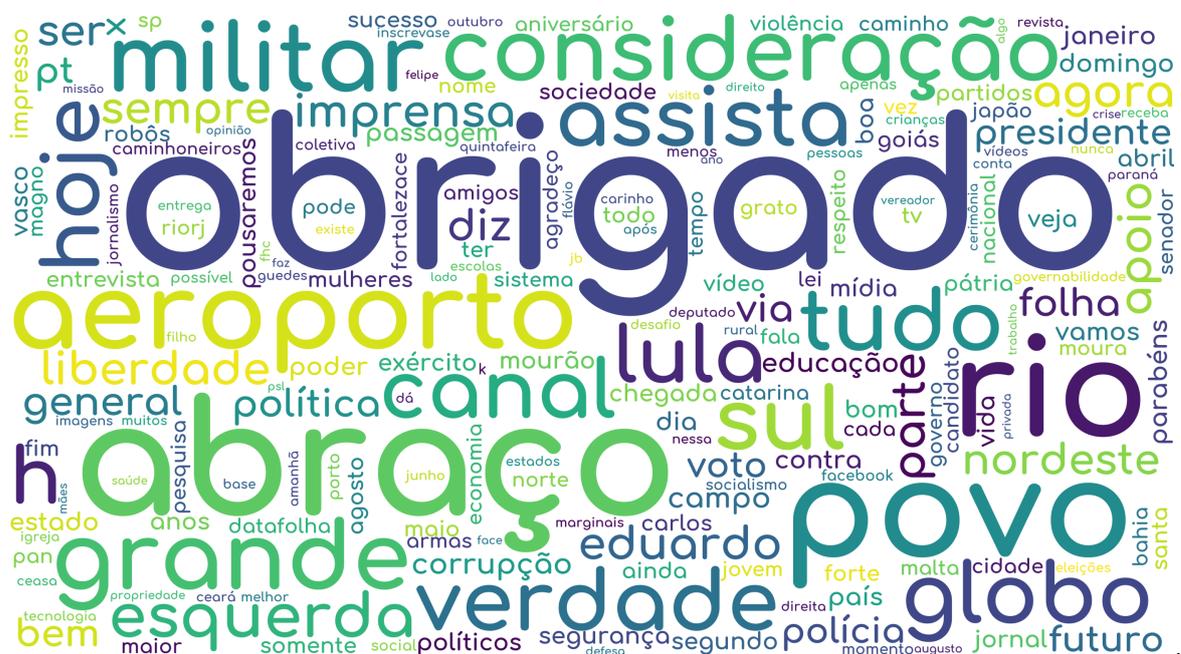
Tabela 12 – Divisão do conjunto de dados em períodos

Nome	Período
Antes da eleição (P1)	01-01-2018 a 06-10-2018
Durante a eleição (P2)	07-10-2018 a 28-10-2018
Após a eleição (P3)	29-10-2018 a 31-12-2019

Fonte: elaborado pelo autor

As Figura 17, Figura 18 e Figura 19 correspondem às nuvens de palavras das postagens de Bolsonaro.

Figura 17 – Nuvens de palavras das postagens do período P1 referente a Bolsonaro



Fonte: elaborado pelo autor

Figura 18 – Nuvens de palavras das postagens do período P2 referente a Bolsonaro



Fonte: elaborado pelo autor

Figura 19 – Nuvens de palavras das postagens do período P3 referente a Bolsonaro



Fonte: elaborado pelo autor

Analisando nas nuvens de palavras por período, observa-se que antes da eleição (P1), a nuvem de palavra de Bolsonaro apresentou as palavras “militar”, “povo”, “esquerda”, “globo”, “verdade”, o que relaciona-se com as propostas de Bolsonaro para a eleição presidencial de 2018. Bolsonaro fazia promessas de reformas no governo com discursos



Figura 21 – Nuvens de palavras das postagens do período P2 referente a Haddad



Fonte: elaborado pelo autor

Figura 22 – Nuvens de palavras das postagens do período P3 referente a Haddad



Fonte: elaborado pelo autor

Analisando nas nuvens de palavras por período, observa-se que no período antes da eleição (P1), a nuvem de palavra de Haddad apresentou as palavras “lula”, “vice”, “campanha”, “democracia”, “caminhada” e “chapa”. Essas palavras podem relaciona-se ao contexto de candidatura de Haddad a eleição, pois inicialmente Lula era o candidato

principal e Haddad era vice. Após decisão de ministro do STF, Lula perde a candidatura por inelegibilidade fazendo com que Haddad assumira a liderança da campanha. A campanha de Haddad foi marcada por essa decisão referente a Lula, tendo alguns considerado a decisão como injusta. Haddad permaneceu na mesma linha de pensamento de Lula, com projetos voltado para o povo e a favor da democracia.

Quanto o período durante a eleição (P2), a nuvem de palavras de Haddad apresentou as palavras “lula”, “democracia” e “educação”. Percebe-se que a ligação de Haddad e Lula ainda permanece. Essa relação é apresentada pela frase “Haddad é Lula”, que foi utilizada pela campanha de Haddad até o primeiro turno da eleição. Após o primeiro turno, o partido decidiu alterar algumas coisas, como o logotipo e a cor da campanha e desvinculou um pouco a imagem de Lula a Haddad.

No período após a eleição (P3), a nuvem de palavra de Haddad apresentou as palavras “lula”, “povo”, “educação”, “caminhada” e “stuckert”. Essas palavras relacionam-se à posição de Haddad após a eleição de 2018. Haddad posicionou em relação ao povo, às minorias, pedindo que a caminhada e a luta continuasse após à eleição. A palavra “stuckert” relaciona ao fotógrafo Ricardo Stuckert, que trabalha com o Partido Trabalhista (PT).

### 4.3.3 Analisando os Sentimentos das Postagens

Esta seção irá abordar a análise de sentimentos das postagens dividida em análise geral, análise por período, análise por conteúdo negativo e conteúdo positivo.

#### 4.3.3.1 Overview da Classificação de Sentimentos

Como mencionado na Subseção 3.2, a remoção de texto vazios das postagens foi apenas considerada no caso de análise envolvendo caracterização de sentimentos, o que representa essa seção do trabalho. Em outros casos de análise não justificam a remoção deste tipo de texto. Com isso, a redução do número das postagens de Bolsonaro e Haddad representaram uma perda de 11.65% e 5.3%, respectivamente, conforme a Tabela 6.

A primeira análise a ser realizada é quantificar cada valor do sentimento gerado (*score*) pelo *Sentistrength*, ou seja, quantas postagens geraram *score* igual a 2, por exemplo. O intervalo (*range*) de valores possíveis de acordo com a Tabela 3 varia entre -5 e 5, considerando todos os modos de saída. Para este trabalho considerou-se a saída *scale* que varia de -4 a 4.

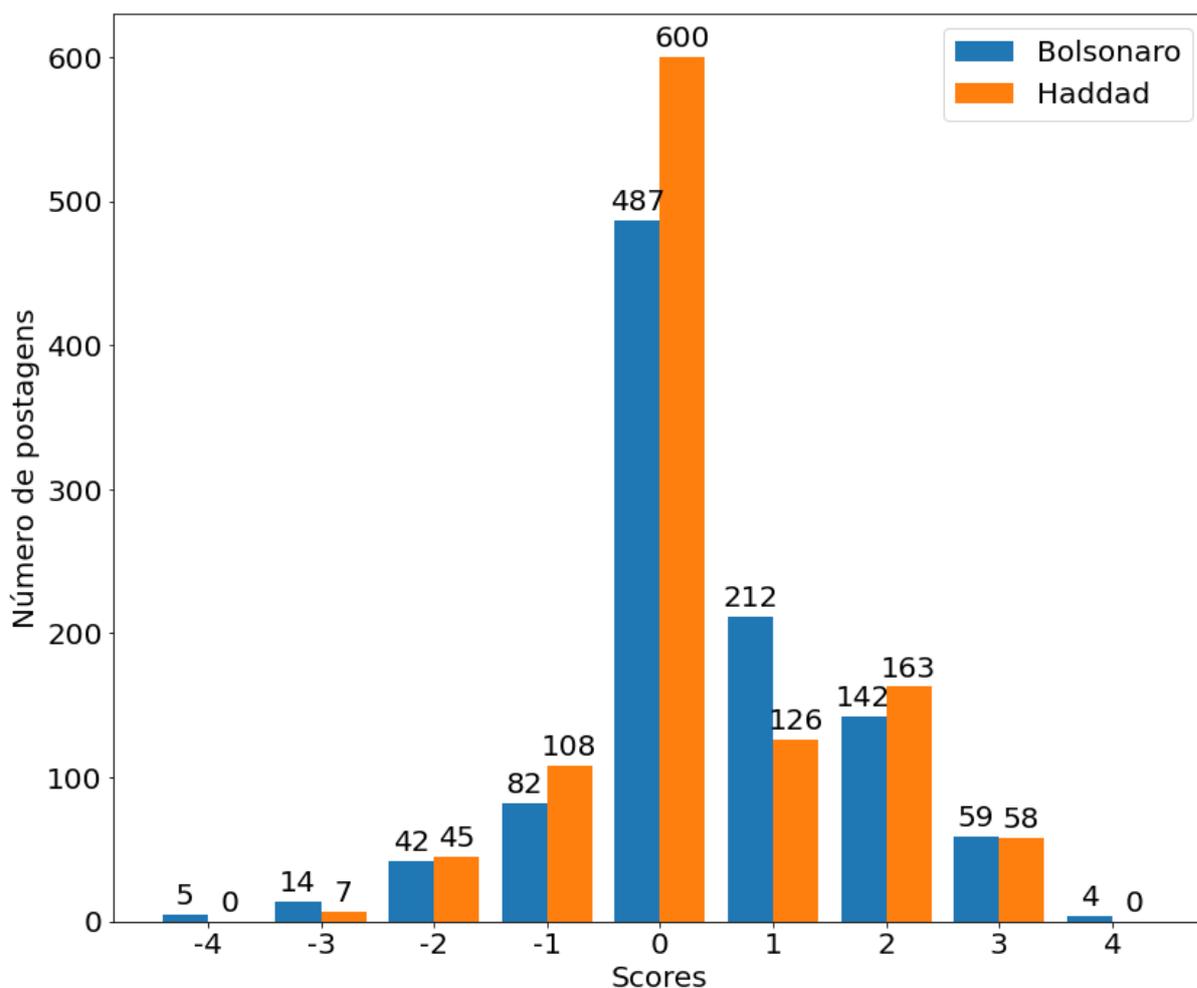
A Figura 23 resume a distribuição dos *scores* gerados. Os valores acima de cada barra representam a quantidade de postagens que geraram o respectivo *score*. Observa-se que para Bolsonaro 487 postagens resultaram em *score* igual a zero ou neutro. Analisando

a distribuição de Haddad, nota-se também o mesmo comportamento, com mais da metade de postagens com classificação neutra (600 postagens).

Outro aspecto interessante são os *scores* extremos. Bolsonaro apresentou cinco postagens com classificação de sentimentos negativa igual a -4, enquanto Haddad não apresentou nenhuma postagem. Analisando o *score* igual -3, percebe-se novamente que Bolsonaro apresentou um valor maior em comparação com Haddad, quatorze postagens negativas contra sete postagens de Haddad.

Quanto ao lado positivo, nota-se que ambos, Bolsonaro e Haddad, tiveram praticamente a mesma quantidade de postagens com classificação igual a 3, cinquenta e nove postagens de Bolsonaro contra cinquenta e oito postagens de Haddad. Quanto a classificação igual a 4, Bolsonaro apresentou quatro postagens e Haddad nenhuma postagem. Posteriormente, o conteúdo das postagens com *scores* maiores serão analisados.

Figura 23 – Gráfico da distribuição dos *scores* das postagens

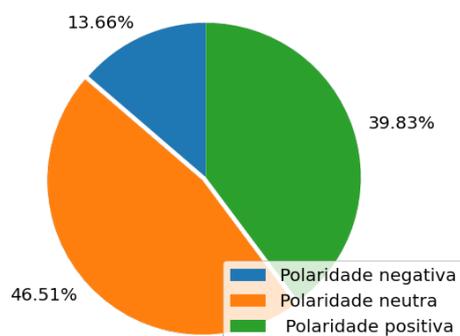


Fonte: elaborado pelo autor

A [Figura 24](#) e a [Figura 25](#) mostram um resumo dos dados anteriores, porém em

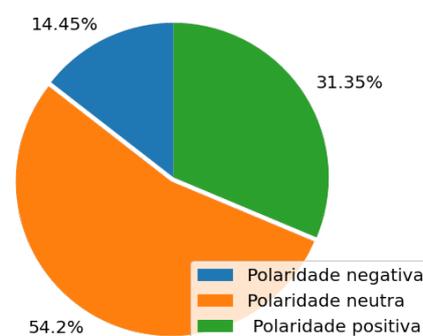
percentual de cada polaridade (negativa, neutra e positiva). Nota-se que a maioria das postagens realizadas pelo candidatos resultaram em *score* neutro, ou seja, igual a zero.

Figura 24 – Distribuição dos scores das postagens de Bolsonaro por polaridade



Fonte: elaborado pelo autor

Figura 25 – Distribuição dos scores das postagens de Haddad por polaridade



Fonte: elaborado pelo autor

#### 4.3.3.2 Analisando os Sentimentos por Período

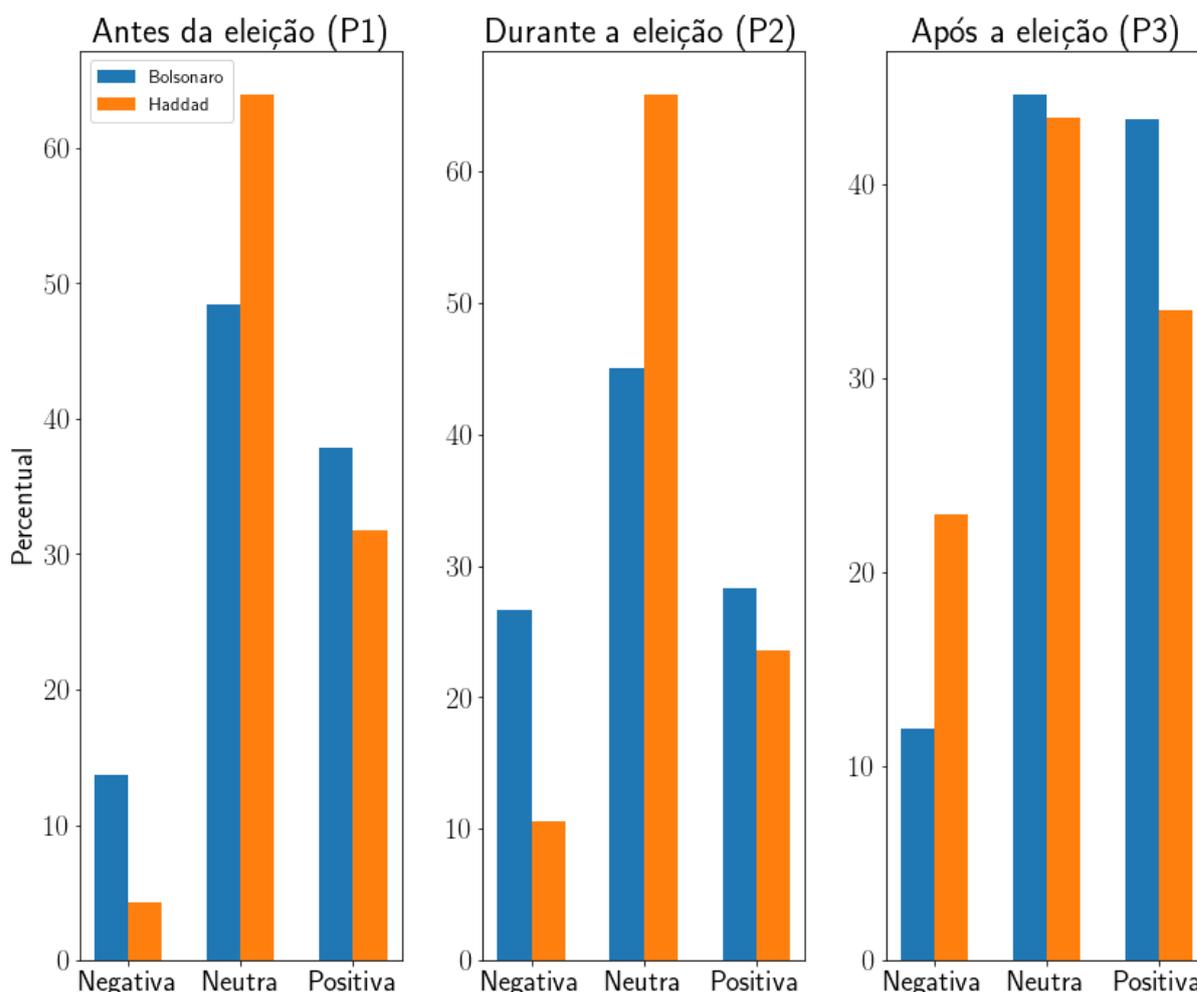
A porcentagem de cada polaridade (negativa, neutra e positiva) foi gerada de acordo com os períodos especificados na Tabela 12. Nota-se que a escala do eixo y é independente em cada período do gráfico da Figura 26.

Analisando a polaridade negativa, observa-se que Bolsonaro apresentou 13.73% das postagens como negativas no período P1 (antes da eleição), no período P2 (durante a eleição) esse valor aumentou para mais de 25% e no período P3 (após a eleição) diminuiu para 11.95%. Enquanto isso, Haddad apresentou um cenário diferente, começando com 4.31% das postagens como negativas no período P1, aumentando para 10.59% no período P2 e 23.02% no período P3.

Quanto a polaridade neutra, a variação foi quase constante para Bolsonaro, tendo uma média aproximada de 46%. Quanto a Haddad a variação é semelhante, tendo apenas uma queda após a eleição. A média de Haddad ficou aproximada em 58%.

A polaridade positiva não sofreu grandes variações. Bolsonaro apresentou 37.84% das postagens como positivas no período P1, diminuindo para pouco menos de 30% no período P2 e aumentando novamente para 43.4% no período P3. Haddad começou o período P1 com pouco mais de 30% das postagens como positivas, diminuindo para 23.53% no período P2 e aumentando para 33.52% no período P3.

Portanto, pode-se dizer que houve variações dentro desses três períodos, principalmente quando se compara os períodos P1 e P2 na polaridade negativa.

Figura 26 – Gráfico do percentual dos *scores* das mensagens por período eleitoral

Fonte: elaborado pelo autor

#### 4.3.3.3 Analisando os Conteúdos das Postagens mais Negativas

De acordo com a [Figura 23](#) Bolsonaro apresentou cinco postagens com polaridade igual a -4 e quatorze postagens com polaridade igual a -3. Haddad apresentou sete postagens com polaridade igual a -3. Nesta seção serão analisados os conteúdos destas postagens na tentativa de entender o que ocasionou essas classificações de sentimentos negativos.

Um dos principais pontos que se deve levar em consideração no uso do *Sentistrength*, ou qualquer outro programa que utiliza o método de análise por dicionários léxicos, é a não detecção de contexto e entonação no uso de determinadas palavras.

Como o *Sentistrength* utiliza dicionários de palavras pré-classificadas, o aparecimento de qualquer palavra que tenha uma polaridade negativa extrema resultará em uma classificação mais negativa para todo o texto. Por exemplo, a palavra ódio tem polaridade igual a -4. Quando essa palavra estiver inserida dentro de um texto, a classificação tenderá a ser mais negativa por mais que o texto não esteja provocando o ódio em si.

Analisando inicialmente as postagens de Haddad com polaridades iguais a -3, percebe-se que o fato mencionado anteriormente acontece algumas vezes no texto das postagens de Haddad. Algumas palavras-chaves como “ódio”, “falsa”, “mentirosa”, “retrógradas”, “Bozo”, “sofrem”, “violência” e “sofrido” apareceram nas postagens fazendo com que conseqüentemente o texto resultasse em uma polaridade mais negativa, uma vez que todas são pré-classificadas com polaridade -4 ou -3. Algumas palavras estavam sendo utilizadas no seu sentido negativo, outras apenas no sentido informativo.

Por exemplo, a palavra “violência” aparece na seguinte postagem: *“Um problema das fake news é que elas se transformam muito rapidamente em bad news: Mais da metade dos LGBT diz ter sofrido violência desde as eleições”*. Ela não está sendo utilizada para incitar a violência, mas sim em um sentido informativo sobre um ato contra as pessoas da comunidade LGBT. O conjunto de palavras anteriores por si só representam polaridade negativa, porém o contexto tem valor fundamental na interpretação de cada uma, o que dificulta a análise durante a classificação.

Nas postagens de Bolsonaro com polaridades iguais a -4, algumas palavras-chaves também auxiliaram as polaridades do texto a se tornarem mais negativas, como “corrupto”, “pobre”, “não”, “estuprador”, “preso” e “estranho”. Não é diferente das postagens com polaridades iguais a -3. Algumas das palavras-chaves como “corrupto”, “estupro”, “corrupção”, “falta”, “mentira”, “desespero”, “mal” e “bandido” também foram utilizadas e são recorrentes nos textos.

Analisando os conteúdos das postagens classificadas com polaridade negativas, percebe-se que as postagens de Bolsonaro destacam as críticas aos membros de partidos relacionados ao PT de forma geral e pautas sobre projetos de governo como a diminuição do crime, a defesa do armamento civil, a proposta de pacote anticrime e a mudança no sistema político em relação à corrupção.

Em relação às postagens de Haddad, percebe-se que em sua maioria, as postagens são relacionadas às críticas ao governo de Bolsonaro em várias frentes como educação, esporte, corrupção, saúde e social.

Portanto, comparando os conteúdos de ambos candidatos, percebe-se que as postagens negativas foram utilizadas com o objetivo de criticar as ações políticas de um em relação ao outro.

#### 4.3.3.4 Analisando os Conteúdos das Postagens mais Positivas

Ao contrário do que aconteceu na seção anterior, as palavras-chaves nas postagens mais positivas apresentam valores mais altos de polaridade positivas, auxiliando a classificação a se tornar mais positiva.

De acordo com [Figura 23](#), Bolsonaro apresentou cinquenta e nove postagens com

polaridade igual a 3 e Haddad apresentou cinquenta e oito postagens. Na polaridade igual a 4, apenas Bolsonaro apresentou quatro postagens. O mesmo comportamento apresentado nas postagens de polaridade igual a 4 mostrou-se similar nas postagens de polaridade igual a 3.

Algumas palavras mais recorrentes de maior polaridade positiva que apareceram nas postagens foram “talentosa”, “sucesso”, “deus”, “talento”, “alegrar”, “querido”, “emoção” e “salvar”. Uma vantagem em comparação com palavras de polaridades negativas é que as palavras de polaridade positiva aparecem mais em textos que remetem positividade.

Quanto aos conteúdos das postagens positivas, as postagens de Bolsonaro relacionam-se em sua maioria aos apoios recebidos de seus seguidores e de pessoas famosas. Há também postagens relacionadas a projetos realizados no seu governo nos campos da economia, saúde e social.

Em relação a Haddad, suas postagens são relacionadas aos apoios recebidos de seus seguidores, entrevistas realizadas na TV com apoiadores da mesmas ideias e mensagens de apoio ao povo brasileiro.

## 4.4 Avaliando os Comentários das Postagens

Nesta seção será realizada a análise dos comentários das postagens quanto aos conteúdos e os sentimentos gerados.

### 4.4.1 Conteúdo dos Comentários das Postagens

Como descrito na Subseção 4.3.2, a análise dos comentários iniciará verificando quais palavras foram mais utilizadas nos comentários das postagens de Bolsonaro e Haddad utilizando de nuvens de palavras de acordo com os períodos da Tabela 12. Na subseção seguinte, a análise será a classificação dos sentimentos dos comentários gerados pelo *Sentistrength*. Essa parte do trabalho analisa o comportamento dos seguidores (*followers*) dos candidatos, o qual é reflexo do impacto das postagens dos mesmos.

As Figura 27, Figura 28 e Figura 29 correspondem às nuvens de palavras dos comentários de Bolsonaro.



Figura 29 – Nuvens de palavras dos comentários do período P3 referente a Bolsonaro



Fonte: elaborado pelo autor

Analisando os conteúdos dos comentários relacionados ao Bolsonaro, observa-se que seus apoiadores o tratam como “capitão”, “mito”, “senhor” e “presidente”. É possível ver uma relação com apoiadores religiosos através de palavras como “deus” e “abênção”, dando indícios de como é formada a base dos seus apoiadores. Há também uma relação com as propostas de seu governo de mudar o sistema político e o país através das palavras “país”, “brasil” e “família”. Nota-se também uma relação com os opositores do governo através das palavras “pt” e “haddad”.

As Figura 30, Figura 31 e Figura 32 correspondem às nuvens de palavras dos comentários de Haddad.

Figura 30 – Nuvens de palavras dos comentários do período P1 referente a Haddad



Fonte: elaborado pelo autor

Figura 31 – Nuvens de palavras dos comentários do período P2 referente a Haddad



Fonte: elaborado pelo autor



número de comentários. Por isso, a primeira análise será considerando a média aritmética<sup>1</sup> dos *scores* de todos os comentários relacionados a uma postagem. Ou seja, soma-se todos os valores dos *scores* dos comentários de uma postagem e divide-se pelo número de comentários. A [Figura 33](#) mostra a distribuição das médias de Bolsonaro e Haddad.

A [Tabela 13](#) mostra os valores do desvio padrão e o erro padrão da média dos comentários de Haddad e Bolsonaro. Esses valores permitem entender como os valores dos sentimentos gerados (*scores*) estão distribuídos no conjunto de dados e adicionalmente explicarão quão bem a média dos sentimentos dos comentários explicará a respectiva postagem.

Percebe-se que Bolsonaro apresenta desvio padrão um pouco maior em relação a Haddad, mostrando uma maior dispersão de sentimentos em relação a Haddad. Quanto aos erros, nota-se que os valores ficaram bem baixos indicando uma boa confiabilidade em relação à média do conjunto de dados. Os intervalos de confiança mostram 95% de probabilidade da média estar entre os intervalos encontrados com um nível de significância de 5%. Portanto, a média expressará bem o comportamento dos sentimentos dos comentários gerados.

Tabela 13 – Desvio padrão e erro padrão em relação à média dos comentários

	Desvio padrão	Erro padrão	Intervalo de Confiança (95%)
<b>Bolsonaro</b>	1.257	0.00053	(-2.06, 2.87)
<b>Haddad</b>	1.173	0.00077	(-2.29, 2.31)

Fonte: elaborado pelo autor

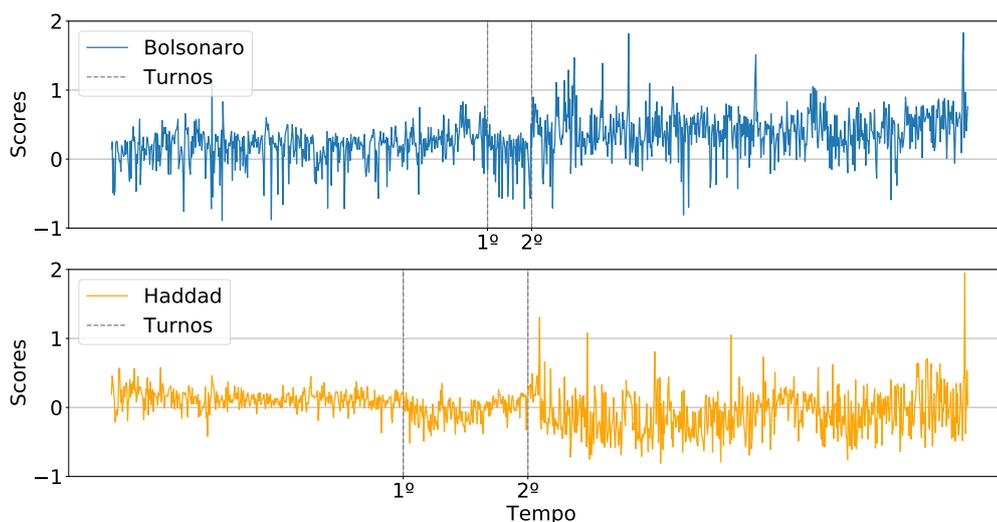
As linhas verticais na [Figura 33](#) indicam o primeiro e segundo turno da eleição presidencial, 07 de Outubro de 2018 e 28 de Outubro de 2018, respectivamente. Essas linhas limitam os períodos apresentados na [Tabela 12](#). Aparentemente o “espaço” entre elas estão diferentes devido Haddad ter realizado mais postagens entre os dois turnos da eleição do que Bolsonaro. Cada pico (tanto positivo quanto negativo) representa a média dos *scores* dos comentários de cada postagem.

Há alguns pontos interessantes a se observar nos gráficos. O intervalo dos valores dos *scores* ficou entre -1 e 2. Em relação a Bolsonaro, nota-se que antes da eleição (P1), os comentários nas postagens apresentaram vários picos com valores negativos. Entre os turnos da eleição (P2), esse comportamento se manteve também com vários valores negativos. Após a eleição (P3), Bolsonaro apresentou ainda valores negativos porém com a maioria dos *scores* sendo positivos.

<sup>1</sup> Média:  $\frac{\text{soma de todos os valores}}{\text{quantidade de valores}}$

Em relação a Haddad, percebe-se que antes da eleição (P1), os valores ficaram entre 0 e +0.5 sem grandes picos em destaque. Durante a eleição (P2), o gráfico sofre um declínio apresentando mais valores negativos neste período. Quando termina o segundo turno da eleição (P3), a variação dos valores dos *scores* aumenta, apresentando em sua maioria muitos picos negativos.

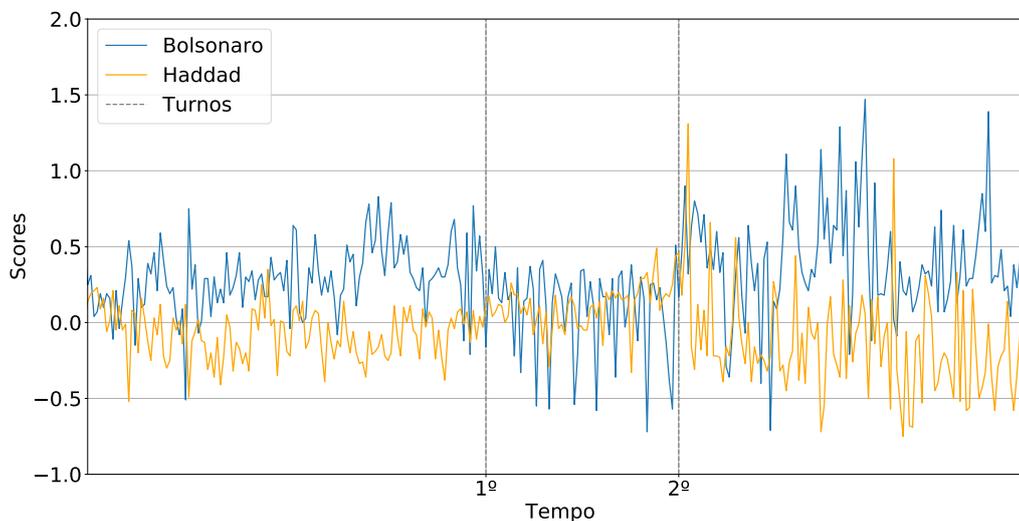
Figura 33 – Média dos *scores* dos comentários de cada postagem



Fonte: elaborado pelo autor

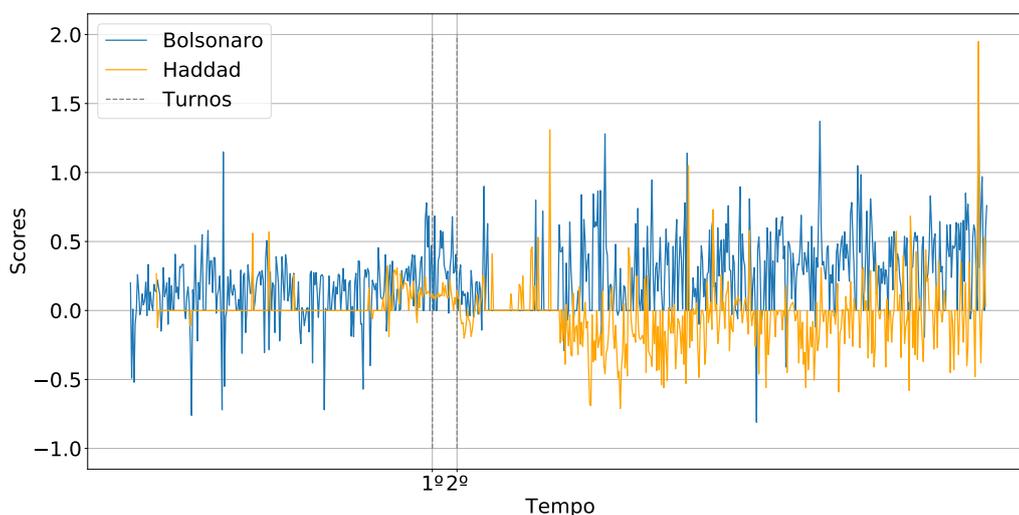
Com isso, percebe-se a diferença dos valores de cada candidato. Como mencionado anteriormente, após a eleição (P3) é possível notar que o gráfico de Bolsonaro fica mais orientado para o lado superior positivo enquanto o gráfico de Haddad fica mais orientado para o lado inferior negativo. Os dois gráficos praticamente se divergem após o período P3. Durante a eleição o comportamento também se repete, apresentando gráficos opostos. Antes da eleição (P1), ambos gráficos se sobrepõem com Bolsonaro apresentando maiores variações dos valores.

O gráfico da [Figura 34](#) é um recorte da sobreposição dos dois gráficos da [Figura 33](#) mostrando em destaque o período de transição entre os turnos da eleição. O período do gráfico está compreendido entre 1º de Agosto de 2018 e 31 de Janeiro de 2019.

Figura 34 – Recorte no intervalo de tempo das médias dos *scores* dos comentários de cada postagem

Fonte: elaborado pelo autor

Outra análise foi verificar a média diária a partir da média dos comentários de cada postagem. Ou seja, a partir da média de cada postagem, realizou-se a soma de todas as médias em um dia e dividiu-se pelo total de postagens neste dia. Pela Figura 35 percebe-se que o comportamento permanece semelhante aos gráficos Figura 33. A oposição dos gráficos de Bolsonaro e Haddad após a eleição (P3) aparece novamente.

Figura 35 – Média diária a partir da média dos *scores* dos comentários de cada postagem

Fonte: elaborado pelo autor

Outra abordagem utilizada durante a análise das médias dos comentários foi através de mapa de calor (*heatmap*). Esse tipo de visualização gráfica permite visualizar densidade de valores de acordo com uma escala métrica estabelecida.

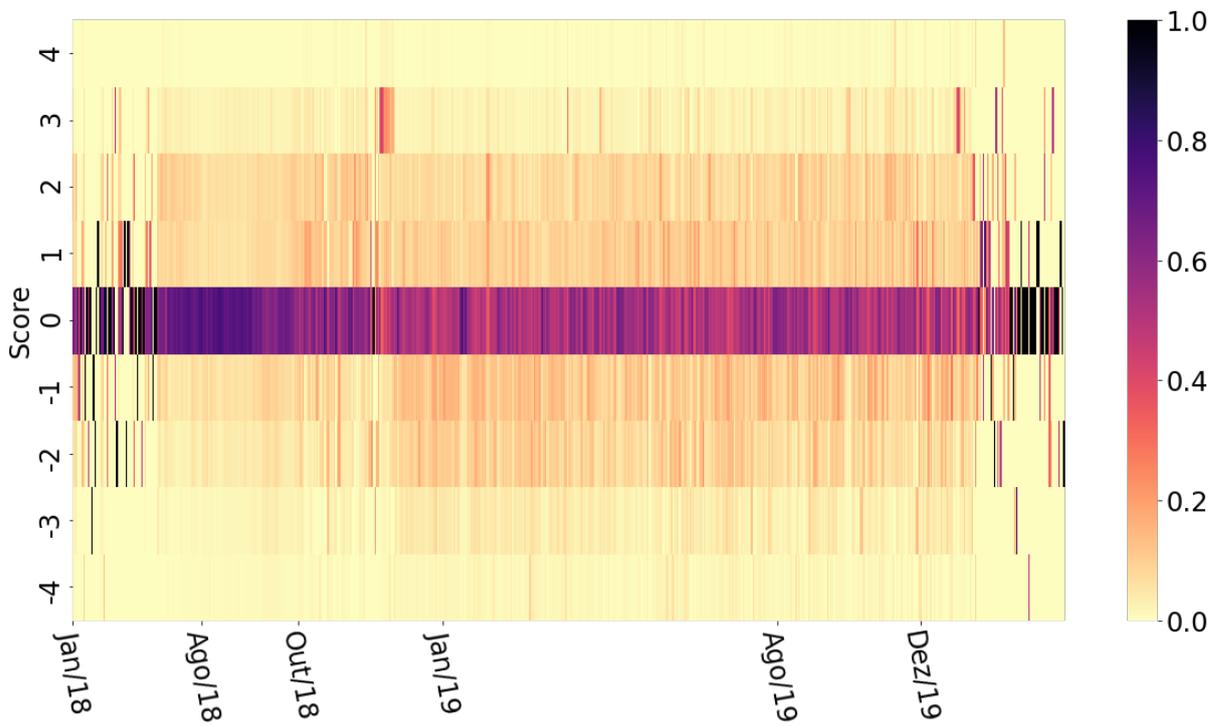
O mapa de calor apresenta uma escala variando de 0 a 1, a qual indica o percentual de cada sentimento (*score*) por dia com 0 indicando 0% e 1 indicando 100%. Por exemplo, em um dia quantos por cento (%) dos comentários foram classificados com 4, quantos por cento dos comentários foram classificados com 3, quantos por cento dos comentários foram classificados com 2 e assim por diante. A escala dos sentimentos variam de -4 a 4 de acordo com a saída *scale* do *SentiStrength*.

A [Figura 36](#) mostra o mapa de calor dos comentários relacionados ao Haddad. Observa-se uma grande concentração de comentários classificados com sentimentos neutros (iguais a 0). Nota-se também que a partir do mês de Janeiro/2019, os percentuais das polaridades negativas começaram a aumentar, tendo assim um maior percentual de representatividade nos comentários. No mês de Dezembro/2019, nota-se que essas concentrações de comentários negativos aumentam um pouco mais, apresentando cores mais escuras nos sentimentos classificados com -1, -2 e -3.

A [Figura 37](#) mostra o mapa de calor dos comentários relacionados ao Bolsonaro. Novamente, observa-se uma grande concentração de comentários classificados com sentimentos neutros (iguais a 0). Diferentemente do mapa de calor de Haddad, o mapa de calor de Bolsonaro apresenta percentuais maiores em relação aos sentimentos positivos classificados com 1, 2 e 3, principalmente após o mês de Janeiro/2019.

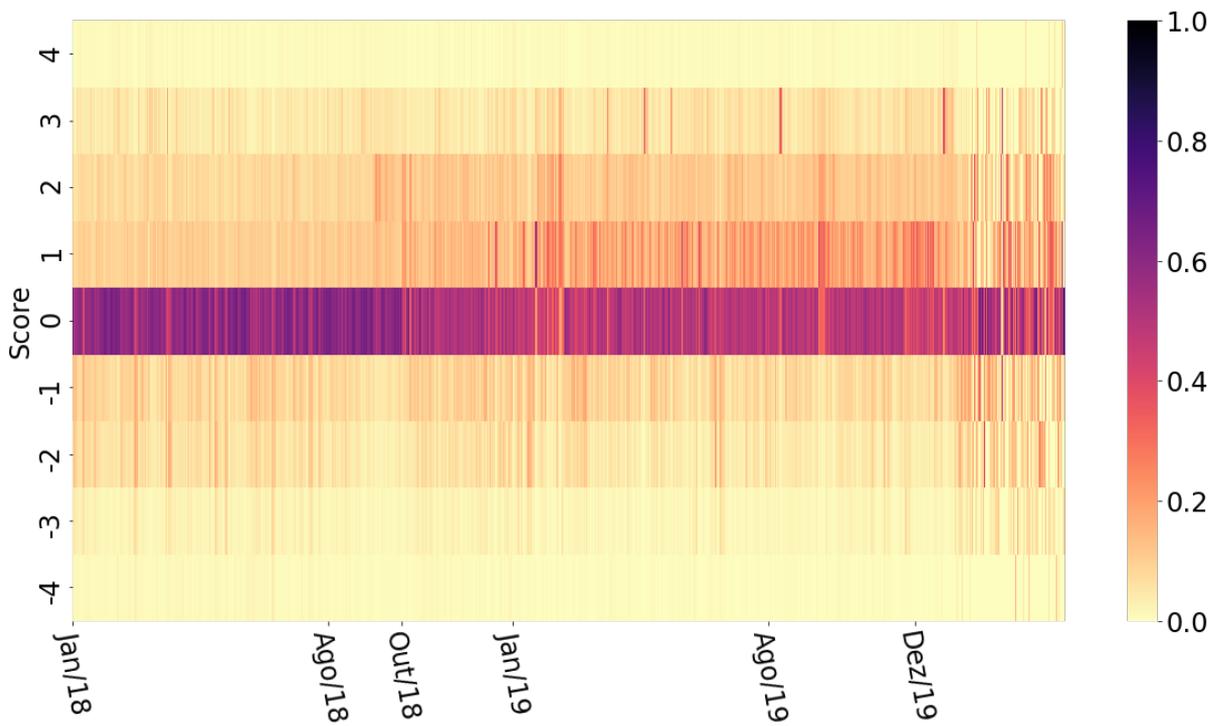
Essa análise evidencia a negatividade nos comentários das postagens de Haddad após a eleição diante do aumento das críticas de Haddad ao governo Bolsonaro em suas postagens ao longo do ano de 2019. Em contraponto, há um aumento da positividade nos comentários em relação a Bolsonaro ao longo do ano de 2019.

Figura 36 – Mapa de calor (*heatmap*) dos comentários relacionados a Haddad



Fonte: elaborado pelo autor

Figura 37 – Mapa de calor (*heatmap*) dos comentários relacionados a Bolsonaro

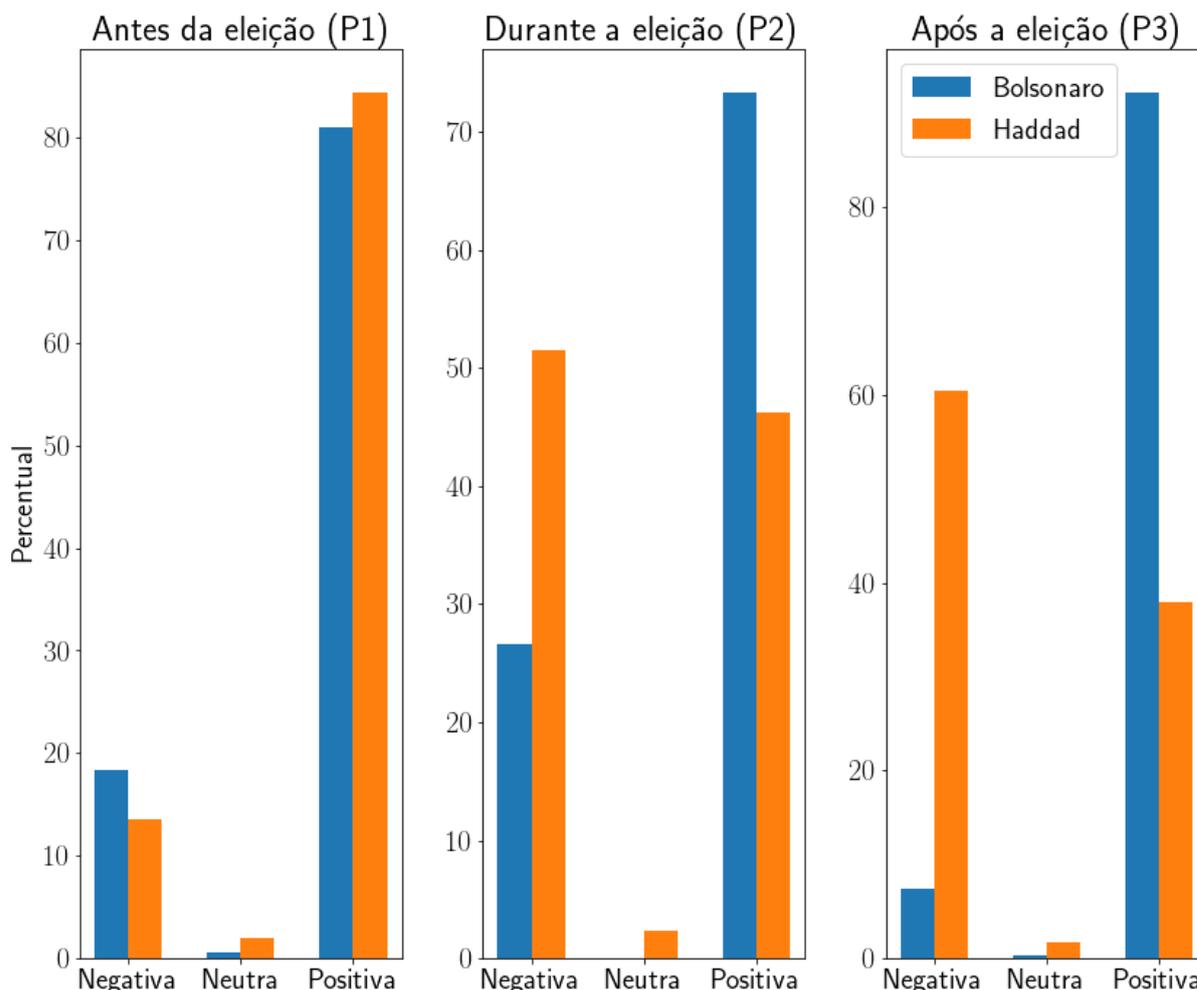


Fonte: elaborado pelo autor

O gráfico da [Figura 38](#) exibe o percentual da média dos *scores* dos comentários por período. Vale ressaltar que mesmo se a média fosse bem próxima de zero, por exemplo 0.001, ela ainda seria avaliada como maior ou menor que zero. Neste caso, 0.001 seria classificada como positiva. No caso contrário, por exemplo, -0.001 seria classificada como negativa.

Primeiro, observa-se que a polaridade neutra é bem baixa enquanto a polaridade positiva apresenta percentuais bem maiores. Analisando por período, o maior percentual entre ambos é da polaridade positiva.

Quanto a polaridade negativa, nota-se que Bolsonaro começou com pouco menos que 20% da média de *scores* dos comentários sendo negativos no período P1, depois aumentou para 26.67% no período P2 e em P3 caiu para 7.48%. Haddad apresentou um comportamento diferente, iniciando o período P1 com 13.57% de média de *scores* dos comentários negativos, no período P2 aumentou para 51.45% e em P3 aumentou para 60.37%. Isso mostra um aumento da média de Haddad contra uma diminuição de Bolsonaro.

Figura 38 – Percentual da média dos *scores* dos comentários por período eleitoral

Fonte: elaborado pelo autor

Pode-se dizer que houve uma mudança no cenário entre o período antes da eleição (P1) e após a eleição (P3) levando em conta a média dos *scores* dos comentários. Na próxima seção outra abordagem será apresentada, desta vez utilizando a moda em vez da média aritmética.

#### 4.4.2.2 Utilizando a moda dos *scores*

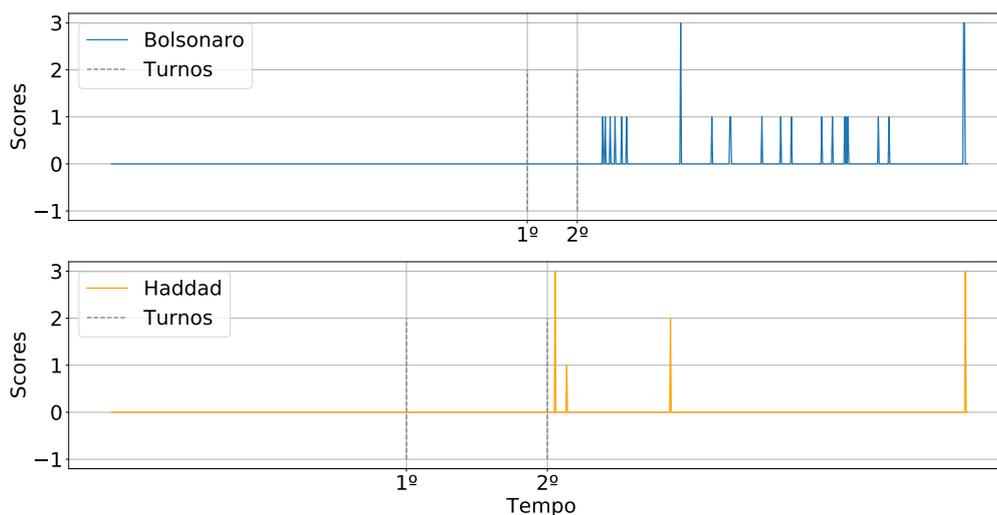
Nessa abordagem será empregado o conceito de moda<sup>2</sup> em vez de média aritmética. Ou seja, dentre todos os *scores* dos comentários de uma postagem, o mais frequente representará a postagem correspondente. O objetivo é comparar os resultados entre a média aritmética e a moda e analisar o comportamento de cada uma.

Considerando todos os sentimentos gerados pelos comentários, ou seja, tanto sentimentos negativos, positivos e neutros, é possível observar pela [Figura 39](#) que a grande

<sup>2</sup> Moda: o valor mais frequente em um conjunto de dados.

maioria dos sentimentos em ambos os gráficos apresentaram o zero como o valor com maior frequência. Por isso, os gráficos apresentaram uma linha reta no valor zero. Os picos presentes no gráfico representaram a moda com valores diferentes de zero e positivos. Portanto, o percentual é de praticamente 100% na polaridade neutra.

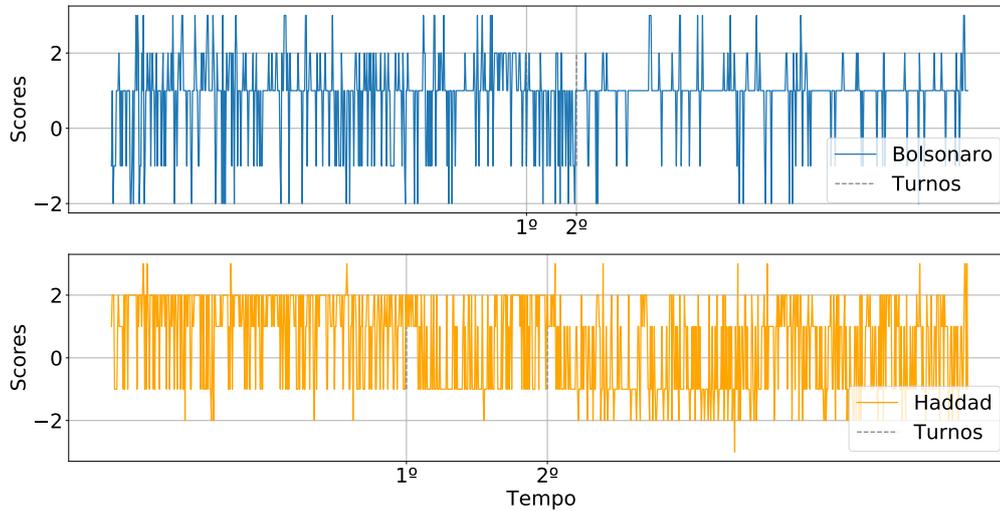
Figura 39 – Moda dos *scores* dos comentários de cada postagem



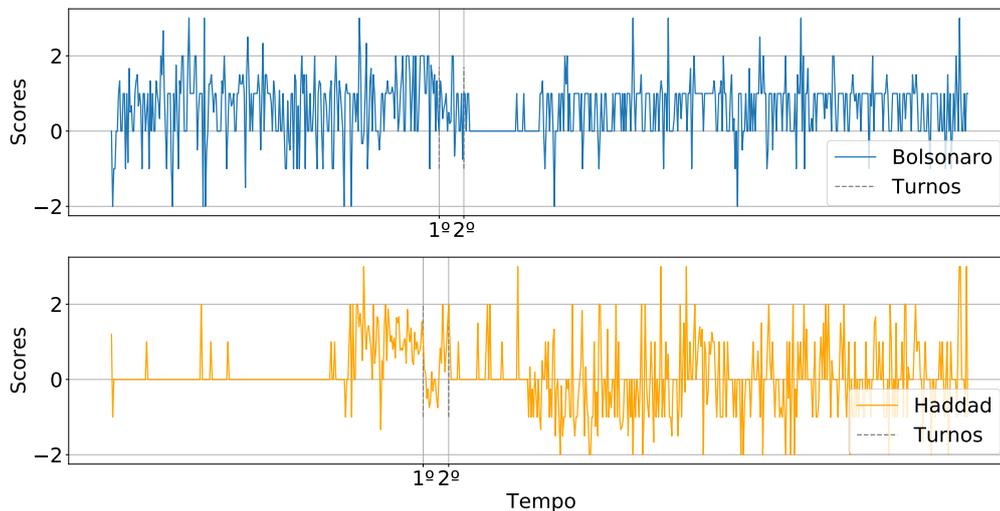
Fonte: elaborado pelo autor

Desconsiderando os sentimentos neutros dos comentários, é possível observar pela [Figura 40](#) que a partir do primeiro turno da eleição, início do período P2, a moda dos comentários relacionados ao Haddad apresentaram tendência mais negativa em relação a Bolsonaro no mesmo período. Após o segundo turno da eleição, início do período P3, essa tendência fica mais evidente.

Analisando a moda diária, ou seja, o sentimento (*score*) mais frequente entre os comentários diários, é possível observar pela [Figura 41](#) que após a eleição no período P3, a moda dos comentários de Bolsonaro apresentaram em sua maioria sentimentos positivos. Por outro lado, a moda dos comentários de Haddad, no mesmo período, apresentaram sentimentos positivos e negativos, sendo os sentimentos negativos mais frequentes.

Figura 40 – Moda dos *scores* dos comentários de cada postagem desconsiderando os sentimentos neutros

Fonte: elaborado pelo autor

Figura 41 – Moda diária dos *scores* dos comentários de cada postagem desconsiderando os sentimentos neutros

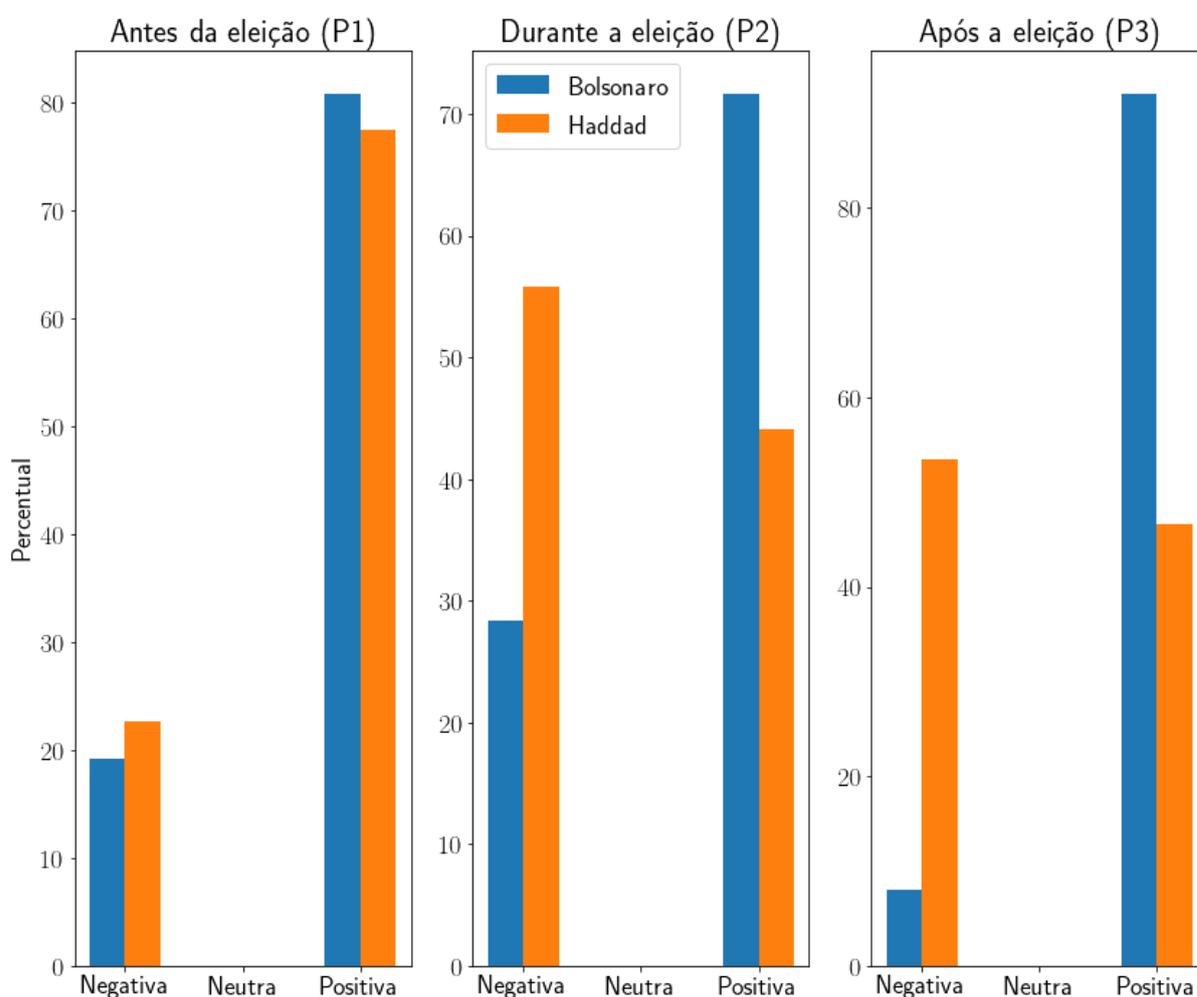
Fonte: elaborado pelo autor

Quanto aos percentuais da moda dos comentários divididos por período apresentados na [Figura 42](#), nota-se a evidência do aumento da representatividade negativa dos comentários de Haddad. Os percentuais negativos em relação Haddad aumentaram ao longo dos períodos, com 22.59% no período P1, indo para 55.88% no período P2 e estabelecendo

em 53.41% no período P3. Os percentuais positivos, por outro lado, sofreram uma queda ao longo dos períodos, iniciando com 77.41% no período P1, indo para 44.12% no período P2 e finalizando com 46.59% no período P3.

O cenário é oposto em relação a Bolsonaro. Os percentuais apresentaram uma queda em relação aos negativos e um aumento em relação aos positivos. Bolsonaro apresentou 19.22% dos comentários classificados como negativos no período P1, indo para 28.33% no período P2 e caindo para 7.97% no período P3. Os percentuais positivos iniciaram com 80.78% no período P1, indo para 71.67% no período P2 e finalizando com 92.03% no período P3.

Figura 42 – Percentual da moda dos *scores* dos comentários por período eleitoral desconsiderando os sentimentos neutros



Fonte: elaborado pelo autor

Portanto, tanto a média aritmética quanto a moda apresentaram perspectivas diferentes da análise de sentimentos para o mesmo conjunto de dados mas com o mesmo resultado. Um aumento na negatividade e uma diminuição na positividade dos comentários

relacionados a Haddad, principalmente após a eleição e uma queda da negatividade e um aumento da positividade dos comentários relacionados a Bolsonaro.

## 5 Resultados

Neste capítulo, são apresentados os resultados obtidos durante o desenvolvimento do trabalho. Estes foram obtidos através das análises realizadas no conjunto de dados.

### 5.1 Validação do *SentiStrength*

Diante da proposta de validação da Subseção 3.3.2, os resultados podem ser conferidos na Tabela 14. Durante a validação foram utilizados três conjuntos de termos para a classificação de sentimentos do conjunto de dados amostral.

O conjunto original é o conjunto de termos em português fornecido pelo próprio responsável pela ferramenta *SentiStrength*. Porém, esse conjunto apresenta uma quantidade reduzida de termos ao ser comparado com o conjunto de termos em inglês, logo sua utilização direta acarretaria em uma abrangência reduzida durante as classificações.

O conjunto aumentado é o conjunto original aumentado com termos traduzidos do conjunto em inglês, termos no plural e termos no feminino.

O conjunto atualizado é o conjunto aumentado com a adição de termos relacionados aos candidatos Jair Bolsonaro e Fernando Haddad com acentuação removida. Exemplos desses termos foram apresentados na Tabela 4.

Os dois últimos conjuntos de termos, o conjunto aumentado e o conjunto atualizado foram disponibilizados por Silva e Barbosa (2019). Neste trabalho, os autores utilizaram esse mesmo conjunto de termos com o objetivo de avaliar a aceitação dos candidatos à presidência do Brasil nas eleições de 2018, Fernando Haddad e Jair Messias Bolsonaro, por meio da análise de comentários feitos por usuários do *YouTube*.

Diante da dificuldade de obter uma base de dados rotulada com sentimentos relacionados aos candidatos para a utilização de métodos de aprendizado de máquina, os autores utilizaram a estratégia de rotulação dos termos por meio da média aritmética das classificações de voluntários e respeitando o padrão do conjunto original.

Tabela 14 – Performance da análise de sentimentos

Conjunto	Precisão	Revocação	Acurácia	<i>F1-Score</i>
Original	0.586	0.276	0.628	0.291
Aumentado	0.860	0.630	0.768	0.675
Atualizado	0.912	0.874	0.862	0.890

Fonte: elaborado pelo autor

Os resultados obtidos na validação apresentada na [Tabela 14](#) mostram que o conjunto atualizado apresentou as melhores métricas de desempenho, sendo este o conjunto utilizado neste trabalho. Comparado com o conjunto original, o conjunto atualizado apresentou um aumento considerável na métrica *F1-Score*.

## 5.2 Análise de Sentimentos

A análise de sentimentos foi constituída por duas abordagens: a análise das mensagens das postagens e a análise dos comentários das postagens.

### 5.2.1 Classificação das Postagens

A classificação de sentimentos foi realizada em duas etapas: a primeira aplicada às postagens e a segunda aplicada aos comentários.

Quanto às postagens, a distribuição dos *scores* resultou, em sua maioria, em polaridade neutra - *score* igual a 0 ([Figura 23](#)). Para Bolsonaro, as postagens neutras representaram 46.51% e para Haddad 54.2%. Nas postagens negativas, os percentuais de Bolsonaro e Haddad representaram, 13.66% e 14.55%, respectivamente. Quanto às postagens positivas, Bolsonaro apresentou 39.83% e Haddad apresentou 31.35%.

Além da prevalência da polaridade neutra, é possível observar que houve postagens classificadas com polaridades negativas e polaridades positivas, observando que algumas postagens foram classificadas com *scores* extremos, por exemplo, postagens com polaridades negativas de -3 e -4, indicando que são extremamente negativas. É válido também para as polaridades positivas, onde postagens apresentaram polaridades positivas de 3 e 4, indicando que são extremamente positivas.

O que se pôde observar avaliando os conteúdos das postagens classificadas com polaridade negativas e positivas foi a presença de palavras-chaves (*keywords*), tanto negativas como “ódio”, “falsa”, “mentirosa” e “Bozo” e positivas como “talentosa”, “sucesso”, “talento” e “querido”. Essas palavras-chaves apresentavam nos dicionários léxicos utilizados pelo classificador *Sentistrength scores* com valores mais extremos. Isso influenciava diretamente na classificação do texto, uma vez que algumas palavras não estavam sendo utilizadas no sentido negativo.

Quanto aos conteúdos das postagens classificadas com sentimentos negativos, foi possível perceber que tanto Bolsonaro quanto Haddad faziam uso de críticas para insultar o outro em assuntos políticos voltados para a educação, corrupção, saúde e social. Quanto aos conteúdos das postagens classificadas com sentimentos positivos, notou-se que a maioria continham assuntos relacionados aos apoiadores de cada candidato.

Quando a análise de sentimentos foi dividida por períodos ([Subseção 4.3.3.2](#)),

observa-se que a representatividade das polaridades apresentam uma nova perspectiva do conjunto como um todo. A [Tabela 15](#) mostra os percentuais de cada polaridade dentro de cada período. É possível notar que Bolsonaro apresentou um maior percentual de postagens classificadas como negativas durante a eleição (P2), 26.67%. Haddad, por outro lado, apresentou um crescimento nos valores de percentuais das postagens classificadas como negativas, indo de 4.31% a 23.02% após a eleição (P3). Os percentuais das polaridades neutra e positiva variaram pouco em relação aos períodos mencionados.

Analisando os conteúdos das postagens negativas de Haddad no período após a eleição (P3), nota-se a predominância de críticas diretas ao governo Bolsonaro, o que poderia explicar esse aumento de negatividade nas postagens após a eleição.

Um fator adicional a esse problema é o fato do classificador *Sentistrength* classificar o texto pela ocorrência dos termos presentes no dicionário, sem levar em consideração o contexto que a palavra está inserida. Esse é um dos desafios que a análise de sentimentos enfrenta somado à complexidade sintática e semântica do português.

Tabela 15 – Percentual dos *scores* das mensagens por período eleitoral

Período	Bolsonaro			Haddad		
	Negativa	Neutra	Positiva	Negativa	Neutra	Positiva
Antes da eleição (P1)	13.73%	48.43%	37.84%	4.31%	63.96%	31.73%
Durante a eleição (P2)	26.67% (↑)	45.0%	28.33% (↓)	10.59% (↑)	65.88%	23.53% (↓)
Após a eleição (P3)	11.95% (↓)	44.65%	43.4% (↑)	23.02% (↑)	43.46%	33.52% (↑)

Fonte: elaborado pelo autor

## 5.2.2 Classificação dos Comentários

No caso dos comentários, a análise envolveu utilizar alguma métrica que resumisse todos os *scores* dos comentários, a fim de expressar a polaridade da postagem relacionada a eles. Foram utilizados dois métodos estatísticos, a média aritmética e a moda, para sintetizar todos os comentários em um *score* representativo da postagem.

A média aritmética mostrou que antes da eleição (P1) tanto Bolsonaro quanto Haddad tinham comportamentos similares, com uma proporção de classificação balanceada em polaridades negativas e positivas. Bolsonaro apresentou mais postagens com polaridades negativas mais altas do que Haddad neste período.

O cenário muda a partir do período durante a eleição (P2), onde ambos começam a divergir na classificação das polaridades. Bolsonaro começa a apresentar polaridades mais positivas e Haddad polaridades mais negativas. A [Figura 45](#) mostra as polaridades de cada postagem a partir da média de seus respectivos comentários. O comportamento de oposição entre as polaridades de Bolsonaro e Haddad após o período P3 permanece

também caso a média diária das postagens seja analisada.

Percebe-se que pelo recorte apresentado na [Figura 34](#), no período P2 Bolsonaro apresenta médias mais negativas do que Haddad. Após o início do período P3, o comportamento muda, com Haddad apresentando médias mais negativas do que Bolsonaro.

Na tentativa de entender o porquê do comportamento da oposição de polaridades entre Bolsonaro e Haddad após a eleição (P3), comentários aleatórios foram selecionados e analisados quanto aos seus conteúdos. Mesmo sem confirmar a quantificação de comentários que realmente vieram dos apoiadores de Bolsonaro, foi possível perceber um forte indício de que a negatividade nos comentários do perfil de Haddad vieram dos apoiadores de Bolsonaro.

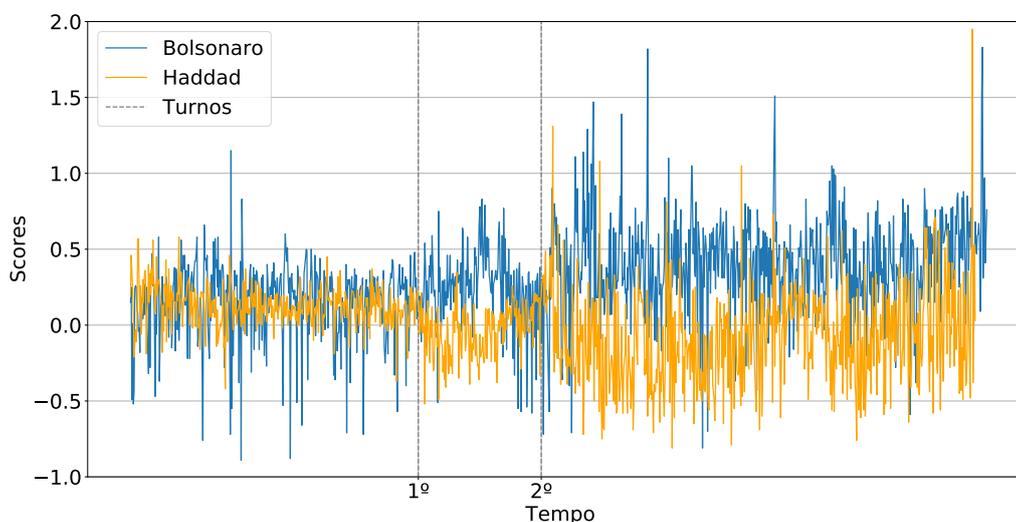
Alguns exemplos dos comentários reais que foram encontrados no perfil de Haddad: *“A inveja é uma me#%\$ de a gangue petista não tá no poder”, “Vai se fu#\$# infeliz. Tu quando era prefeito de são Paulo nomeava gente sem experiência”, “Gente. Estamos a 55 dias sem ver o Haddad e a canalha da vice dele”, “BURRO DO LULA BURRO DO LULA”, “Experiência, tem vocês do PT, roubam que é uma beleza, tem até doutorado nesse quesito”, “Esse fantoche do Lula só fala bos#% kkkk piada pronta”, “Lula e um ladrao rapaz, para c essa história de preso político.”*. Estes comentários mostram o indício mencionado anteriormente que poderiam justificar a tendência das médias das postagens de Haddad serem mais negativas após a eleição (P3) em relação a Bolsonaro.

Uma possível explicação do aumento da negatividade relacionada ao Haddad após a eleição pode estar relacionado à predominância de críticas ao governo de Bolsonaro identificadas nas postagens de Haddad após a eleição. Os indícios de comentários provenientes de seguidores de Bolsonaro na base de dados de Haddad explicariam o aumento do percentual negativo de Haddad, uma vez que os seguidores de Bolsonaro estariam insultando Haddad por tais postagens.

As nuvens de palavras das [Figura 43](#) e [Figura 44](#) representam respectivamente, os comentários negativos de postagens negativas e os comentários negativos de postagens positivas. Percebe-se que em ambas nuvens de palavras a presença de palavras de insultos é grande, ou seja, tanto em postagens classificadas como positivas ou negativas ocorreram o uso de várias palavras negativas, as quais são utilizadas em contexto de insultos. Palavras recorrentes como “idiota”, “me#%\$”, “babaca”, “vagabundo”, “burro” e “lixo” apareceram em ambas nuvens de palavras.

Essa análise reforça o aumento da negatividade nos comentários de Haddad, que mesmo em postagens classificadas como negativas, onde foi identificado uma predominância de críticas ao governo de Bolsonaro, há também a presença de negatividade em postagens classificadas como positivas.



Figura 45 – Média dos *scores* dos comentários de cada postagem

Fonte: elaborado pelo autor

Os percentuais da média de cada polaridade de acordo com cada período de acordo com a [Tabela 16](#) reforço a negatividade presente nos comentários de Haddad após a eleição. Assim, foi possível perceber a diferença de valores entre Bolsonaro e Haddad nos períodos P2 e P3 referente às polaridades positivas e negativas. Na polaridade negativa, Bolsonaro apresentou uma queda de 19.19% do período P2 para o período P3 enquanto Haddad apresentou um aumento de 8.92% no mesmo período. Na polaridade positiva o cenário foi oposto. Bolsonaro apresentou um aumento de 18.86% do período P2 para o período P3 e Haddad uma queda de 8.28% no mesmo período.

Tabela 16 – Percentual da média dos *scores* dos comentários por período eleitoral

Período	Bolsonaro			Haddad		
	Negativa	Neutra	Positiva	Negativa	Neutra	Positiva
Antes da eleição (P1)	18.36%	0.57%	81.07%	13.57%	2.01%	84.42%
Durante a eleição (P2)	26.67% (↑)	0.0%	73.33% (↓)	51.45% (↑)	2.31%	46.24% (↓)
Após a eleição (P3)	7.48% (↓)	0.33%	92.19% (↑)	60.37% (↑)	1.67%	37.96% (↓)

Fonte: elaborado pelo autor

A moda, que retorna o valor com maior frequência em um conjunto de dados, mostrou-se o mesmo cenário da média aritmética quando a análise leva em consideração a remoção dos comentários classificados como neutros. Pela [Tabela 17](#), percebe-se a diferença entre Bolsonaro e Haddad nos sentimentos negativos. No período após a eleição (P3),

Bolsonaro apresentou 7.97% dos comentários como negativos enquanto Haddad apresentou 53.41% comentários como negativos.

Tabela 17 – Percentual da moda dos *scores* dos comentários por período desconsiderando sentimentos neutros

Período	Bolsonaro			Haddad		
	Negativa	Neutra	Positiva	Negativa	Neutra	Positiva
Antes da eleição (P1)	19.22%	0.00%	80.78%	22.59%	0.00%	77.41%
Durante a eleição (P2)	28.33% (↑)	0.00%	71.67% (↓)	55.88% (↑)	0.00%	44.12% (↓)
Após a eleição (P3)	7.97% (↓)	0.00%	92.03% (↑)	53.41% (↓)	0.00%	46.59% (↑)

Fonte: elaborado pelo autor

Logo, tanto a média aritmética quanto a moda apresentaram perspectivas diferentes da análise de sentimentos para o mesmo conjunto de dados mas com o mesmo resultado. Um aumento na negatividade e uma diminuição na positividade dos comentários relacionados a Haddad, principalmente após a eleição. Enquanto Bolsonaro apresentou, no mesmo período, uma queda da negatividade e um aumento da positividade dos comentários.

## 6 Considerações Finais

Este trabalho apresentou um estudo para identificar e comparar a classificação de sentimentos no período eleitoral de 2018 referente às postagens realizadas na plataforma do *Facebook* dos candidatos Jair Bolsonaro e Fernando Haddad, utilizando da técnica de análise de sentimento.

O primeiro desafio foi criar o conjunto de dados devido a grande quantidade de dados presente nas páginas dos candidatos analisados. Através da própria API do *Facebook* foi possível realizar a coleta de forma automatizada utilizando *scripts* desenvolvidos em *Python*. Com isso, uma grande base de dados das informações das postagens e seus comentários pode ser formada.

O classificador *Sentistrength* por apresentar resultados significativos na literatura, foi a escolha como classificador de sentimentos neste trabalho. Porém, o desafio era analisar seu desempenho no idioma português, uma vez que seu desenvolvimento, bem como a maioria dos trabalhos relacionados foram elaborados no idioma inglês.

Outro fator adicional que dificultou sua aplicabilidade foi a alta complexidade sintática e semântica do idioma português. Como o *Sentistrength* utiliza dicionários com palavras pré-classificadas e baseia-se em sua ocorrência no texto, uma mesma palavra pode ter sentidos diversos em diferentes contextos. Por isso, a simples ocorrência da palavra “ódio” por exemplo, no texto, não indica necessariamente uma polaridade negativa. Pode ser apenas um texto com sentido informativo. Como determinadas palavras apresentam classificações de polaridades extremas, isso tende o texto a ter polaridade mais extremas de acordo com essas palavras.

Apesar destas observações foi possível perceber, comparando os períodos antes (P1) e após eleição (P3) no conjunto de dados, que houve uma mudança no comportamento das polaridades dos comentários relacionados aos candidatos Jair Bolsonaro e Fernando Haddad através da detecção de sentimentos positivos, negativos e neutros.

Após o primeiro turno da eleição, início do período P2, as polaridades de Bolsonaro e Haddad divergiram. Haddad apresentou mais polaridades positivas e Bolsonaro apresentou mais polaridades negativas. Com o fim do segundo turno da eleição e o início do período P3, ficou ainda mais evidente essa divergência, onde as polaridades se mostraram mais acentuadas, porém ocorrendo uma inversão nas polaridades entre os candidatos. Bolsonaro passa a apresentar polaridades mais positivas e Haddad mais negativas.

O percentual dos sentimentos relacionados a cada candidato é um reflexo do posicionamento de seus apoiadores. Haddad apresentou um aumento de 13.57% para

60.37% em comparação com os períodos P1 e P3 nos sentimentos de polaridade negativas levando em consideração a média dos comentários das postagens. Bolsonaro, por sua vez, teve um aumento durante o período P2, chegando a 26.67% de sentimentos negativos e terminando o período P3 com 7.48% de sentimentos negativos. O mesmo comportamento foi verificado na análise envolvendo a moda dos sentimentos dos comentários.

O alto percentual negativo nos comentários relacionados a Haddad após a eleição (P3) são justificados pela presença de críticas de Haddad ao governo de Bolsonaro após a eleição (P3), acarretando em insultos nos comentários de suas postagens como abordado na Subseção 5.2.2.

A técnica de análise de sentimentos utilizando o classificador *SentiStrength* apresentou desempenho satisfatório apesar de toda complexidade do idioma português. A utilização de um conjunto de termos aumentado mostrou-se mais eficaz em comparação com o conjunto original.

Diante das limitações do uso do *SentiStrength* no idioma português, uma possível melhoria para esse escopo seria ampliar os dicionários de termos do *SentiStrength* e avaliar seu comportamento em outros contextos. A verificação de uma possível relação entre análise de sentimentos e manifestação ódio no contexto político são propostas para trabalhos futuros.

Utilizar também meta-informações como histórico de atividades do usuário e informações de perfis para classificação de sentimentos e uso de aprimoramento de classificação através de aprendizado de máquina são propostas que podem aprimorar o desempenho do *SentiStrength* no idioma português.

## Referências

- AL-HASSAN, A.; AL-DOSSARI, H. Detection of hate speech in social networks: a survey on multilingual corpus. In: *6th International Conference on Computer Science and Information Technology*. [S.l.: s.n.], 2019. v. 10. Citado na página 18.
- ARAÚJO, M. et al. Métodos para análise de sentimentos no twitter. In: SN. *Proceedings of the 19th Brazilian symposium on Multimedia and the Web (WebMedia'13)*. [S.l.], 2013. p. 19. Citado 2 vezes nas páginas 25 e 27.
- BENEVENUTO, F.; RIBEIRO, F.; ARAÚJO, M. Métodos para análise de sentimentos em mídias sociais. *Sociedade Brasileira de Computação*, 2015. Citado 3 vezes nas páginas 20, 21 e 23.
- BIRD, S.; KLEIN, E.; LOPER, E. *Natural language processing with Python: analyzing text with the natural language toolkit*. [S.l.]: "O'Reilly Media, Inc.", 2009. Citado na página 33.
- BLAYA, C. Cyberhate: A review and content analysis of intervention strategies. *Aggression and violent behavior*, Elsevier, v. 45, p. 163–172, 2019. Citado na página 18.
- BROWN, A. What is hate speech? part 1: The myth of hate. *Law and Philosophy*, Springer, v. 36, n. 4, p. 419–468, 2017. Citado na página 18.
- BURNAP, P. et al. Detecting tension in online communities with computational twitter analysis. *Technological Forecasting and Social Change*, Elsevier, v. 95, p. 96–108, 2015. Citado na página 25.
- BURNAP, P.; WILLIAMS, M. L. Us and them: identifying cyber hate on twitter across multiple protected characteristics. *EPJ Data science*, Springer, v. 5, p. 1–15, 2016. Citado na página 18.
- CAMBRIA, E.; HUSSAIN, A. Senticnet. In: *Sentic Computing*. [S.l.]: Springer, 2015. p. 23–71. Citado na página 25.
- DINAKAR, K. et al. Common sense reasoning for detection, prevention, and mitigation of cyberbullying. *ACM Transactions on Interactive Intelligent Systems (TiiS)*, ACM New York, NY, USA, v. 2, n. 3, p. 1–30, 2012. Citado na página 19.
- DJURIC, N. et al. Hate speech detection with comment embeddings. In: *Proceedings of the 24th international conference on world wide web*. [S.l.: s.n.], 2015. p. 29–30. Citado na página 18.
- FACEBOOK. *Sharing Our Actions on Stopping Hate*. [S.l.], 2020. Disponível em: <<https://www.facebook.com/business/news/sharing-actions-on-stopping-hate>>. Citado na página 15.
- FACEBOOK. *Facebook for Developers, Page Feed*. [S.l.], 2021. Disponível em: <<https://developers.facebook.com/docs/graph-api/reference/v10.0/page/feed>>. Citado na página 49.

- GAMON, M. Sentiment classification on customer feedback data: noisy data, large feature vectors, and the role of linguistic analysis. In: *COLING 2004: Proceedings of the 20th International Conference on Computational Linguistics*. [S.l.: s.n.], 2004. p. 841–847. Citado na página 22.
- GONÇALVES, P. et al. Comparing and combining sentiment analysis methods. In: *Proceedings of the first ACM conference on Online social networks*. [S.l.: s.n.], 2013. p. 27–38. Citado 2 vezes nas páginas 20 e 23.
- GUZMAN, E.; AZÓCAR, D.; LI, Y. Sentiment analysis of commit comments in github: an empirical study. In: *Proceedings of the 11th working conference on mining software repositories*. [S.l.: s.n.], 2014. p. 352–355. Citado na página 27.
- HASSAN, A.; ABBASI, A.; ZENG, D. Twitter sentiment analysis: A bootstrap ensemble framework. In: *IEEE. 2013 international conference on social computing*. [S.l.], 2013. p. 357–364. Citado na página 21.
- HEMMATIAN, F.; SOHRABI, M. K. A survey on classification techniques for opinion mining and sentiment analysis. *Artificial Intelligence Review*, Springer, v. 52, n. 3, p. 1495–1545, 2019. Citado 2 vezes nas páginas 21 e 22.
- HOSSEINMARDI, H. et al. Detection of cyberbullying incidents on the instagram social network. *arXiv preprint arXiv:1503.03909*, 2015. Citado na página 19.
- INDURKHYA, N.; DAMERAU, F. J. *Handbook of natural language processing*. [S.l.]: CRC Press, 2010. v. 2. Citado na página 19.
- KIRILENKO, A. P. et al. Automated sentiment analysis in tourism: Comparison of approaches. *Journal of Travel Research*, Sage Publications Sage CA: Los Angeles, CA, v. 57, n. 8, p. 1012–1025, 2018. Citado na página 25.
- LIAO, C. et al. A hybrid method of domain lexicon construction for opinion targets extraction using syntax and semantics. *Journal of Computer Science and Technology*, Springer, v. 31, n. 3, p. 595–603, 2016. Citado na página 22.
- LIU, B. Sentiment analysis and opinion mining. *Synthesis lectures on human language technologies*, Morgan & Claypool Publishers, v. 5, n. 1, p. 1–167, 2012. Citado na página 21.
- MELO, R. L. Avaliando o dicionário em português do método de análise de sentimentos sentistrength. 2017. Citado na página 24.
- MOHAMMAD, S. M. et al. Sentiment, emotion, purpose, and style in electoral tweets. *Information Processing & Management*, Elsevier, v. 51, n. 4, p. 480–499, 2015. Citado na página 26.
- MOLINA-GONZÁLEZ, M. D. et al. A spanish semantic orientation approach to domain adaptation for polarity classification. *Information Processing & Management*, Elsevier, v. 51, n. 4, p. 520–531, 2015. Citado na página 22.
- MONDAL, M.; SILVA, L. A.; BENEVENUTO, F. A measurement study of hate speech in social media. In: *Proceedings of the 28th acm conference on hypertext and social media*. [S.l.: s.n.], 2017. p. 85–94. Citado na página 15.

- NOBATA, C. et al. Abusive language detection in online user content. In: *Proceedings of the 25th international conference on world wide web*. [S.l.: s.n.], 2016. p. 145–153. Citado na página 19.
- QIU, G. et al. Opinion word expansion and target extraction through double propagation. *Computational linguistics*, MIT Press, v. 37, n. 1, p. 9–27, 2011. Citado na página 21.
- RABAB'AH, A. M. et al. Evaluating sentiment strength for arabic sentiment analysis. In: IEEE. *2016 7th International Conference on Computer Science and Information Technology (CSIT)*. [S.l.], 2016. p. 1–6. Citado na página 25.
- REIS, J. et al. Uma abordagem multilíngue para análise de sentimentos. In: SBC. *Anais do IV Brazilian Workshop on Social Network Analysis and Mining*. [S.l.], 2015. Citado 3 vezes nas páginas 25, 26 e 27.
- RIBEIRO, F. N. et al. Sentibench - a benchmark comparison of state-of-the-practice sentiment analysis methods. *EPJ Data Science*, v. 5, n. 1, p. 1–29, 2016. ISSN 2193-1127. Disponível em: <<http://dx.doi.org/10.1140/epjds/s13688-016-0085-1>>. Citado 2 vezes nas páginas 20 e 23.
- SALAWU, S.; HE, Y.; LUMSDEN, J. Approaches to automated detection of cyberbullying: A survey. *IEEE Transactions on Affective Computing*, IEEE, v. 11, n. 1, p. 3–24, 2017. Citado na página 18.
- SCHMIDT, A.; WIEGAND, M. A survey on hate speech detection using natural language processing. In: *Proceedings of the fifth international workshop on natural language processing for social media*. [S.l.: s.n.], 2017. p. 1–10. Citado 2 vezes nas páginas 18 e 34.
- SILVA, C. A.; BARBOSA, D. M. Analyzing the acceptance of the 2018 brazilian presidential election's main candidates based on youtube comments. In: *Proceedings of the 25th Brazillian Symposium on Multimedia and the Web*. [S.l.: s.n.], 2019. p. 377–384. Citado 8 vezes nas páginas 16, 26, 31, 33, 34, 36, 37 e 76.
- SILVA, L. et al. Analyzing the targets of hate in online social media. In: *Proceedings of the International AAAI Conference on Web and Social Media*. [S.l.: s.n.], 2016. v. 10, n. 1. Citado na página 18.
- SOCHER, R. et al. Recursive deep models for semantic compositionality over a sentiment treebank. In: *Proceedings of the 2013 conference on empirical methods in natural language processing*. [S.l.: s.n.], 2013. p. 1631–1642. Citado na página 25.
- SOKOLOVA, M.; LAPALME, G. A systematic analysis of performance measures for classification tasks. *Information processing & management*, Elsevier, v. 45, n. 4, p. 427–437, 2009. Citado na página 35.
- TABOADA, M. et al. Lexicon-based methods for sentiment analysis. *Computational linguistics*, MIT Press, v. 37, n. 2, p. 267–307, 2011. Citado na página 20.
- TANKOVSKA, H. *Cumulative number of monthly Facebook product users as of 4th quarter 2020*. [S.l.], 2021. Disponível em: <<https://www.statista.com/statistics/947869/facebook-product-mau/>>. Citado na página 15.

- TANKOVSKA, H. *Leading countries based on Facebook audience size as of January 2021*. [S.l.], 2021. Disponível em: <<https://www.statista.com/statistics/268136/top-15-countries-based-on-number-of-facebook-users/>>. Citado na página 15.
- TANKOVSKA, H. *Number of monthly active Facebook users worldwide as of 4th quarter 2020*. [S.l.], 2021. Disponível em: <<https://www.statista.com/statistics/264810/number-of-monthly-active-facebook-users-worldwide/>>. Citado na página 15.
- THELWALL, M. The heart and soul of the web? sentiment strength detection in the social web with sentistrength. In: *Cyberemotions*. [S.l.]: Springer, 2017. p. 119–134. Citado na página 25.
- THELWALL, M.; BUCKLEY, K.; PALTOGLOU, G. Sentiment in twitter events. *Journal of the American Society for Information Science and Technology*, Wiley Online Library, v. 62, n. 2, p. 406–418, 2011. Citado na página 20.
- THELWALL, M. et al. Sentiment strength detection in short informal text. *Journal of the American society for information science and technology*, Wiley Online Library, v. 61, n. 12, p. 2544–2558, 2010. Citado 2 vezes nas páginas 19 e 24.
- TSAKALIDIS, A. et al. Predicting elections for multiple countries using twitter and polls. *IEEE Intelligent Systems*, IEEE, v. 30, n. 2, p. 10–17, 2015. Citado na página 26.
- UNANKARD, S. et al. Predicting elections from social networks based on sub-event detection and sentiment analysis. In: SPRINGER. *International Conference on Web Information Systems Engineering*. [S.l.], 2014. p. 1–16. Citado na página 26.
- VILARES, D.; THELWALL, M.; ALONSO, M. A. The megaphone of the people? spanish sentistrength for real-time analysis of political tweets. *Journal of Information Science*, Sage Publications Sage UK: London, England, v. 41, n. 6, p. 799–813, 2015. Citado na página 25.
- WILSON, T.; WIEBE, J.; HOFFMANN, P. Recognizing contextual polarity: An exploration of features for phrase-level sentiment analysis. *Computational linguistics*, MIT Press, v. 35, n. 3, p. 399–433, 2009. Citado na página 22.
- ZHONG, H. et al. Content-driven detection of cyberbullying on the instagram social network. In: *IJCAI*. [S.l.: s.n.], 2016. v. 16, p. 3952–3958. Citado na página 19.