

Análise de Sentimento de Postagens de Usuários no Twitter Combinando GPT-3 e Aprendizado de Máquina: Um Estudo de Caso Sobre o 2º Turno das Eleições Presidências Brasileiras

Ronilson Pereira¹, André Alves², Douglas Vidal², Flávio Moura², Laura Cabral³, Rita Paulino³, Marcos Serrufo², Karla Figueiredo¹

¹Universidade do Estado do Rio de Janeiro (UERJ) - Rio de Janeiro - RJ - Brasil

²Universidade Federal do Pará (UFPA) - Belém - PA - Brasil

³Universidade Federal de Santa Catarina (UFSC) - Florianópolis - SC - Brasil

{ronilsonengenharia, alvesandrevinicius, rvidalstm998}@gmail.com,

flavio.moura@itec.ufpa.br, {laurandrader, rcpauli}@gmail.com,

seruffo@ufpa.br, karla.figueiredo@gmail.com

Abstract. *In recent years, the influence of social media on elections around the world has become increasingly evident, for example, on Twitter. Texts posted on Twitter have attracted significant attention as an important source of information that can guide many decision-making processes. However, it becomes difficult to manually analyze all the comments on a certain subject on the internet. In this context, the aim of this study is to explore the application of the combination of GPT-3 and Machine Learning for the sentiment analysis of user posts on Twitter during the second round of the 2022 Brazilian presidential elections. GPT-3 and Machine Learning were able to accurately classify and identify the sentiments of user posts on Twitter. The proposed method obtained an accuracy of 90.88% using the Multinomial Naive Bayes classification algorithm.*

Resumo. *Nos últimos anos, a influência das mídias sociais nas eleições em todo o mundo tornou-se cada vez mais evidente, como exemplo, o Twitter. Os textos postados no Twitter têm atraído atenção significativa como uma importante fonte de informações que podem orientar muitos processos de tomada de decisão. No entanto, torna-se difícil analisar manualmente todos os comentários sobre um determinado assunto na internet. Neste contexto, o objetivo deste estudo é explorar a aplicação da combinação do GPT-3 e Aprendizado de Máquina para a análise de sentimento de postagens de usuários no Twitter durante o segundo turno das eleições presidenciais brasileiras de 2022. Os resultados revelam que a combinação do GPT-3 e Aprendizado de Máquina foi capaz de classificar e identificar com precisão os sentimentos das postagens de usuários no Twitter. O método proposto, obteve uma acurácia de 90,88% usando o algoritmo de classificação Multinomial Naive Bayes.*

1. Introdução

O Twitter tornou-se um dos canais de comunicação mais importantes para a divulgação de informações e opiniões nos últimos anos. Portanto, tem sido amplamente pesquisado

para extrair informações valiosas de postagens de usuários do *Twitter* usando técnicas de análise de sentimento [Biradar et al. 2022]. Ao longo da última década, as plataformas de mídia social têm se tornado cada vez mais importantes para a discussão de assuntos políticos. Devido a isso, observou-se que os analistas políticos começaram a buscar informações no uso das mídias sociais para conhecer as opiniões dos usuários sobre um determinado assunto [Jain et al. 2022].

O campo de estudo conhecido como análise de sentimento examina como opiniões, sentimentos, avaliações, atitudes e emoções são expressas em relação a entidades e seus atributos em textos escritos [Rodríguez-Ibáñez et al. 2023]. Normalmente, a tarefa da análise de sentimentos é reduzida a determinar se as emoções carregam uma conotação positiva ou negativa, ou como classificá-las. Um dos maiores desafios na classificação do sentimento dos *tweets* é que as pessoas normalmente comunicam seus sentimentos e opiniões em um estilo linguístico casual, o que leva à presença de palavras com erros ortográficos e ao uso descuidado da gramática [Barreto et al. 2023].

Em 2022, o Brasil viveu um dos grandes momentos da história política recente. As eleições despertaram a atenção e o interesse da população para a escolha dos representantes e do futuro do país. Ao longo de todo o período de campanha eleitoral, os candidatos à presidência da república participaram de debates em diversos canais e veículos, apresentaram suas ideias e utilizaram as mídias sociais para se aproximar da população e dialogar sobre suas propostas para o país.

Conforme demonstrado em [Mishra et al. 2022], a análise de sentimentos usando técnicas de Aprendizado de Máquina (ML - Machine Learning) é eficaz e permite a classificação de sentimentos em textos como tweets, comentários de blog e análises de produtos. O modelo de aprendizado de máquina estudado atingiu uma precisão de 94%. A abordagem de Processamento de Linguagem Natural (PLN) mudou a forma como nos relacionamos com as máquinas. Modelos avançados de processamento de linguagem, permitem que máquinas aprendam e compreendam a linguagem humana, entendendo contextos de conversa, significados semânticos e sintáticos e interprete textos [Lammerse et al. 2022]. Portanto, técnicas de PLN permitem análises complexas de dados textuais, permitindo aplicações práticas como *Chatbots*, geração de textos, sumarização de textos e a análise de sentimentos.

O GPT-3 criado pela empresa OpenAI¹, é um modelo de previsão de linguagem que se enquadra nas principais áreas de aplicativos de Inteligência Artificial. O GPT-3 é uma estrutura algorítmica feita para capturar uma parte da linguagem (uma entrada) e transformá-la na próxima parte da linguagem (uma saída) que o usuário acharia mais útil [Floridi and Chiriatti 2020]. Atualmente, a utilização do modelo GPT-3 está bastante evidente, devido sua popularização na mídia, como exemplo, o título: “*A.I. Is Mastering Language. Should We Trust What It Says?*”² publicado na revista *The New York Times*. O marco mais recente, foi a criação e lançamento do GPT-4³, um grande modelo multimodal que aceita entradas de imagem e texto e emite saídas de texto como respostas.

¹Mais informações em: <https://openai.com/>. Acesso em 16 de Janeiro de 2023.

²Disponível em: <https://www.nytimes.com/2022/04/15/magazine/ai-language.html?searchResultPosition=4>. Acessado em 13 de Fevereiro de 2023.

³Mais informações em: <https://openai.com/gpt-4>. Acessado em 03 de Novembro de 2023.

Seguindo este caminho, objetiva-se neste estudo explorar a aplicação da combinação do GPT-3 e Aprendizado de Máquina para a análise de sentimento de postagens de usuários no *Twitter*, durante um debate promovido por uma rede de televisão no dia 16 de outubro de 2022, ao longo do segundo turno das eleições presidenciais brasileiras de 2022. Para isso, utilizou-se o GPT-3 para classificar as postagens de usuários no *Twitter* como positivas, negativas ou neutras. Utilizou-se o GPT-3 em vez do GPT-4, pois, tem-se uma melhor disponibilidade de acesso. Em seguida, empregou-se o aprendizado de máquina para analisar os dados textuais classificados pelo GPT-3 e encontrar uma abordagem eficaz para análise de sentimentos.

O trabalho está organizado da seguinte maneira: a Seção 2 apresenta os trabalhos relacionados e a Seção 3 apresenta a metodologia utilizada. Na Seção 4 são apresentados os resultados das análises implementadas. Por fim, a Seção 5 apresenta as conclusões e sugestões de trabalhos futuros.

2. Trabalhos Relacionados

Para dar embasamento neste artigo, foram investigados na literatura, trabalhos voltados para análise de sentimentos, em especial, no *Twitter*. Estudos recentes têm explorado a aplicação de técnicas de aprendizado de máquina para a detecção de sentimentos em textos, como classificação de sentimentos, análise de polaridade e análise de emoções.

[Kheiri and Karimi 2023] apresenta um estudo de várias metodologias de *Generative Pretrained Transformer* (GPT) na análise de sentimentos. Foi proposta uma abordagem utilizando três estratégias. A primeira baseada em engenharia de *prompt* usando o GPT-3.5 Turbo. A segunda usando o ajuste fino de modelos GPT e a terceira utilizando uma abordagem para incorporar classificação. A pesquisa produziu *insights* comparativos detalhados entre essas estratégias e modelos individuais de GPT. Os resultados ilustraram a superioridade significativa de abordagens GPT em termos de desempenho preditivo, mais do que 22% na métrica de avaliação *F1-score* em comparação com o estado da arte. Por fim, o estudo destacou os benefícios da utilização dos modelos baseados em GPT.

O trabalho realizado por [Mathew and Bindu 2020] apresenta vários métodos de incorporação de palavras usados para análise de sentimento, seguido por uma visão geral sobre modelos pré-treinados de última geração usados para processamento de linguagem natural, que são comumente usados no processo de análise de sentimento. Os autores destacam a importância da opinião do público em geral a partir das redes sociais sobre um determinado assunto. O estudo avaliou o desempenho de dois modelos, o BiGRU e BERT usando conjunto de dados da IMDB. O BERT apresentou uma melhor precisão, exibindo um desempenho superior.

Modelos de processamento de linguagem natural foram estudados em [Brown et al. 2020]. Os autores utilizaram o GPT-3 e testaram seu desempenho. Para todas as tarefas realizadas como tradução, raciocínio, compreensão de leitura, não se utilizou nenhuma atualização de gradiente ou ajuste fino. Por fim, o GPT-3 atingiu um desempenho de 87.7% em muitos conjuntos de dados, incluindo tradução, resposta a perguntas, bem como várias tarefas que requerem raciocínio rápido.

Modelos de processamento de linguagem natural foram estudados em [Brown et al. 2020]. Os autores utilizaram o GPT-3 e testaram seu desempenho com poucas configurações de *prompt*. Para todas as tarefas realizadas como tradução, raciocínio,

compreensão de leitura, não se utilizou nenhuma atualização de gradiente ou ajuste fino. Por fim, o GPT-3 atingiu um desempenho de 87.7% em muitos conjuntos de dados, incluindo tradução, resposta a perguntas, bem como várias tarefas que requerem raciocínio rápido.

Considerando a linha de pesquisa voltada para análise de sentimentos e discurso de ódio em conteúdo político no geral, o trabalho feito por [Wang et al. 2022] se concentra no discurso de ódio político usado para atacar maliciosamente as pessoas que apresentam um ponto de vista político diferente. Os autores utilizaram um modelo de aprendizado profundo baseado em BERT, para análise de sentimento e detectar discurso de ódio político no idioma chinês, alcançando uma acurácia de 89.35%.

Com base no levantamento do estado da arte sobre análise de sentimentos, o uso de técnicas de aprendizado de máquina é amplamente utilizado neste contexto. Existem inúmeras propostas que utilizam essas técnicas e trabalhos utilizando GPT-3. Entretanto, não se encontraram trabalhos que usam essas duas soluções para análise de sentimentos em cenários diversos. Diferente de todos os trabalhos, a proposta de nossa abordagem visa uma análise de sentimentos a partir de dados coletados do *Twitter* sobre o segundo turno das eleições presidências Brasileiras, utilizando o GPT-3, para classificar (rotular) as postagens de usuários no *Twitter* como positivas, negativas ou neutras. Em seguida, empregou-se o aprendizado de máquina para analisar os dados textuais classificados pelo GPT-3 e encontrar uma abordagem eficaz para análise de sentimentos.

3. Metodologia

Conforme ilustrada na Camada 1 da Figura 1, os conjuntos de dados em análise inclui uma amostra de *tweets* postados durante um debate promovido por uma rede de televisão no dia 16 de outubro de 2022. A coleta de dados foi feita usando a biblioteca *SNScrape*⁴, que consegue extrair dados, perfis de usuários, *tweets* ao vivo e filtrar os mais importantes. Para buscar e coletar *tweets* relevantes, utilizou-se as *strings* "Bolsonaro debate", e "Lula debate". Com isso, foram gerados dois conjuntos de dados não rotulados, o primeiro possui 5.184 *tweets* relacionados ao candidato Bolsonaro e o segundo 6.485 relacionados ao candidato Lula. O objetivo desta separação é identificar sentimentos sobre postagens de apoiadores de Bolsonaro e Lula.

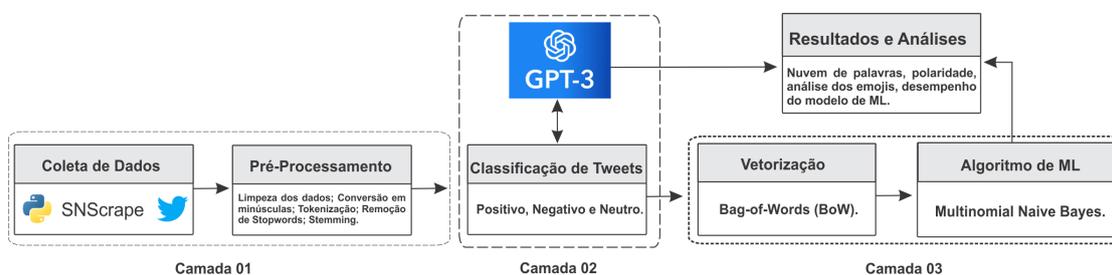


Figura 1. Visão Geral da Metodologia Proposta.

Depois que os dados são coletados, foi realizada a limpeza e o pré-processamento com base na metodologia apresentada na Figura 1, uma vez que, a maior parte do conjunto

⁴<https://github.com/JustAnotherArchivist/sns scrape>. Acesso em 02 de Fevereiro de 2023.

de dados contém ruídos ou dados indesejáveis. Foi seguida a metodologia proposta por [Sohrabi and Hemmatian 2019] para limpeza e pré-processamento dos dados.

De acordo com [Pradana and Hayaty 2019], uma série de etapas de pré-processamento são necessárias antes de aplicar qualquer classificador de aprendizado de máquina. Primeiramente, efetuou-se a limpeza dos dados, removendo pontuação, números e símbolos e todo conteúdo HTML, sendo a limpeza realizada usando expressões regulares. Outro passo necessário é a transformação de todo conteúdo textual para *lower case*. Outra etapa é a remoção de palavras irrelevantes (*Stopwords*) nos *tweets*, para isso foi utilizado o Python. Por fim, executou-se a *stemming* que é responsável por reduzir as palavras flexionadas à sua raiz. Realizou-se a *stemming* usando o *SnowBallStemmer* da ferramenta NLTK⁵.

As mensagens textuais coletadas passaram por um processo de rotulação usando o GPT-3 (Camada 2 da Figura 1), baseada no trabalho de [Pawar and Makwana 2022] para categorizar os sentimentos nos *tweets*, em que para conjunto de dados de amostra inclui 3.500 *tweets* selecionados aleatoriamente na ordem crescente. Em particular, cada *tweet* coletado foi classificado de forma semiautomática como positivo, negativo ou neutro. Portanto, cada *tweet* foi verificado manualmente posteriormente, a fim de validar as classificações geradas pelo GPT-3. Para utilizar o algoritmo de ML, realizou-se a junção dos conjuntos de dados rotulados totalizando 7.000 *tweets*.

Os modelos de aprendizado de máquina não compreendem dados textuais, desta forma, é essencial converter os dados textuais em vetores para o posterior processamento. A vetorização é ilustrada na Camada 3 da Figura ??, o texto foi transformado em uma informação numérica de modo que seja possível utilizá-lo para alimentar o modelo. Para converter palavras em representações vetoriais, aplicou-se o modelo *Bag-of-Words* (BoW), conforme utilizado em [Lee et al. 2022], pois é simples e eficiente para classificação de textos.

Depois que os dados dos *tweets* são convertidos para um formato vetorial, o conjunto de dados foi dividido em treino e teste com uma taxa de treinamento e teste de 70:30. Existem diversos Algoritmos de aprendizado de máquina, por exemplo, *Random Forest* (RF), *Support Vector Machine* (SVM), *Gradient Boosting* (GB), *Naive Bayes* (NB) etc. que são amplamente utilizados para análise de sentimentos [Singh et al. 2022]. Para esta classificação utilizou-se o algoritmo de classificação *Naive Bayes* (NB), visto que, várias tarefas de classificação podem ser executadas usando o método probabilístico de aprendizado de máquina NB [Singh et al. 2022].

4. Resultados e Discussões

Primeiramente, se analisou os termos mais utilizados dos 11.669 tweets coletados pela biblioteca SNScrape, o objetivo é apresentar uma compreensão geral sobre o teor das mensagens relacionadas aos candidatos Lula e Bolsonaro. Esses termos foram utilizados para criar nuvens de palavras para cada candidato, estas nuvens são mostradas na Figura 2 (a) e (b), relacionadas ao candidato Lula e Bolsonaro, respectivamente.

Na Figura 3, tem-se os resultados obtidos na análise de polaridade dos sentimentos sobre os candidatos realizada no GPT-3 foram os seguintes. Para o candidato Bolsonaro,

⁵<https://github.com/nltk/nltk>. Acesso em 06 de Fevereiro de 2023.



Figura 2. Nuvem de Palavras do Candidato Lula(a) e Bolsonaro(b).

35.8% dos *tweets* apresentaram polaridade positiva, 31.7% negativa e 32.5% neutro. Este cenário, se mostrou diferente para a análise feita com os dados do candidato Lula, tal que 43.6% dos *tweets* foram positivos, 25.4% negativos e 32.5% neutros. Através de uma análise quantitativa e qualitativa baseada nos termos mais frequentes para os dois conjuntos de dados, notou-se que as palavras "bolsonaro", "debate", "lula" e "globo" obtiveram maiores frequências. Além do mais, os resultados mostraram os termos que informam os sentimentos associados aos candidatos, como exemplo, "inocente", "ladrão", "brasil".

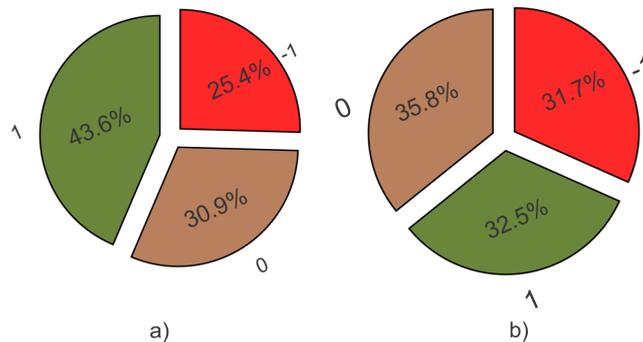


Figura 3. Distribuição de Sentimento do Candidato Lula(a) e Bolsonaro(b).

Com base nos dados, realizou-se um teste utilizando três algoritmos de classificação baseados no NB e, então, ranqueados seus resultados preliminares para seleção de um dos algoritmos, são eles: GaussianNB = 78.43%, BernoulliNB = 83.33% e o MultinomialNB = 90,88%. Considerando os resultados preliminares, foi selecionado o algoritmo MultinomialNB (MNB), dado que, é adaptado para saída multiclasse (positivo, negativo e neutro). Para verificar a eficiência e a validação do modelo, aplicou-se quatro métricas muito comuns na literatura para avaliar modelos de aprendizado de máquina, *accuracy*, *f1_score*, *recall* e *precision*. A Tabela 1 fornece os resultados da classificação realizada com o algoritmo MNB.

Tabela 1. Resumo de Desempenho do modelo

Algoritmo	Métricas			
	Accuracy (%)	F1_Score (%)	Recall (%)	Precision (%)
MNB	90.88%	91.32%	91.55%	90.06%

5. Conclusão

Neste trabalho objetivou-se explorar a aplicação da combinação de GPT-3 e Aprendizado de Máquina para a análise de sentimentos de postagens de usuários no *Twitter*, durante um debate promovido por uma rede de televisão no dia 16 de outubro de 2022, ao longo do segundo turno das eleições presidenciais brasileiras de 2022.

O estudo de caso realizado, combinando o GPT-3 e aprendizado de máquina apresentou resultados melhores do que os apontados por [Pandya et al. 2021] e [Singh et al. 2022], o modelo obteve um valor médio de acurácia de 90.88% utilizando o algoritmo MNB para saída multiclasse. Desta forma, indicando que a abordagem é capaz de classificar com precisão os sentimentos dos posts. Além disso, a abordagem pode ser utilizada em outros contextos, como na análise de sentimento de outras redes sociais, tal como, *Facebook* e *Instagram*. Com base nos resultados quantitativos e qualitativos, chegou-se à conclusão de que as redes sociais e as tecnologias digitais desempenham um papel significativo na democracia, porque permitem que os eleitores obtenham informações para que possam tomar decisões sobre um determinado assunto.

No entanto, é importante observar que ainda existem algumas limitações a serem levadas em consideração. Por exemplo, a classificação dos sentimentos utilizando o GPT-3 não possui 100% de precisão, tornando-se necessário uma anotação semiautomática de cada *tweet*. Ademais, a análise de sentimento em redes sociais possui bastante textos informais, o que dificulta as análises e pré-processamentos. As recomendações para trabalhos futuros incluem a realização de estudos de caso em outros idiomas, pesquisa de abordagens alternativas para a análise de sentimentos, coletar dados mais abrangentes, utilização de outros algoritmos de aprendizado de máquina e aplicação de modelos mais complexos de aprendizagem profunda.

Referências

- Barreto, S., Moura, R., Carvalho, J., Paes, A., and Plastino, A. (2023). Sentiment analysis in tweets: an assessment study from classical to modern word representation models. *Data Mining and Knowledge Discovery*, 37(1):318–380.
- Biradar, S. H., Gorabal, J., and Gupta, G. (2022). Machine learning tool for exploring sentiment analysis on twitter data. *Materials Today: Proceedings*, 56:1927–1934.
- Brown, T., Mann, B., Ryder, N., Subbiah, M., Kaplan, J. D., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., et al. (2020). Language models are few-shot learners. *Advances in neural information processing systems*, 33:1877–1901.
- Floridi, L. and Chiriatti, M. (2020). Gpt-3: Its nature, scope, limits, and consequences. *Minds and Machines*, 30:681–694.
- Jain, T., Mathur, S., Ninnad, A., Nikshep, B., and Chalil, N. (2022). Analyzing of political tweets in hindi language using machine learning and deep learning. In *2022 IEEE International Conference on Data Science and Information System (ICDSIS)*, pages 1–5. IEEE.
- Kheiri, K. and Karimi, H. (2023). Sentimentgpt: Exploiting gpt for advanced sentiment analysis and its departure from current machine learning. *arXiv preprint arXiv:2307.10234*.

- Lammerse, M., Hassan, S. Z., Sabet, S. S., Riegler, M. A., and Halvorsen, P. (2022). Human vs. gpt-3: The challenges of extracting emotions from child responses. In *2022 14th International Conference on Quality of Multimedia Experience (QoMEX)*, pages 1–4. IEEE.
- Lee, J., Warner, E., Shaikhouni, S., Bitzer, M., Kretzler, M., Gipson, D., Pennathur, S., Bellovich, K., Bhat, Z., Gadegbeku, C., et al. (2022). Unsupervised machine learning for identifying important visual features through bag-of-words using histopathology data from chronic kidney disease. *Scientific Reports*, 12(1):4832.
- Mathew, L. and Bindu, V. (2020). A review of natural language processing techniques for sentiment analysis using pre-trained models. In *2020 Fourth International Conference on Computing Methodologies and Communication (ICCMC)*, pages 340–345. IEEE.
- Mishra, P., Patil, S. A., Shehroj, U., Aniyeri, P., and Khan, T. A. (2022). Twitter sentiment analysis using naive bayes algorithm. In *2022 3rd International Informatics and Software Engineering Conference (IISEC)*, pages 1–5. IEEE.
- Pandya, V., Somthankar, A., Shrivastava, S. S., and Patil, M. (2021). Twitter sentiment analysis using machine learning and deep learning techniques. In *2021 2nd International Conference on Communication, Computing and Industry 4.0 (C2I4)*, pages 1–5. IEEE.
- Pawar, C. S. and Makwana, A. (2022). Comparison of bert-base and gpt-3 for marathi text classification. In *Futuristic Trends in Networks and Computing Technologies: Select Proceedings of Fourth International Conference on FTNCT 2021*, pages 563–574. Springer.
- Pradana, A. W. and Hayaty, M. (2019). The effect of stemming and removal of stopwords on the accuracy of sentiment analysis on indonesian-language texts. *Kinetik: Game Technology, Information System, Computer Network, Computing, Electronics, and Control*, pages 375–380.
- Rodríguez-Ibáñez, M., Casáñez-Ventura, A., Castejón-Mateos, F., and Cuenca-Jiménez, P.-M. (2023). A review on sentiment analysis from social media platforms. *Expert Systems with Applications*, page 119862.
- Singh, S., Kumar, K., and Kumar, B. (2022). Sentiment analysis of twitter data using tf-idf and machine learning techniques. In *2022 International Conference on Machine Learning, Big Data, Cloud and Parallel Computing (COM-IT-CON)*, volume 1, pages 252–255. IEEE.
- Sohrabi, M. K. and Hemmatian, F. (2019). An efficient preprocessing method for supervised sentiment analysis by converting sentences to numerical vectors: a twitter case study. *Multimedia tools and applications*, 78(17):24863–24882.
- Wang, C.-C., Day, M.-Y., and Wu, C.-L. (2022). Political hate speech detection and lexicon building: A study in taiwan. *IEEE Access*, 10:44337–44346.