



UFOP

Universidade Federal
de Ouro Preto

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

**Modelo para classificação do viés
político de postagens de usuários em
redes sociais**

Lucas Pereira Miranda

**TRABALHO DE
CONCLUSÃO DE CURSO**

**ORIENTAÇÃO:
Filipe Nunes Ribeiro**

**Março, 2023
João Monlevade–MG**

Lucas Pereira Miranda

**Modelo para classificação do viés político de
postagens de usuários em redes sociais**

Orientador: 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

Março de 2023



FOLHA DE APROVAÇÃO

Lucas Pereira Miranda

Modelo para classificação do viés político de postagens de usuários em redes sociais

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 março de 2023

Membros da banca

Doutor - Filipe Nunes Ribeiro - Orientador(a) (Universidade Federal de Ouro Preto)
Doutora - Helen de Cássia Sousa da Costa Lima - (Universidade Federal de Ouro Preto)
Doutor - Luiz Carlos Bambirra Torres - (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 07/04/2023



Documento assinado eletronicamente por **Filipe Nunes Ribeiro, PROFESSOR DE MAGISTERIO SUPERIOR**, em 08/04/2023, às 12:02, 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, informando o código verificador **0505503** e o código CRC **9C57168F**.

A Deus, meus familiares e amigos, por fazerem parte da minha vida e me inspirarem a
cada dia

Agradecimentos

Gostaria de começar meus agradecimentos expressando minha gratidão a Deus, por ter me dado saúde e determinação para concluir este trabalho.

Aos meus pais, José Wilson e Erica, agradeço por terem me incentivado nos momentos difíceis e compreendido minha ausência enquanto me dedicava à realização deste trabalho. O apoio de vocês fez toda a diferença nesta jornada.

As minhas avós, Istela e Mafalda, que estiveram ao meu lado com palavras de conforto, incentivo e amor, as quais foram muito importantes para a minha trajetória acadêmica e de vida.

Aos meus irmãos, Bruno e Ellen, pela companhia, amizade, cumplicidade e apoio incondicional ao longo de minha trajetória acadêmica e pessoal.

Ao meu orientador, Filipe Nunes Ribeiro, agradeço por ter sido um guia dedicado e amigo nesta jornada. Seus conselhos e sugestões foram inestimáveis na realização deste trabalho.

Aos meus amigos e colegas de turma, Bruno, Bryan, Débora, Hellrison, Lucas Henrique, Lucas Rocha, Matheus, Nathália, Pedro, Thuane, Thiago, Tiesari, Victor Dias, Victor Huggo e Warlen, por sua companhia, amizade e apoio durante a graduação.

A Universidade Federal de Ouro Preto ([UFOP](#)) e a todos os seus professores, que desempenharam um papel fundamental em minha formação profissional. Ao longo dos anos do curso, tive o privilégio de aprender com excelentes professores que me incentivaram a buscar o conhecimento e desenvolver minhas habilidades. Sou grato por todo o suporte e orientação que recebi, os quais foram essenciais para meu crescimento acadêmico e pessoal.

A todos que me acompanharam em minha caminhada para a realização deste trabalho, minha gratidão.

'Deus é a minha salvação. Terei confiança e não temerei'

—Isaías 12:2,
Bíblia sagrada

Resumo

O presente trabalho tem como objetivo treinar e avaliar modelos preditivos usando como base algoritmos de aprendizagem presentes na literatura para obter classificação de textos contidos em publicações políticas presentes nas redes sociais. O estudo aborda técnicas de coleta de dados, processamento de linguagem natural e algoritmos de aprendizado de máquina. Para atingir esse objetivo foram coletados dados de mídias alternativas com forte viés político de esquerda e direita para serem utilizados em modelos pré-treinados do *BERT* visando a classificação e identificação de suas características para categorizar outros textos publicados por candidatos e usuários. Os modelos desenvolvidos baseados no *bert-base-uncased* e *neuralmind/bert-base-portuguese-cased* foram comparados variando hiper parâmetros de treinamento, a fim de gerar os modelos com os melhores desempenhos dentro dos conjuntos de teste e validação. Como principal resultado, foi obtido um modelo baseado no *neuralmind/bert-base-portuguese-cased* com o maior desempenho em relação aos demais treinados a partir deste modelo estado da arte no trabalho, o qual apresentou uma acurácia de 74,25% e uma medida F de 71,93% em um conjunto recente de postagens. O estudo realizado tem como objetivo trazer modelos que possam auxiliar futuramente cientistas políticos, pesquisadores e jornalistas na análise do viés textual no contexto político utilizando a opinião imparcial e apartidária da tecnologia.

Palavras-chaves: mídias alternativas. *BERT*. aprendizagem de máquina.

Abstract

The present study aims to train and evaluate predictive models using learning algorithms from the literature to obtain classification of texts contained in political publications on social media. The study addresses data collection techniques, natural language processing, and machine learning algorithms. To achieve this objective, data from alternative media with a strong political left and right bias were collected and used in pre-trained BERT models to classify and identify their characteristics, in order to categorize other texts published by candidates and users. Models based on bert-base-uncased and neuralmind/bert-base-portuguese-cased will be compared by varying training hyperparameters to generate models with the best performance within the validation set. As a main result, a model based on neuralmind/bert-base-portuguese-cased was obtained with the best performance compared to the others trained from this state-of-the-art model in the work, which presented an accuracy of 74.25% and an F-measure of 71.93% on a recent set of posts. The study aims to provide models that can assist political scientists, researchers, and journalists in analyzing textual bias in the political context using the impartial and non-partisan opinion of technology.

Key-words: *alternative media. BERT. machine learning.*

Lista de ilustrações

Figura 1 – Fluxograma associado a metodologia para obter as páginas base para serem aplicadas ao <i>Crowntangle</i>	24
Figura 2 – Fluxograma associado a metodologia para selecionar páginas após a análise do <i>Crowntangle</i>	27
Figura 3 – Exemplo de post coletado no formato JavaScript Object Notation (JSON). As propriedades <i>reactions_sad</i> , <i>reactions_angry</i> e <i>reactions_love</i> estão minimizadas na ilustração	28
Figura 4 – Análise da similaridade de cosseno	32
Figura 5 – Demonstrando a Label 0 para posts de páginas de esquerda e 1 para posts de páginas de direita.	36

Lista de tabelas

Tabela 1	–	Páginas inicialmente selecionadas na esfera anti-anti-PT	24
Tabela 2	–	Páginas previamente selecionadas na esfera anti-PT	24
Tabela 3	–	14 páginas associadas a esfera anti-anti-PT com maiores frequências dentro da coleta do <i>Crowdtangle</i>	25
Tabela 4	–	15 páginas associadas a esfera anti-PT com maiores frequências dentro da coleta do <i>Crowdtangle</i>	26
Tabela 5	–	Páginas selecionadas na esfera de esquerda	26
Tabela 6	–	Páginas selecionadas na esfera de direita	27
Tabela 7	–	Páginas selecionadas na esfera de direita para a análise dos modelos com melhores métricas no conjunto de treinamento e validação	31
Tabela 8	–	Páginas selecionadas na esfera de esquerda para a análise dos modelos com melhores métricas no conjunto de treinamento e validação	31
Tabela 9	–	Hiper parâmetros usados na etapa de <i>fine-tuning</i> dos modelos estado da arte do Bidirectional Encoder Representations from Transformers (BERT)	36
Tabela 10	–	Análise da entrada e saída a partir do modelo durante o processo de classificação	37
Tabela 11	–	Métricas associadas a quantidade de posts por página coletada no <i>Facebook</i> para o treinamento e validação dos modelos	38
Tabela 12	–	Métricas associadas a quantidade de likes por ano coletadas no <i>Facebook</i> para o treinamento e validação dos modelos	39
Tabela 13	–	Métricas associadas a quantidade de reações por ano em páginas coletadas no <i>Facebook</i> para o treinamento e validação dos modelos	39
Tabela 14	–	Convenção utilizada na matriz de confusão	40
Tabela 15	–	Métricas dos modelos gerados a partir do <i>bert-base-uncased</i> na etapa de treinamento	41
Tabela 16	–	Matrizes de confusão para os modelos baseados no <i>bert-base-uncased</i> na etapa de validação	41
Tabela 17	–	Métricas dos modelos gerados a partir do <i>bert-base-uncased</i> na etapa de validação	42
Tabela 18	–	Métricas dos modelos gerados a partir do <i>neuralmind/bert-base-portuguese-cased</i> na etapa de treinamento	42
Tabela 19	–	Matrizes de confusão para os modelos baseados no <i>neuralmind/bert-base-portuguese-cased</i>	43
Tabela 20	–	Métricas dos modelos gerados a partir do <i>neuralmind/bert-base-portuguese-cased</i> na etapa de validação	43

Tabela 21 – Métricas do modelo gerado a partir do <i>fine-tuning</i> do <i>bert-base-uncased</i> com 4 épocas de treinamento no conjunto adicional de posts	44
Tabela 22 – Matriz de confusão associada ao modelo gerado a partir do <i>fine-tuning</i> do <i>bert-base-uncased</i> no conjunto adicional de posts	44
Tabela 23 – Métricas do modelo gerado a partir do <i>fine-tuning</i> do <i>neuralmind/bert-base-portuguese-cased</i> com 2 épocas de treinamento no conjunto adicional de posts	45
Tabela 24 – Matriz de confusão associada ao modelo gerado a partir do <i>fine-tuning</i> do <i>neuralmind/bert-base-portuguese-cased</i> no conjunto adicional de posts	45

Lista de abreviaturas e siglas

ML Machine Learning

LDA Latent Dirichlet Allocation

IA Inteligência artificial

WEB world wide web

PT Partido dos Trabalhadores

API Application Programming Interface

JSON JavaScript Object Notation

URL Uniform Resource Locator

UTF-8 8-bit Unicode Transformation Format

BERT Bidirectional Encoder Representations from Transformers

SVM Support vector machines

LSTM Long short-term memory

PT-BR Português do Brasil

PLN processamento de linguagem natural

UFOP Universidade Federal de Ouro Preto

EUA Estados Unidos da America

Sumário

1	INTRODUÇÃO	15
2	REVISÃO BIBLIOGRÁFICA	18
2.1	Mídias alternativas	18
2.2	Ciência de dados e <i>Machine Learning</i>	20
3	MATERIAIS E MÉTODOS	23
3.1	Seleção das páginas de mídias alternativas	23
3.2	Coleta de dados	26
3.3	Processamento do <i>corpus</i>	29
3.4	Coleta adicional para aplicação nos modelos com melhores métricas	30
3.5	<i>BERT</i>	31
3.6	<i>Seleção de modelos estado da arte</i>	34
3.7	<i>fine-tuning</i> dos modelos selecionados	35
4	RESULTADOS	38
4.1	Caracterização dos dados coletados para o treinamento e validação dos modelos	38
4.2	Resultados do processo de <i>fine-tuning</i>	39
4.2.1	Resultados com o <i>bert-base-uncased</i>	40
4.2.1.1	Etapa de treinamento	40
4.2.1.2	Etapa de validação	41
4.2.2	Resultados com o <i>neuralmind/bert-base-portuguese-cased</i>	42
4.2.2.1	Etapa de treinamento	42
4.2.2.2	Etapa de validação	42
4.2.3	Comparação entre os modelos treinados	43
4.3	Validação adicional dos modelos com melhor desempenho	43
4.3.1	Validação adicional do modelo gerado a partir do <i>bert-base-uncased</i> com 4 épocas	44
4.3.2	Validação adicional do modelo gerado a partir do <i>neuralmind/bert-base-portuguese-cased</i> com 2 épocas	44
5	CONCLUSÃO	46
	REFERÊNCIAS	47

APÊNDICES	51
APÊNDICE A – <i>STOPWORDS NLTK</i> UTILIZADAS	52
APÊNDICE B – CÓDIGO UTILIZADO PARA OBTER A CLAS- SIFICAÇÃO DE UM TEXTO DE ENTRADA A PARTIR DO MODELO TREINADO	53

1 Introdução

Com o advento e crescimento da rede mundial de computadores, as mídias sociais se tornaram populares e receberam uma grande quantidade de usuários em todos os continentes do planeta. Nesse contexto, foi visto uma expansão das mídias alternativas, as quais são veículos de divulgação da informação que realizam o jornalismo independente e que estão fora dos jornais convencionais e da mídia tradicional que detinha grande parte do monopólio da divulgação das informações para a população.

Segundo [Teixeira \(2022\)](#), as mídias alternativas desempenham um papel muito de contra-informação propondo abordagens opostas às mídias convencionais as quais são frequentemente pautadas pelas agendas dos grandes grupos econômicos e de alguns governos com indícios de serem antidemocráticos.

Em seu trabalho, [Aharoni \(2021\)](#) indica que de forma análoga a necessidade de inovação causada pelos serviços de *streaming* de vídeos nos cinemas, as mídias alternativas também estão fazendo com que as mídias convencionais tenham que se adaptar para se manterem fortes no topo da área de divulgação de conteúdos em geral.

No recente cenário eleitoral brasileiro, o qual está marcado pelo *impeachment* de uma presidente em exercício, prisão de um ex-presidente e grande presença da população nas redes, as mídias alternativas vêm mostrando grande poder de influência nos internautas por meio de seus discursos, muitas vezes extremistas e com uma clara polarização para uma esfera política.

Segundo [Garimella \(2018\)](#), a polarização ocorre devido à discussão de tópicos polêmicos em redes sociais, como por exemplo, aborto e porte de armas. No Brasil, estes e outros tópicos vêm sendo consistentemente discutidos por eleitores devido a estarem presentes em pautas nas diferentes esferas políticas com maiores probabilidades de ascenderem ao cargo presidencial no país.

No ambiente *online*, o jornalismo independente presente nas mídias sociais consegue fornecer um alimento constante de notícias tendenciosas aos eleitores, gerando um combustível a mais nesse cenário de discussões políticas ([VASCONCELOS et al., 2020](#)).

Ainda em [Vasconcelos et al. \(2020\)](#), os autores fizeram contribuições como a criação e validação de uma metodologia para identificar e mensurar o viés político das páginas presentes no *Facebook*. Outra contribuição dos autores foi determinar um método para diferenciar mídias alternativas, mídias convencionais e figuras públicas em páginas brasileiras do *Facebook*, metodologia a qual está sendo utilizada no presente trabalho.

O autor [Garimella \(2018\)](#) trouxe uma caracterização da polarização dos discursos

no *Twitter* utilizando um *dataset* de mais de 2.5 bilhões de *tweets*. O trabalho obteve como resultado um indicativo de que houve um consistente crescimento na polarização (cerca de 10 a 20%) desde a última década.

Com a evolução das técnicas de análise de conteúdo textual, está sendo possível observar o surgimento de ferramentas que realizam processamento de linguagem natural possibilitando obter de uma forma sistemática análises de sentimentos, classificação, tradução e predição de sequência em textos.

As redes sociais tem uma grande quantidade de usuários e analisar o conteúdo textual gerado de forma sistemática e eficiente sem auxílio da tecnologia é complexo, pois demanda tempo e alocação de juízes humanos. Desenvolver modelos preditivos baseados em processamento de linguagem natural (PLN) pode auxiliar cientistas políticos, pesquisadores e jornalistas a analisarem os conteúdos dos textos de forma automatizada.

Durante as revisões bibliográficas não foram encontrados trabalhos com foco no desenvolvimento de modelos para classificação de textos políticos no contexto do cenário eleitoral brasileiro atual em mídias sociais. Assim, o presente trabalho poderá ajudar a preencher um *gap* na literatura nesse cenário.

O objetivo geral da pesquisa é desenvolver modelos para a classificação de mensagens de redes sociais de esquerda e direita no cenário político atual do Brasil. Para construir o classificador, o presente trabalho utiliza modelos *open source* em estado da arte baseados no *BERT* para realizar o processo de *fine-tuning* visando capacitá-los para a classificação da polaridade política esquerda/direita de posts das redes sociais.

De forma mais detalhada, os objetivos específicos da pesquisa são:

- Selecionar páginas presentes em mídias alternativas de direita e esquerda.
- Coletar postagens realizadas nessas páginas abordadas.
- Caracterizar os dados coletados.
- Selecionar modelos estado da arte para serem utilizados como base de treinamento.
- Preparar os dados para serem utilizados no processo de *fine-tuning* dos modelos selecionados.
- Realizar o treinamento e a validação utilizando diferentes hiper parâmetros.
- Análise e avaliação dos resultados obtidos.

Em relação à estrutura do trabalho, o Capítulo 2 apresenta a revisão da literatura trazendo os estudos dos trabalhos sobre PLN, ciência de dados e mídias alternativas. Na sequência, o Capítulo 3 traz os materiais e métodos utilizados para o desenvolvimento do

trabalho, bem como as metodologias utilizadas para coletas, processamento e *fine-tuning* realizados em modelos estado da arte selecionados do *BERT*. No Capítulo 4 é apresentado uma caracterização dos dados coletados e um estudo sobre o desempenho dos modelos treinados. E por fim, o Capítulo 5 indica as conclusões resultantes do desenvolvimento deste trabalho.

2 Revisão Bibliográfica

A presente seção tem como finalidade apresentar o referencial teórico para a pesquisa, explicando e definindo os principais conceitos utilizados como ciência de dados, PLN, mídias alternativas e Machine Learning (ML).

2.1 Mídias alternativas

Em relação ao conceito de mídias alternativas para os usuários, Rauch (2014) realizou uma pesquisa de audiência com consumidores de conteúdos em que as respostas revelaram os valores que os entrevistados concordaram serem importantes para a definição de mídia alternativa. Os usuários consideraram como mídias alternativas: blogs políticos, emissoras públicas, fontes estrangeiras e instituições de imprensa alternativa. Os entrevistados valorizaram o conteúdo alternativo como pautas negligenciadas, vozes diversas e minorias para definir o jornalismo independente mais do que o fato de muitos desses jornais serem sem fins lucrativos, não comercial e de pequena escala.

Segundo Goes (2022), as mídias alternativas compartilham valores dos movimentos sociais na world wide web (WEB), visando a transformação social, conscientização política, luta por direitos e denuncia de causas. Essas mídias também podem sugerir ações que podem ser tomadas para aliviar essas pautas.

Com a popularização do acesso à *Internet*, as mídias alternativas conseguiram o poder de exercer jornalismo independente influenciando os seguidores em prol de causas específicas, o que antes faziam parte principalmente da esfera de influência das mídias tradicionais. Ainda segundo Goes (2022), a *Internet* fornece a base material que permite os movimentos sociais engajarem-se na produção de uma nova sociedade, por meio das discursões geradas nas mídias alternativas.

O trabalho de Boyle e Schmierbach (2009) examinou o papel que a mídia convencional e alternativa desempenham em influenciar a população na participação política tradicional em protestos. Os resultados do trabalho indicam que a mídia alternativa está relacionada à participação nesses eventos. Desde a época da publicação do trabalho, os autores já ressaltavam a importância emergente da mídia alternativa baseada na WEB dentro dos fenômenos políticos.

Também no início do século XXI, o trabalho de Harcup (2005) já estava analisando eventos associados a relação entre as mídias alternativas e as mídias convencionais. No estudo, o autor identificou que mídias alternativas surgiam e eram fomentadas graças ao sentimento de que elas podiam exercer o jornalismo independente com a sensação de

poder mudar o mundo a partir da ação de divulgar o seu ponto de vista e ideais para o seu público.

Em [Aharoni \(2021\)](#), o autor realizou estudos visando entender o fenômeno da interação das mídias alternativas dentro do ecossistema das mídias tradicionais com a finalidade de trazer uma teoria poli sistêmica como base de uma resposta das grandes mídias para se manterem firmes frente a crescente popularização do jornalismo independente. Os resultados demonstram que sistemas rígidos e flexíveis são duas formas principais de caracterizar as relações entre mídias alternativas e convencionais levando em consideração o conteúdo, percepções do produtor e recepção do público.

Dentro do contexto político, [Teixeira \(2022\)](#) trouxe a tona a questão de que algumas mídias alternativas, como por exemplo a página *Brasil 247*, a qual assume uma postura em defesa do Partido dos Trabalhadores (PT) como um exemplo de que páginas de mídias que realizam jornalismo independente também se posicionam explicitamente a favor de partidos políticos. Ainda segundo [Teixeira \(2022\)](#), foi identificado que existem mídias que apoiam movimentos extremistas, fundamentalistas, liberais, e de propagação de notícias falsas.

Em [Haller e Holt \(2019\)](#), os autores realizaram análises dos conteúdos de páginas do *Facebook* na Alemanha em relação à grande mídia. A pauta do trabalho era a imigração gerada a partir da primavera árabe. O trabalho dos autores trouxe pontos como as mídias alternativas estarem geralmente associados com o ativismo de esquerda na Europa e que movimentos polêmicos como partidos ou organizações populistas vem tendendo a confiar mais em mídias alternativas do que na mídia tradicional.

No trabalho de [Nygaard \(2021\)](#) foi analisada a grande mídia na Europa como ponto de partida para argumentar se os meios de comunicação alternativos são aceitos ou rejeitados como atores jornalísticos. O autor chegou à conclusão que a reação geral da mídia *mainstream* aos "invasores" tende a ser geralmente de rejeição, trazendo à tona sua falta de pertencimento ao jornalismo profissional. O trabalho observou evidências de como os jornalistas tradicionais costumam usar rótulos vagos como *site* e mídia *online* para descrever o jornalismo independente.

Na Península Escandinava, os autores [Ihlebak e Nygaard \(2021\)](#) realizaram um trabalho com a finalidade de entender o panorama das mídias alternativas de direita. Durante o estudo, é trazido à tona o fenômeno em que os críticos enfatizam o conteúdo de baixa qualidade, sensacionalista, e às vezes odioso encontrado em alguns desses sites, temendo que eles possam contribuir para o aumento da polarização, desconfiança e racismo na sociedade. Por outro lado, apoiadores argumentam que as mídias alternativas fornecem perspectivas originais e novas vozes sobre questões importantes como crime, imigração e islamismo, que não são cobertas em todos os detalhes pela grande imprensa.

Em Vasconcelos et al. (2020), os autores fizeram contribuições importantes como uma metodologia para caracterizar mídias alternativas, mídias convencionais e figuras públicas em páginas brasileiras do *Facebook*. Dentro dessas categorizações, foram definidas as seguintes classificações:

- **Mídias alternativas:** São páginas nas redes sociais que não possuem registro como mídia de imprensa oficial brasileira e que realizam jornalismo independente.
- **Mídias convencionais:** São jornais, revistas, websites, TV e rádio que possuem registro como mídia de imprensa oficial brasileira.
- **Figuras públicas:** São páginas de políticos e personalidades públicas no cenário das mídias sociais.

No cenário eleitoral Brasileiro, Vasconcelos et al. (2020) utilizou um conjunto de páginas disponibilizadas pelo autor Pablo Ortellado ¹ contendo páginas de mídias alternativas no contexto eleitoral brasileiro, as quais foram usadas como base para a seleção e coleta de dados do presente trabalho.

2.2 Ciência de dados e *Machine Learning*

A ciência de dados vem tendo um grande destaque no meio organizacional e acadêmico devido a grande quantidade de informações que estão sendo geradas sistematicamente nos meios digitais.

Segundo Pimentel et al. (2021), “a ciência de dados tem como objetivo extrair conhecimentos úteis de bases de informações. Durante o processo de extração, os dados brutos com diversos formatos e estruturas são obtidos de fontes, pré-processados para atingir um nível esperado de integridade, e finalmente analisados através da extração de estatísticas, visualizações e técnicas de mineração de dados e aprendizado de máquina para que as informações desejadas sejam obtidas”.

O trabalho de Shahrezaye et al. (2019) realizou estudos de ciência de dados com a finalidade de entender e prever o partido político de usuários do *Twitter* em relação a 6 partidos na Alemanha. O trabalho obteve como resultado uma taxa de acurácia de 62%. Esta obra trouxe observações quanto as métricas e processos para tratamento de dados, como o pré-processamento e a acurácia na análise de dados, a qual é dada pela porcentagem representando a quantidade de acertos do modelo dentro do conjunto total de elementos validados.

¹ <https://homepages.dcc.ufmg.br/samuel.guimaraes/ASONAM2020> - acesso em: 19/03/2022

Analisar o conteúdo utilizando tecnologias como *Machine Learning* vem se mostrando eficiente para processar variadas e numerosas quantidades de dados, especialmente para descobrir padrões ocultos e correlações desconhecidas [Gandomi, Chen e Abualigah \(2022\)](#). O ML trouxe a tona uma nova forma de auxílio aos humanos na tomada de decisões em cima dos dados.

Segundo [Faceli et al. \(2011\)](#), o ML é uma área de pesquisa da Inteligência artificial (IA) que visa o desenvolvimento de programas de computador com a capacidade de aprender a executar uma dada tarefa com sua própria experiência.

De acordo com [Cerri e Carvalho \(2017\)](#), dentro do ML podem ser realizadas tarefas descritivas e preditivas. As tarefas descritivas estão associadas ao agrupamento de dados para que as informações semelhantes fiquem em um mesmo grupo. Por outro lado, as tarefas preditivas estão vinculadas a classificação e regressão, sendo que na primeira se busca atribuir categorias predefinidas aos dados, enquanto que a regressão busca prever o valor de uma saída dada outras variáveis de entrada para encontrar uma função que mapeie essa entrada, como por exemplo o valor de uma ação de uma empresa.

Os algoritmos de aprendizado de máquina supervisionado requerem que um agente externo gere rótulos de classificação para os dados no conjunto de teste e validação. Enquanto que o aprendizado de máquina não supervisionado tem a habilidade de clusterizar os resultados para um modelo mesmo sem saber as saídas desejadas [Géron \(2019\)](#). Nessa abordagem, quando novas entradas são recebidas, o algoritmo utiliza o conhecimento prévio com a finalidade de prever a categorização do novo dado.

Segundo [Monard e Prati \(2005\)](#), o aprendizado semi-supervisionado representa a junção do aprendizado supervisionado e não-supervisionado, e tem o potencial de reduzir a necessidade de exemplos rotulados quando somente um pequeno conjunto deles está disponível.

[Hagen \(2018\)](#) utilizou o algoritmo de ML Latent Dirichlet Allocation (LDA) para a modelagem de tópicos. Esse trabalho trouxe contribuições para o entendimento do processamento do *corpus* e para a compreensão do funcionamento de um algoritmo de análise de conteúdo textual.

O Algoritmo LDA é segundo seus autores [Blei, Ng e Jordan \(2003\)](#) um modelo probabilístico generativo para coleções de dados discretos como *corpus* textuais. Esta ferramenta consegue obter probabilisticamente as palavras que possuem correlação com um determinado tópico.

O trabalho de [Kang, Kim e Kang \(2019\)](#) utiliza o LDA na mineração de texto aplicado a área da bioquímica com a finalidade de identificar os principais tópicos de pesquisa e analisar quantitativamente as mudanças em suas tendências. O artigo forneceu uma ferramenta para pesquisadores e agências de financiamento entenderem melhor como

os tópicos de pesquisa se integram e se ramificam com outros temas dentro e fora da bioquímica.

Os autores [Yiran e Srivastava \(2019\)](#) trouxeram à tona o contexto de grandes *e-commerces* como a *Amazon*, a qual gera avaliações para produtos associados a diversas comunidades de usuários e consumidores. Os autores aplicaram o algoritmo [LDA](#) com o intuito de auxiliar na detecção de sentimento nesses textos, os quais geralmente são dados não estruturados que requerem uma análise minuciosa para consumidores e fabricantes extraírem informações significativas e relevantes.

Em seu trabalho, [Yiran e Srivastava \(2019\)](#) trouxeram a tona que a análise tradicional de sentimentos baseada em análise léxica considera a pontuação de polaridade das palavras, porém ignora as diferenças entre os contextos. A modelagem de tópicos em nível de documento providas pelo [LDA](#) ajuda a superar essas limitações.

Os autores [Simões e Castaños \(2020\)](#) utilizaram o [BERT](#) para detectar ideologias políticas em transcrições de debates no Congresso político dos Estados Unidos da America (EUA) de 2005. O processo de *fine-tuning* foi realizado a partir do *Bert Base Uncased* e ele obteve com resultados uma acurácia de 68% e um score F1 de 65%. Este trabalho é um exemplo de que o *BERT* pode ser utilizado para classificação de textos presentes nas redes sociais após aplicar um processo de aprendizado ao modelo para que ele seja capaz de fazer esta tarefa.

O trabalho de [Boudiaf, Ounadi e Benkhelifa \(2021\)](#) trouxe um estudo para realizar a classificação de *tweets* quanto as categorias de política, negócios, saúde, esporte, tecnologia, moda e entretenimento usando como base o modelo do [BERT](#) *BERT-based*. Durante o processo, os autores realizaram um teste com 3 etapas de pré-processamento dos dados. No primeiro passo, foram aplicadas etapas comuns como: remoção de pontuação, números e conversão para minúsculo. No segundo experimento, além de todas as etapas da primeira experimentação, os *emojis* foram convertidos em textos. Na terceira e última etapa foi realizado um experimento adicional ao aplicar a *lematização* para simplificar o *corpus* e ter menos sentenças para serem processadas no modelo *BERT*. Os melhores resultados de acurácia foram obtidos a partir do modelo que obteve o *fine-tuning* a partir do primeiro experimento, sendo este de 95%.

3 Materiais e Métodos

Este capítulo descreve a metodologia utilizada para o desenvolvimento do trabalho, abordando pontos como a seleção de páginas, quais dados foram coletados e as técnicas de tratamento e processamento utilizados nos modelos estado da arte do [BERT](#).

3.1 Seleção das páginas de mídias alternativas

Durante o trabalho de [Vasconcelos et al. \(2020\)](#), os autores utilizaram como base um conjunto de páginas de mídias alternativas disponibilizadas pelo autor [Pablo Ortellado](#)¹ para a pesquisa de análise da polarização em relação ao cenário político no *Facebook*. As páginas disponibilizadas pelo autor são extremistas e possuem forte viés ideológico. Esses perfis também podem não estar disponíveis publicamente no momento atual. Essas páginas possuem duas inclinações:

1. anti-PT, as quais possuem inclinação oposta ao [PT](#).
2. anti-anti-PT, que consistem em páginas que são contra os opositores do [PT](#).

Cada uma destas páginas presentes no arquivo foram analisadas a partir do próprio *Facebook* levando em consideração a maior frequência de postagem no período da análise em Novembro de 2021 e maior engajamento em relação a comentários por parte da audiência da página.

A Figura 1 indica um fluxograma resumido para a metodologia de seleção das páginas bases utilizadas para obter as páginas coletadas para o treinamento e validação dos modelos, a qual será descrita no decorrer da presente seção.

As 5 páginas que foram inicialmente selecionadas para cada esfera política estão indicados nas tabelas 1 e 2 mapeados por facebook id, um identificador único da página dentro do *Facebook*.

Para buscar outras páginas que tenham características análogas as páginas inicialmente sumarizadas, como: apoio para as esferas políticas e audiência no período de análise, estes perfis de mídias alternativas foram buscados na plataforma *Crowdtangle*², uma ferramenta da *Meta* com o intuito de ajudar a acompanhar, analisar e relatar o que está acontecendo nas mídias sociais. Esta ferramenta foi utilizada com a finalidade de obter

¹ <https://homepages.dcc.ufmg.br/samuel.guimaraes/ASONAM2020> - acesso em: 19/03/2022

² <https://www.crowdtangle.com>

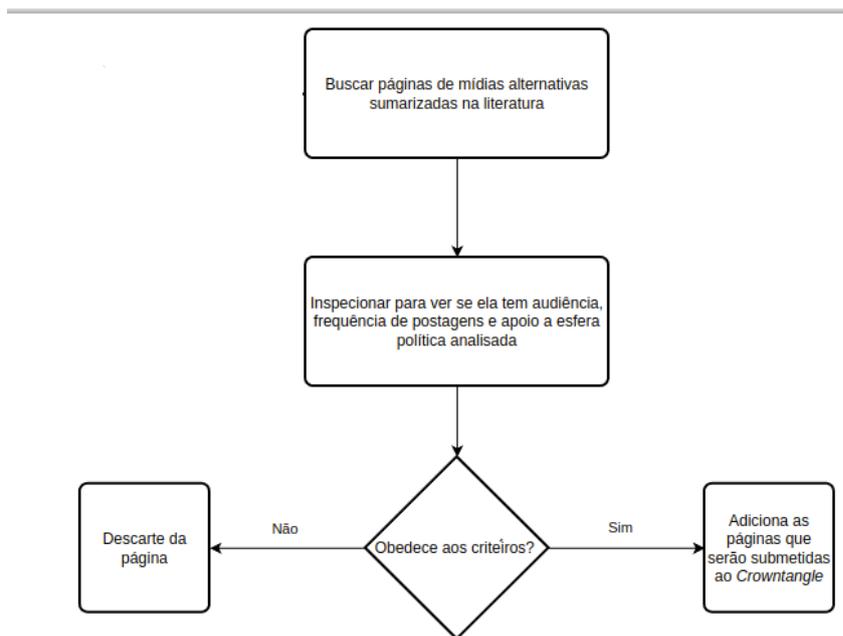


Figura 1 – Fluxograma associado a metodologia para obter as páginas base para serem aplicadas ao *Crowdtangle*

Fonte: Produzido pelo autor

Tabela 1 – Páginas inicialmente selecionadas na esfera anti-anti-PT

Página	facebook id
PT na Câmara	396614643772478
MTST - Movimento dos Trabalhadores Sem-Teto	464790330225970
Feminismo Sem Demagogia - Original	564161453675848
Todos Pela Educação - Página Oficial	128802790469337
Levante Popular da Juventude	162474053818157

Fonte: Produzido pelo autor

outras páginas que tenham aspectos equivalentes segundo a plataforma, como audiência, temas e teor nas postagens.

Dentro dos resultados do *Crowdtangle*, as 11 páginas de esquerda e direita com maiores frequências de postagem e que estavam diretamente associadas ao contexto político

Tabela 2 – Páginas previamente selecionadas na esfera anti-PT

Página	facebook id
Sargento Fahur	443913262372306
Canal da Direita	262104660600739
Movimento Brasil Livre - São Paulo	394979920626916
Jovens de Direita	1392558690986399
Magno Malta	604028822974212

Fonte: Produzido pelo autor

Tabela 3 – 14 páginas associadas a esfera anti-anti-PT com maiores frequências dentro da coleta do *Crowdtangle*

Página	facebook id	Frequência de postagens
Sou esquerda e daí?	371913239843447	1055
Diário do Centro do Mundo	1441803576032791	978
Brasil 247	167637636622585	945
Jornalistas Livres	292074710916413	920
Catraca Livre	145632722140414	681
Jovens de Esquerda	665517103649471	644
Revista Pazes	937461749665413	609
BLOG DA DILMA	219188754789679	569
Quebrando o Tabu	165205036869225	420
Revista Bula	123903924345503	352
Revista Fórum	135536083145232	348
Apoio a Policia Federal	890711084350263	199
Crítica Nacional	1022046834507026	190
Gazeta Esportiva	510628685646022	168

Fonte: Produzido pelo autor

foram selecionadas. Estas frequências foram contabilizadas a partir de um agrupamento das postagens presentes na coleta por página, ou seja, a frequência indica a quantidade de *posts* dentro do período entre 07/09/2020 e 06/10/2021.

A coleta no *Crowdtangle* possui informações em destaque como mensagem das postagens, reações *sharing* e conteúdo textual das imagens. As primeiras 14 páginas associadas ao anti-anti-PT e as primeiras 15 páginas associadas ao anti-PT com maiores frequências agrupadas por quantidade de postagens dentro da coleta estão indicados nas Tabelas 3 e 4, respectivamente. Foi realizado este processo para identificar as páginas que tiveram maior relevância e quantidade de postagens a partir da coleta na plataforma *Crowdtangle*.

Algumas páginas coletadas no *Crowdtangle*, como TecMundo, Notícias Concurso, Assembleianos de VALOR e Yahoo Brasil, foram desconsideradas, uma vez que não estão diretamente relacionadas ao contexto político. Esse padrão ocorreu principalmente em páginas ligadas à esfera política de direita, o que exigiu a inclusão de páginas com menor quantidade de posts na seleção de páginas finais a serem usadas para o treinamento e validação dos modelos.

Após a aplicação da metodologia indicada, as páginas associadas a esfera de esquerda selecionadas para o treinamento dos modelos estão indicadas na Tabela 5.

Por outro lado, na esfera de direita as páginas selecionadas usando a metodologia apresentada estão listadas na Tabela 6.

A Figura 2 indica um fluxograma resumido para a metodologia de seleção das

Tabela 4 – 15 páginas associadas a esfera anti-PT com maiores frequências dentro da coleta do *Crowdtangle*

Página	facebook id	Frequência de postagens
Pleno.News	1370679566314386	1996
TecMundo	111090485635468	1662
Notícias Concursos	309715102450026	671
Yahoo Brasil	150897358265131	646
Campo Grande News	135691029833091	641
O Antagonista	323983461125902	559
InfoMoney	204590739576667	543
Assembleianos de VALOR	428663864538931	280
Evangélicos da Ilha	252709064933674	269
Jornal Midiamax	190489027690419	258
ofuxico	162629758434	206
Apoio a Policia Federal	890711084350263	199
Crítica Nacional	1022046834507026	190
Gazeta Esportiva	510628685646022	168
Admiradores do Pr. Silas Malafaia	220890121438301	132

Fonte: Produzido pelo autor

Tabela 5 – Páginas selecionadas na esfera de esquerda

Página	facebook id
Sou esquerda e dai?	371913239843447
Diário do Centro do Mundo	1441803576032791
Brasil 247	167637636622585
Jornalistas Livres	292074710916413
Jovens de Esquerda	665517103649471
BLOG DA DILMA	219188754789679
Quebrando o Tabu	165205036869225
Revista Fórum	135536083145232
Esquerda Diário	1565130177075527
Esquerda Online	654339308067228
Rede Brasil Atual	127835925882

Fonte: Produzido pelo autor

páginas finais selecionadas para o treinamento e validação dos modelos.

3.2 Coleta de dados

Para a coleta dos dados que serão usados para o treinamento e validação dos modelos, o presente trabalho utilizou o *Facebook Graph API*³ em conjunto com a linguagem de programação *Python*. A *Application Programming Interface (API)* provida pelo *Facebook*

³ <https://developers.facebook.com/docs/graph-api/>

Tabela 6 – Páginas selecionadas na esfera de direita

Página	facebook id
Apoio a Policia Federal	890711084350263
Brasil Acima De tudo	550142935316937
Partido Brasil	448529311980229
SomostodosBolsonaro	433157527015872
O Brasil Acordou	409388089120866
Jair Bolsonaro 2022, a ultima Esperança da Nação	705782799602254
Jair bolsonaro #mito	1965770023473808
Jair Bolsonaro Presidente 2018	402760906551545
Jovens de Direita	1392558690986399
Bolsonaro Herói Nacional	1911779855707714
Operação lava Jato - eu apoio	1708330669405230

Fonte: Produzido pelo autor

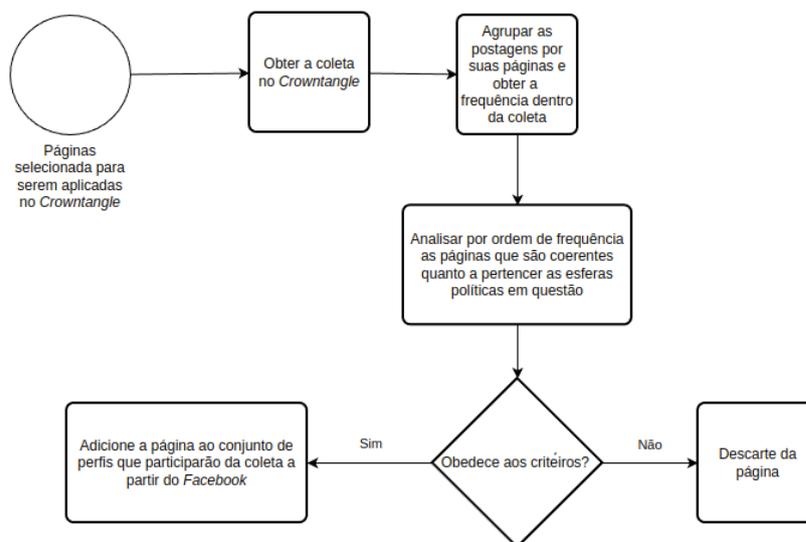


Figura 2 – Fluxograma associado a metodologia para selecionar páginas após a análise do Crowdtangle

Fonte: Produzido pelo autor

oferece um grande conjunto de *endpoints* visando prover funcionalidades, como por exemplo recursos para a coleta de posts e comentários encontrados em páginas públicas contidas na rede social.

A *Graph API* foi utilizada pois inicialmente era desejado utilizar os dados dos comentários também durante o treinamento dos modelos, podendo estes serem obtidos a partir desta ferramenta. Na versão final do projeto os comentários não foram utilizados, entretando o *Graph API* foi a ferramenta escolhida para a obtenção dos *posts*.

A linguagem de programação *Python* foi utilizada nas etapas do desenvolvimento da pesquisa graças às suas bibliotecas disponíveis e com grande utilização pela comunidade

para mineração, análise, processamento e visualização de dados. Dentre as bibliotecas presentes, algumas das principais são: *Pandas*⁴, *Matplotlib*⁵ e *Numpy*⁶.

O período dos dados coletados para o treinamento e validação dos modelos foi de 01 de Janeiro de 2018 até 17 de Outubro de 2021, contemplando eventos importantes como as Eleições Presidenciais de 2018, Eleições Municipais de 2020 e a Pandemia do Coronavírus.

Os dados dos posts foram obtidos a partir da *API* do *Facebook* no formato *JSON*, o qual segundo *Pezoa et al. (2016)* é o formato de dados mais popular para enviar solicitações e respostas de *API* e que consiste em um par de chave-valor, sendo facilmente entendido por humanos em relação a notações de mais baixo nível, como dados em formato binário. A Figura 3 representa um dos posts coletados no formato *JSON*.

```

1 {
2   "created_time": "2021-10-15T23:53:05+0000",
3   "id": "164188247072662_2364123363745795",
4   "message": "Ten #PapoNinja na área no Dia Mundial da Alimentação! Amanhã, 16 de novembro às 11h celebramos essa
data tão importante, mas infelizmente não temos muita coisa para comemorar com o recrudescimento da fome e da
miséria no Brasil e tudo mais que esse desgoverno vem fazendo na economia e na vida do povo. \nAmanhã, Dia
Mundial da Alimentação, tem #PapoNinja especial realizado pela @xepativismo e @ongfase sobre Sistemas
Alimentares: fome, corporações e alternativas, que também marca o lançamento do webdossiê de mesmo título
produzido pela FASE.\n\nParticipam Larissa Bombardi (@lartissabombardi) Fran Paula (@franpaula22) e Francisco
Menezes (@francisco.menezes.14224), com mediação de Maureen Santos (@santos.maureen). A discussão abordará a
captura dos sistemas alimentares pelas corporações geram mais fome, mais doenças e destruição ambiental e criam
ainda mais dificuldades para que as alternativas para o modelo de produção do agronegócio possa ser superado
.\n\nAcompanhe, a partir das 11h, aqui no Instagram da @midianinja.\n\n#soberaniaalimentar #sistemasalimentares
#fome #dianundialdaalimentação",
5   "shares": {
6     "count": 2
7   },
8   "status_type": "added_photos",
9   "full_picture": "https://scontent.fplu2-1.fna.fbcdn.net/v/t1.6435-9/p720x720
/246028469_2364123340412464_3879630125999972747_n.jpg?_nc_cat=102&ccb=1-5&_nc_sid=8024bb&_nc_ohc=Qe
-Vp6tyXoEAX82jrd0&_nc_ht=scontent.fplu2-1.fna&edm=AKIIGFEAAA&oh=b55dd7c8c5351ab7fec5f6754a9837c380e=61948484",
10  "reactions_like": {
11    "data": [],
12    "summary": {
13      "total_count": 20
14    }
15  },
16  "reactions_haha": {
17    "data": [],
18    "summary": {
19      "total_count": 2
20    }
21  },
22  "reactions_wow": {
23    "data": [],
24    "summary": {
25      "total_count": 0
26    }
27  },
28  "reactions_sad": {},
34  "reactions_angry": {},
40  "reactions_love": {}
46 }

```

Figura 3 – Exemplo de post coletado no formato *JSON*. As propriedades *reactions_sad*, *reactions_angry* e *reactions_love* estão minimizadas na ilustração

Fonte: Produzido pelo autor

Dentro do conjunto de dados coletados retornados pela *API*, tem se as seguintes propriedades:

- *created_time*: representando a data de criação do *post*.
- *id*: sendo este um identificador único para o *post* dentro do *Facebook*

⁴ <https://pandas.pydata.org/>

⁵ <https://matplotlib.org/>

⁶ <https://numpy.org/>

- *message*: indicando a mensagem textual adicionada pelo publicador dentro do *post*. Caso o *post* não tenha mensagem textual, essa propriedade é omitida no retorno da [API](#).
- *shares*: representando a contagem de compartilhamentos realizados por outros usuários a partir da postagem de origem.
- *status_type*: o que segundo a documentação da [API](#)⁷ é uma propriedade que indica uma descrição do tipo de *status* de atualização da postagem.
- *full_picture*: indicando uma *Uniform Resource Locator (URL)* temporária para acesso a recursos audiovisuais adicionados na postagem.
- *reactions_like*: representando o total de reações *like* na postagem.
- *reactions_haha*: indicando o total de reações *haha* no *post*.
- *reactions_wow*: representando o total de reações *wow* na publicação.
- *reactions_sad*: indicando o total de reações *sad* no *post*.
- *reactions_angry*: representando o total de reações *angry* na postagem.
- *reactions_love*: indicando o total de reações *love* na publicação.

Durante a etapa de coleta de dados, foram obtidos 76280 postagens para o corpus de mídias alternativas de esquerda. Por outro lado, foram coletados 49519 postagens em páginas que realizam jornalismo independente na esfera política de direita.

3.3 Processamento do *corpus*

No meio digital, muitas das interações entre os indivíduos são realizadas por meio de linguagem natural, como por exemplo os textos contidos em postagens e comentários gerados pelos internautas nas redes sociais. Os recursos computacionais conseguem processar estas mensagens para que possam ter seu conteúdo analisado de maneira automática.

Segundo Rosa (2011), o PLN pode ser definido como a habilidade de um computador em processar a mesma linguagem que os humanos utilizam no seu dia a dia, podendo ser aplicado em reconhecimento de falas, traduções, predições e classificações.

Oliveira et al. (2022) levantou um ponto importante em sua pesquisa sobre PLN via aprendizagem profunda, o qual utilizou como premissa que modelos treinados com textos formais podem não ser totalmente aplicados em textos informais sem um processamento adicional.

⁷ <https://developers.facebook.com/docs/graph-api/reference/post/>

Para o processamento de dados brutos, os principais processos são a remoção de vírgula, números, conversão para minúsculo e remoção de *stopwords*, as quais segundo Sarica e Luo (2021) são palavras como "cada", "sobre", "tal" e "o" que carregam poucas informações sobre a parte do texto a que pertencem. Essas etapas de processamento têm como finalidade simplificar o *corpus* linguístico mantendo ao máximo o valor semântico do conteúdo para ser utilizado durante o processamento.

Utilizando como inspiração as metodologias providas por Wang e Hu (2021), Hagen (2018) e Boudiaf, Ounadi e Benkhelifa (2021), foi realizado o processamento do *corpus* das mídias alternativas de direita e esquerda transformando os caracteres para caixa baixa e deixando as mensagens decodificadas para o *8-bit Unicode Transformation Format (UTF-8)*. O módulo do *Python re*⁸ foi utilizado junto com o *word_tokenize* para aplicar expressões regulares com o intuito de fazer este processo no *corpus* linguístico. Foi realizado também um processamento secundário levando em consideração a remoção de números, *stopwords*, URL e símbolos em adição ao processamento inicial. Durante essa etapa, o *toolkit* para processamento de linguagem natural *NLTK*⁹ foi utilizado. Um exemplo de aplicação do processamento nos textos é:

Entrada: "LAVA JATO ATRAVESSA O ATLANTICO, CHEGA EM PORTUGAL E GERA ESCANDALO INEDITO NO PAIS://goo.gl/zaUtDs"

Texto processado: "lava jato atravessa atlantico chega portugal gera escandalo inedito pais"

3.4 Coleta adicional para aplicação nos modelos com melhores métricas

Como o período de coleta dos dados para o treinamento dos modelos foi entre 01 de Janeiro de 2018 até 17 de Outubro de 2021, o presente trabalho buscou coletar um novo conjunto de dados de postagens para o período recente entre 14 de Dezembro de 2022 e 14 de Janeiro de 2023 com a finalidade de testar modelos que tiveram as melhores métricas para estudar o desempenho dentro deste novo conjunto de dados recentes.

Os dados consistem em 400 posts da esfera de direita e 400 posts da esfera de esquerda coletados no *Crowdtangle* utilizando como base 3 páginas de ambas as esferas políticas selecionadas baseado em quantidade de posts dentro do período analisado e em estarem dentro do conjunto de páginas que participaram da coleta a partir do *Facebook*, as quais estão representados nas Tabelas 7 e 8.

Para obter páginas relevantes dentro do período atualizado, foi realizada uma nova

⁸ <https://docs.python.org/3/library/re.html>

⁹ <https://www.nltk.org/>

coleta no *Crowdtangle* durante o período entre 14 de dezembro de 2022 e 14 de janeiro de 2023, utilizando as páginas de mídias alternativas que foram escolhidas para treinar e validar os modelos gerados. Verificou-se que o *Crowdtangle* retornou poucas postagens durante esse intervalo de tempo para a maioria das páginas analisadas. Como resultado, optou-se por selecionar as páginas que apresentaram o maior número de postagens durante esse período.

Tabela 7 – Páginas selecionadas na esfera de direita para a análise dos modelos com melhores métricas no conjunto de treinamento e validação

Página	facebook id	Frequência
Apoio a Policia Federal	890711084350263	298
O Brasil acordou	409388089120866	84
Jovens de Direita	100068234133822	18

Fonte: Produzido pelo autor

Tabela 8 – Páginas selecionadas na esfera de esquerda para a análise dos modelos com melhores métricas no conjunto de treinamento e validação

Página	facebook id	Frequência
Sou esquerda e dai?	371913239843447	39
Jornalistas Livres	292074710916413	344
Jovens de Esquerda	665517103649471	17

Fonte: Produzido pelo autor

3.5 BERT

Segundo Reimers e Gurevych (2019), O *BERT* é um *framework* de código aberto de *ML* para *PLN* desenvolvido pelo *Google* que usa estruturas para derivar *embeddings* de frases semanticamente significativas que podem ser comparadas usando similaridade de cosseno. Os *embeddings* são um mapeamento de sentenças para vetores de números, a fim de facilitar o processamento no universo computacional. Segundo Chen, Peng e Lu (2019), os *embeddings* tornaram uma parte essencial do *PLN* atual, especialmente junto com métodos avançados de *deep learning*. De acordo com Tenney, Das e Pavlick (2019), o *BERT* tem mostrado desempenho de ponta em muitas tarefas na área de *PLN*.

O *BERT* possui uma gama de modelos estado da arte de código aberto presentes na plataforma *huggingface*¹⁰, os quais estão disponíveis para serem utilizados. Estes modelos são derivados do *BERT* e possuem aplicações em atividades específicas ou para idiomas específicos.

¹⁰ <https://huggingface.co/>

Internamente o [BERT](#) utiliza a métrica de similaridade de cossenos para obter o índice representando o quão similar dois segmentos de textos vetorizados são. Segundo [Li e Han \(2013\)](#), essa métrica é efetivamente calculada como produto de ponto de dois vetores normalizados. Dados dois vetores \vec{v} e \vec{w} , a semelhança de cosseno entre eles é calculado da seguinte forma:

$$\text{Cosine}(\vec{v}, \vec{w}) = \frac{\vec{v} \bullet \vec{w}}{|\vec{v}||\vec{w}|} = \frac{\sum_{i=1}^N \vec{v}_i \times \vec{w}_i}{\sqrt{\sum_{i=1}^N \vec{v}_i^2} \sqrt{\sum_{i=1}^N \vec{w}_i^2}}$$

Antes de realizar a análise no algoritmo de similaridade de cosseno, será necessário realizar a codificação desses textos para vetores, já que o algoritmo de similaridade recebe como entrada vetores numéricos gerados a partir dos textos.

A Figura 4 representa a utilização da similaridade de cosseno em textos curtos com o resultado do *score* de similaridade.

Sentence 1	Sentence 2	Score
How old are you	What is your age	0.99
The food is tasty	The food is delicious	0.98
I played the chess	He was sleeping	0.00
⋮	⋮	⋮

Figura 4 – Análise da similaridade de cosseno

Fonte: [Ravichandiran \(2021\)](#)

Nos experimentos realizados por [Sun et al. \(2021\)](#), os autores criaram um *framework* que utiliza modelos auxiliares que visam melhorar o resultado da similaridade entre frases baseados no princípio de que as probabilidades de gerar duas sentenças semelhantes baseadas no mesmo contexto também devem ser semelhantes.

No trabalho de [Geetha e Karthika Renuka \(2021\)](#), as autoras utilizaram o modelo *Bert Base Uncased* com a finalidade de processar e realizar a análise de sentimentos em um dataset de 24352 reviews de produtos comprados no *e-commerce Amazon*. Os resultados do modelo *BERT* foram comparados com o *Naive-Bayes*, *Support vector machines (SVM)* e *Long short-term memory (LSTM)*. Os resultados do trabalho demonstram que o *Bert Base Uncased* obteve resultados melhores nas métricas de Precisão (*Precision*), Revocação (*Recall*), Medida F (*F-Measure*) e Acurácia (*Accuracy*).

Em relação as métricas utilizadas por [Geetha e Karthika Renuka \(2021\)](#), um maior resultado de Precisão representa menos falso positivos na predição do modelo. A Precisão está indicada na equação a seguir:

$$\text{Precisão } (P) = \frac{\text{VerdadeirosPositivos}}{\text{VerdadeirosPositivos} + \text{FalsoPositivos}}$$

Por outro lado, a métrica de Revocação traz à tona a sensibilidade do classificador. O aumento desse resultado representa uma menor quantidade de falso negativo a partir da predição do modelo. A equação da métrica está sendo exibida a seguir:

$$\text{Revocação } (R) = \frac{\text{VerdadeirosPositivos}}{\text{VerdadeirosPositivos} + \text{FalsoNegativos}}$$

A métrica de Medida F é indicada por [Geetha e Karthika Renuka \(2021\)](#) como sendo a média harmônica entre a Precisão e a Revocação. O resultado tem como melhor valor 1 e pior 0. A equação está descrita a seguir:

$$\text{MedidaF } (F1) = \frac{2 * \text{Precisão} * \text{Revocação}}{\text{Precisão} + \text{Revocação}}$$

A métrica de Especificidade (*Specificity*) tem como objetivo indicar a proporção de previsões negativas corretas em relação ao número total de observações verdadeiramente negativas, ou seja, ela representa a capacidade do modelo em detectar corretamente as observações negativas as quais não pertencem à classe de interesse.

$$\text{Especificidade } (S) = \frac{\text{VerdadeirosNegativos}}{\text{VerdadeirosNegativos} + \text{FalsoPositivos}}$$

O Resultado de Acurácia é indicado como sendo razão entre o resultado corretamente previsto e o total de predições. A equação está descrita a seguir:

$$\text{Acurácia } (A) = \frac{\text{VerdadeirosPositivos} + \text{VerdadeirosNegativos}}{\text{Total}}$$

As métricas apresentadas pelo trabalho de [Geetha e Karthika Renuka \(2021\)](#) serão utilizadas para mensurar o desempenho dos modelos treinados para a classificação dos posts de redes sociais do presente trabalho.

Durante a etapa de treinamento, será visto também a métrica da perda (*loss*), a qual é usada para avaliar como um modelo de aprendizado se ajusta aos dados de treinamento. Segundo [Ishida et al. \(2020\)](#), ao aumentar o número de épocas a perda de treinamento tenderá a diminuir e pode se tornar quase zero.

3.6 Seleção de modelos estado da arte

O *huggingface* é uma plataforma de código aberto que contém uma grande gama de modelos *BERT* disponíveis para serem utilizados pela comunidade. Durante o aprendizado do funcionamento do *BERT*, houve tentativas e testes com os seguintes modelos estado da arte: *all-MiniLM-L6-v2*¹¹, *distilbert-base-uncased*¹², *distilbert-base-multilingual-cased*¹³, *bert-base-uncased*¹⁴ e o *neuralmind/bert-base-portuguese-cased*¹⁵.

Dado o sucesso de Geetha e Karthika Renuka (2021) na análise de sentimentos com o *Bert Base Uncased*, esse modelo foi selecionado para realizar o processo de *fine-tuning* variando os parâmetros de treinamento. Os autores Devlin et al. (2018a) trouxeram este modelo após um pré-treinamento baseado em 11038 livros não publicados no *BookCorpus*¹⁶ e no *Wikipédia*¹⁷ em inglês. Segundo os autores, o modelo consegue realizar tomada de decisões como classificação de sequência e resposta a perguntas para textos de entrada em caixa baixa ou alta.

No trabalho de Souza, Nogueira e Lotufo (2020) foi desenvolvido o *BERTimbau*, o qual é um modelo adaptado para a língua portuguesa, trazendo a tona novas possibilidades de uso do *BERT* para o idioma Português do Brasil (PT-BR). Devido a esse modelo ser otimizado para o idioma do *corpus*, o *neuralmind/bert-base-portuguese-cased* também foi selecionado para fazer parte do processo de treinamento e testes para a classificação de textos presentes em mídias sociais. Segundo os autores, o *BERTimbau* utilizou dados do *brWaC*¹⁸ (*Brazilian Web as Corpus*) como base de treinamento. Ele contém 2.68 bilhões de *tokens* em 3.53 milhões de documentos com alta diversidade de conteúdos e áreas, garantindo assim características desejáveis para a utilização no treino do modelo *BERT*. Ainda segundo Souza, Nogueira e Lotufo (2020), o *BERTimbau* foi desenvolvido principalmente para as tarefas de similaridade de sentenças e reconhecimento de implicação textual.

Os dois modelos selecionados são de código aberto e estão disponíveis para serem treinados para novas atividades. Esse processo é conhecido como *fine-tuning* e foi utilizado por Vucetic et al. (2022) em testes para demonstrar a importância dos modelos modernos terem a flexibilidade de se adaptar a novos ambientes.

¹¹ <https://huggingface.co/sentence-transformers/all-MiniLM-L6-v2>

¹² <https://huggingface.co/distilbert-base-uncased>

¹³ <https://huggingface.co/distilbert-base-multilingual-cased>

¹⁴ <https://huggingface.co/bert-base-uncased>

¹⁵ <https://huggingface.co/neuralmind/bert-base-portuguese-cased>

¹⁶ <https://paperswithcode.com/dataset/bookcorpus>

¹⁷ https://en.wikipedia.org/wiki/Main_Page

¹⁸ <https://huggingface.co/datasets/brwac>

3.7 *fine-tuning* dos modelos selecionados

Em seu trabalho, Hammes e Freitas (2021) indicaram que o processo de *fine-tuning* é uma técnica de *transfer learning* em que partindo de um modelo pré-treinado em uma tarefa de conhecimento, os parâmetros desse modelo de ML são ajustados para uma nova tarefa.

As tecnologias utilizadas em conjunto com a linguagem *Python* na presente etapa foram as bibliotecas *pytorch*¹⁹ com a finalidade de utilizar módulos que auxiliaram no tratamento e treinamento dos modelos durante a etapa de *fine-tuning*. A biblioteca *transformers*²⁰ também foi manuseada com o intuito de realizar o *download* de modelos estado da arte a partir do *huggingface*. O módulo de partição da base em treinamento e validação do *sklearn*²¹ também serviu como instrumento com a finalidade de realizar a divisão da base de dados utilizada na presente etapa.

Com os modelos estado da arte selecionados, a pesquisa buscou uma metodologia para balancear os dados das postagens coletados com a finalidade do classificador desenvolvido não ficar desequilibrado para algumas das esferas políticas.

A fim de manter a base de treinamento balanceada, foram selecionados aleatoriamente 30668 postagens de mídias alternativas com conteúdo textual de direita e 30396 postagens com conteúdo textual de esquerda. No entanto, é importante mencionar que dentro do conjunto de *posts*, há aqueles que não possuem mensagem textual direta, ou seja, são *posts* que em seu conteúdo possuem somente uma figura e não um texto explícito. A quantidade de *posts* de direita com conteúdo textual é de 38335 dentro dos 49519 posts coletados, enquanto que a quantidade de *posts* com mensagem textual de esquerda são 67541 dentro do conjunto de 76280 *posts* coletados.

O trabalho utilizou uma abordagem de ML supervisionada, em que *labels* foram adicionados em cada uma das postagens processadas para auxiliar os modelos estado da arte *bert-base-uncased* e *neuralmind/bert-base-portuguese-cased* durante o processo de aprendizagem. O rótulo 0 foi adicionado as postagens de esquerda enquanto a *label* 1 foi indicada nos *posts* de direita, conforme indicado na Figura 5. Os métodos utilizados para processamento foram baseados nas instruções de como treinar um modelo BERT presentes no trabalho de Albanese (2022).

Durante a etapa de treinamento, foi realizada uma separação de 80% dos 61061 posts totais para o treinamento do modelo e 20% para validação durante esta etapa. Isso ocorreu devido a outro trabalho presente na literatura como Vries et al. (2019) também ter utilizado 80% da base de dados como treinamento. Após a identificação do

¹⁹ <https://pytorch.org/>

²⁰ <https://huggingface.co/docs/transformers/index>

²¹ <https://scikit-learn.org/stable/>

message_min_processed	shares	status_type	full_picture	reactions_like	reactions_haha	reactions_wow	reactions_sad	reactions_angry	reactions_love	has_textual_message	author	label
agora pouco no metro carroca (o ato pro lula	556	added_video	https://content.fbclid-1.fba.fbcdn.net/v115.5...	576	1	5	0	3	91	True	left_all_posts	0
as agencias reguladoras da europa so recediam...	67	shared_story	https://external.fbclid-1.fba.fbcdn.net/safe_im...	75	2	5	5	51	0	True	left_all_posts	0
os cientistas observaram taxas mais altas de v...	41	shared_story	https://external.fbclid-1.fba.fbcdn.net/safe_im...	129	5	2	1	1	0	True	left_all_posts	0
cultura palavra e resistencia - programa dem...	8	added_video	https://content.fbclid-1.fba.fbcdn.net/v115.5...	30	1	1	0	0	4	True	left_all_posts	0
jogo sup pelo whatsapp: a eleicao de bolsonaro...	617	added_video	https://content.fbclid-1.fba.fbcdn.net/v115.5...	467	2	6	2	5	52	True	left_all_posts	0
...
vamos fazer esse video bombar !!! compartil...	4	mobile_status_update	None	38	0	0	0	0	5	True	right_all_posts	1
um show de boneiras cuminando com " e por ca	26	shared_story	https://external.fbclid-1.fba.fbcdn.net/safe_im...	49	31	3	3	50	0	True	right_all_posts	1
se nao for assim eu nem caso	70	added_photos	https://content.fbclid-1.fba.fbcdn.net/v115.64...	45	8	1	0	0	6	True	right_all_posts	1
hang nao pega leve	262	shared_story	https://external.fbclid-1.fba.fbcdn.net/safe_im...	2029	200	4	0	3	125	True	right_all_posts	1
discurso historico do presidente jaé bolsonaro...	949	added_video	https://content.fbclid-1.fba.fbcdn.net/v115.5...	1605	9	10	1	4	320	True	right_all_posts	1

Figura 5 – Demonstrando a Label 0 para posts de páginas de esquerda e 1 para posts de páginas de direita.

Fonte: Produzido pelo autor

desbalanceamento inicial entre posts de direita e esquerda, parte do conjunto de posts restante fora a base de treinamento será utilizado como testes de *performance* dos modelos. Nesta etapa, também foi escolhido o tamanho dos batches como sendo 16, devido a estar dentro da faixa de recomendação dos autores [Devlin et al. \(2018b\)](#). Segundo [Brownlee \(2018\)](#), o número de *batches* indica o número de amostras a serem trabalhadas antes de atualizar os parâmetros internos do modelo.

O *optimizer* utilizado durante o *fine-tuning* foi o *Adam*, proposto no trabalho de [Kingma e Ba \(2014\)](#). Os valores deste otimizador ajudam a potencializar o treinamento e a melhorar a eficiência e a velocidade do processo de treinamento. O *optimizer* utilizado também foi uma recomendação dos autores [Devlin et al. \(2018b\)](#).

Para o treinamento dos modelos, o hiper parâmetro variado foi o número de épocas. O trabalho de [Devlin et al. \(2018b\)](#) recomenda a utilização de 2, 3 e 4 épocas durante esta etapa. Portanto, foi realizada uma análise exploratória visando entender qual a quantidade ideal para ser utilizado no processo de *fine-tuning* realizado para a classificação de posts de mídias sociais em esquerda e direita. Segundo [Brownlee \(2018\)](#), a quantidade de épocas é um hiper parâmetro que representa o número de vezes que o algoritmo de aprendizado precisa executar em todo o conjunto de dados de treinamento. A Tabela 9 indica um resumo dos parâmetros utilizados no processo de *fine-tuning* dos modelos.

Tabela 9 – Hiper parâmetros usados na etapa de *fine-tuning* dos modelos estado da arte do BERT

hiper parâmetros	
<i>Número de lotes (batches)</i>	16
<i>Número de épocas (epochs)</i>	[2,3,4]
Otimizador	<i>Adam</i>

Fonte: Produzido pelo autor

Os experimentos foram realizados na plataforma *Google Colaboratory*²², um produto do *Google* que permite que usuários escrevam e executem códigos *Python* pelo navegador. Essa ferramenta é utilizada em tarefas de análise de dados e [ML](#).

Durante a etapa de validação, foram selecionados aleatoriamente um total de 37678 posts, caracterizados em 30394 mensagens de esquerda e 7284 de direita. Estes posts estão fora do conjunto de 61061 utilizados durante a etapa de treinamento.

Após o processo de *fine-tuning*, é possível obter o rótulo de um novo texto de entrada codificando-o em *embeddings* e utilizando-o como entrada do modelo. Dois exemplos de processamento de novos textos de entrada podem ser observados na Tabela 10, representando a predição do modelo para os textos de entrada 'bolsonaro ruim' e 'bolsonaro bom'. O código para a predição da classificação de um novo texto de entrada está disponível no Apêndice B. Os algoritmos completos utilizados para o processo de *fine-tuning* dos modelos treinados estão presentes no *Github*²³, que é uma plataforma *online* onde os usuários podem armazenar, gerenciar, controlar versões e compartilhar seu código-fonte.

Tabela 10 – Análise da entrada e saída a partir do modelo durante o processo de classificação

Texto de Entrada	Predição do Modelo
bolsonaro ruim	Esquerda
bolsonaro bom	Direita

Fonte: Produzido pelo autor

²² <https://colab.research.google.com/>

²³ <https://github.com/LucasPereiraMiranda/fine-tuned-BERT-models-for-political-leaning-detection>

4 Resultados

A presente etapa apresenta a caracterização da coleta base realizada para o treinamento dos modelos e um estudo sobre o desempenho dos algoritmos desenvolvidos baseados no *bert-base-uncased* e *neuralmind/bert-base-portuguese-cased* gerados após o processo de *fine-tuning*. Nesse capítulo são demonstrados as métricas obtidas durante o treinamento e um estudo do modelo com melhor *performance* dentro de *posts* recentes publicados por mídias alternativas.

4.1 Caracterização dos dados coletados para o treinamento e validação dos modelos

A presente seção visa caracterizar os posts coletados para a etapa de treinamento e validação a partir da *Graph API* entre o período de 01 de Janeiro de 2018 até 17 de Outubro de 2021.

Dentro do conjunto de dados coletados das páginas de esquerda foram obtidas 76280 postagens. A Tabela 11a representa a divisão dos posts por página. A Tabela 12a indica um panorama geral do número de *likes* em posts nas mídias alternativas de esquerda por ano. É possível observar na Tabela 13a um panorama geral do total de reações, incluindo *likes*, *shares*, *sad*, *wow*, *angry* e *love*. De forma geral, o corpus coletado das mídias alternativas de esquerda possuem 67541 posts com mensagens textuais e 8739 posts sem mensagens textuais diretas, contendo imagens e vídeos, exclusivamente.

Tabela 11 – Métricas associadas a quantidade de posts por página coletada no *Facebook* para o treinamento e validação dos modelos

Página	Quantidade de posts
Esquerda Diário	7193
Diário do centro do mundo	7182
Revista Forum	7135
Jornalistas Livres	7020
Jovens de esquerda	6970
Rede Brasil Atual	6943
Brasil 247	6912
Esquerda Online	6842
Quebrando o tabu	6797
Sou esquerda e daí?	6703
Blog da Dilma	6583

(a) Número de posts de esquerda por página

Página	Quantidade de posts
SomostodosBolsonaro	6889
Brasil acima de tudo	6436
Jair Bolsonaro Presidente 2018	5690
jair bolsonaro mito	5001
Bolsonaro Heroi Nacional	4496
Apoio a Polícia Federal	6289
Partido Brasil	6208
O Brasil Acordou	3649
jovens de direita	3036
Jair Bolsonaro 2022 a ultima esperança da Nação	1393
Operação lava jato - eu apoio	432

(b) Número de posts de direita por página

Fonte: Produzido pelo autor

Realizando a análise do conjunto de dados coletados das páginas de direita foram obtidas 49519 postagens. A Tabela 11b representa a divisão dos posts por página. Ao analisar a Tabela 12b, pode-se observar um panorama geral do número de *likes* em posts

Tabela 12 – Métricas associadas a quantidade de likes por ano coletadas no *Facebook* para o treinamento e validação dos modelos

Ano	Número total de likes	Ano	Número total de likes
2018	31.19 M	2018	15.62 M
2019	24.72 M	2019	20.87 M
2020	29.28 M	2020	26.52 M
2021	27.88 M	2021	27.94 M

- (a) Número de likes em *posts* presentes em páginas de esquerda por ano
- (b) Número de likes em *posts* presentes em páginas de direita por ano

Fonte: Produzido pelo autor

Tabela 13 – Métricas associadas a quantidade de reações por ano em páginas coletadas no *Facebook* para o treinamento e validação dos modelos

Ano	Número total de reações	Ano	Número total de reações
2018	87.89 M	2018	42.95 M
2019	57.85 M	2019	40.62 M
2020	60.70 M	2020	39.61 M
2021	52.85 M	2021	38.10 M

- (a) Número de reações em *posts* presentes em páginas de esquerda por ano
- (b) Número de reações em *posts* presentes em páginas de direita por ano

Fonte: Produzido pelo autor

nas mídias alternativas de direita por ano. Ao verificar a Figura 13b, é possível identificar um panorama geral do total de reações, incluindo *likes*, *shares*, *sad*, *wow*, *angry* e *love*. De forma geral, o *corpus* coletado das mídias alternativas de direita possuem 38335 posts com mensagens textuais e 11184 posts sem mensagens textuais diretas, contendo imagens e vídeos, exclusivamente.

4.2 Resultados do processo de *fine-tuning*

A presente seção tem como objetivo trazer os resultados com o *bert-base-uncased* e o *neuralmind/bert-base-portuguese-cased* nas etapas de treinamento e validação. Nesta etapa são demonstrados também os resultados dos modelos com melhores métricas em um conjunto atualizado de posts para mensurar se o modelo tem métricas eficientes dentro de postagens recentes.

Nesta seção, também são apresentadas as matrizes de confusão binárias geradas após o processo de validação do *fine-tuning*, a fim de ilustrar a distribuição dos resultados dos modelos. Segundo Raschka (2014), as matrizes de confusão binárias são uma maneira concisa de avaliar o desempenho de um classificador para tarefas de classificação em duas classes distintas. A matriz quadrada é composta por colunas e linhas que representam o número de instâncias classificadas corretamente ou incorretamente em relação à "classe

real"versus "classe prevista", podendo ser expressa em valores absolutos ou relativos.

A Tabela 14 apresenta a convenção das classes presentes na matriz de confusão no contexto do presente trabalho, que são divididas em duas categorias: *post* de direita (D) e *post* de esquerda (E). Para cada categoria, há duas possibilidades de predição: verdadeira ou falsa. Os elementos da matriz que correspondem às predições corretas para a classe real *post* de direita são representados por **VD**, enquanto os elementos que correspondem às predições erradas são representados por **FD**. De maneira semelhante, os elementos da matriz que correspondem às predições corretas e erradas para a classe real *post* de esquerda são representados por **VE** e **FE**, respectivamente.

Tabela 14 – Convenção utilizada na matriz de confusão

		Predicted label	
		d	e
True label	D	VD	FE
	E	FD	VE

Fonte: Produzido pelo autor

4.2.1 Resultados com o *bert-base-uncased*

4.2.1.1 Etapa de treinamento

A Tabela 15 indica o desempenho dos modelos gerados a partir do *bert-base-uncased* durante a etapa de treinamento utilizando 2, 3 e 4 épocas. Ao utilizar 2, épocas foram obtidos resultados instáveis, como por exemplo uma perda no treinamento (*loss*) crescente entre a primeira e a segunda etapa, o que não está de acordo com as características para esta situação, conforme indicado por [Ishida et al. \(2020\)](#). Na segunda etapa foi possível ver uma revocação de 1 e uma especificidade de 0 podendo indicar que o modelo passou por *underfitting* não conseguindo se ajustar bem aos dados de treinamento utilizando este hiper parâmetro. Foram levantadas hipóteses como o modelo ser baseado na língua inglesa, necessitando ainda de mais aprendizagem para se adaptar ao *corpus* na língua portuguesa PT-BR.

Durante 3 e 4 épocas de treinamento, foi possível identificar que o modelo teve características mais coerentes, como por exemplo um decréscimo na perda (*loss*) no decorrer das etapas e uma acurácia mais estável no decorrer do processo de treinamento.

Tabela 15 – Métricas dos modelos gerados a partir do *bert-base-uncased* na etapa de treinamento

Métricas	bert-base-uncased								
	2 épocas		3 épocas			4 épocas			
	Etapa 1	Etapa 2	Etapa 1	Etapa 2	Etapa 3	Etapa 1	Etapa 2	Etapa 3	Etapa 4
Perda (loss)	0.5350	0.6182	0.5072	0.3986	0.3341	0.4859	0.3708	0.2877	0.2043
Acurácia	0.7869	0.5022	0.7902	0.7937	0.8146	0.8079	0.8224	0.8189	0.8204
Precisão	0.8331	0.5022	0.8383	0.8660	0.7760	0.7884	0.8390	0.8195	0.8195
Revocação	0.7176	1	0.7237	0.6999	0.8902	0.8366	0.7926	0.7754	0.8177
Especificidade	0.8561	0	0.8552	0.8862	0.7399	0.7790	0.8517	0.8624	0.8227
Medida F	0.7710	0.6686	0.8466	0.7741	0.8291	0.8117	0.7926	0.7968	0.8185

Fonte: Produzido pelo autor

4.2.1.2 Etapa de validação

A Tabela 16 indica as matrizes de confusão trazendo o desempenho dos modelos gerados a partir do *bert-base-uncased* durante a etapa de validação utilizando 2, 3 e 4 épocas. Foi possível perceber resultados instáveis no processo de validação para 2 épocas de forma análoga a etapa de treinamento, como por exemplo uma quantidade de 0 acertos no conjunto de esquerda e 30394 erros, enquanto que dentro do conjunto de posts de direita ele obteve 7284 acertos e 0 erros, indicando que o modelo gerado com 2 épocas de treinamento baseado no *bert-base-uncased* classificou qualquer entrada como posts de direita.

Ao analisar o desempenho dos modelos com 3 e 4 épocas foi possível notar que houve um resultado mais condizente e real, como por exemplo a validação do modelo gerado com 4 épocas, o qual trouxe 25039 acertos no conjunto de esquerda e 5355 erros, por outro lado, este modelo acertou 6013 posts no conjunto de direita e errou 1271 vezes no conjunto de validação. A Tabela 17 indica as métricas dos modelos gerados a partir do *bert-base-uncased* na etapa de validação, trazendo resultados coerentes ao analisar as métricas com 4 épocas.

Tabela 16 – Matrizes de confusão para os modelos baseados no *bert-base-uncased* na etapa de validação

		Predicted label				Predicted label				Predicted label	
		D	E			D	E			D	E
True label	D	7284	0	True label	D	6501	783	True label	D	6013	1271
	E	30394	0		E	8209	22185		E	5355	25039
		d	e			d	e			d	e
		(a) 2 épocas				(b) 3 épocas				(c) 4 épocas	

Fonte: Produzido pelo autor

Tabela 17 – Métricas dos modelos gerados a partir do *bert-base-uncased* na etapa de validação

bert-base-uncased			
	2 épocas	3 épocas	4 épocas
Acurácia	0.1933	0.7613	0.8241
Precisão	0.1933	0.4419	0.5289
Revocação	1	0.8925	0.8255
Especificidade	0	0.7299	0.8238
Medida F	0.3239	0.5911	0.6447

Fonte: Produzido pelo autor

4.2.2 Resultados com o *neuralmind/bert-base-portuguese-cased*

4.2.2.1 Etapa de treinamento

A Tabela 18 indica o desempenho dos modelos gerados a partir do *neuralmind/bert-base-portuguese-cased* durante a etapa de treinamento utilizando 2, 3 e 4 épocas. Foi possível perceber uma diminuição na métrica de perda no treinamento (*loss*) no decorrer das etapas. Os modelos tiveram índices próximos de acurácia, precisão, revocação, especificidade e medida F no decorrer das épocas, indicando que variar o número de épocas pode não ser determinante para o processo de *fine-tuning* do *neuralmind/bert-base-portuguese-cased* no contexto de classificação de dados políticos nas redes sociais.

Tabela 18 – Métricas dos modelos gerados a partir do *neuralmind/bert-base-portuguese-cased* na etapa de treinamento

neuralmind/bert-base-portuguese-cased									
Métricas	2 épocas		3 épocas			4 épocas			
	Etapa 1	Etapa 2	Etapa 1	Etapa 2	Etapa 3	Etapa 1	Etapa 2	Etapa 3	Etapa 4
Perda (<i>loss</i>)	0.4097	0.2771	0.4126	0.2821	0.1900	0.4133	0.2758	0.2289	0.1439
Acurácia	0.8498	0.8628	0.8481	0.8582	0.8565	0.8474	0.8567	0.8573	0.8536
Precisão	0.8273	0.8454	0.8231	0.8371	0.8297	0.8551	0.8274	0.8629	0.8250
Revocação	0.8883	0.8882	0.8869	0.8890	0.8986	0.8407	0.9020	0.8533	0.9009
Especificidade	0.8111	0.8362	0.8057	0.8234	0.8138	0.8557	0.8128	0.8635	0.8084
Medida F	0.8567	0.8662	0.8538	0.8622	0.8627	0.8478	0.8630	0.8580	0.8612

Fonte: Produzido pelo autor

4.2.2.2 Etapa de validação

A Tabela 19 indica as matrizes de confusão contendo um resumo do desempenho dos modelos gerados a partir do *neuralmind/bert-base-portuguese-cased* durante a etapa de validação utilizando 2, 3 e 4 épocas. Foi possível perceber que para ambas as épocas o modelo teve quantidades de acertos e erro muito próximas, entretanto o modelo que passou pelo processo de *fine-tuning* com 2 épocas teve uma melhor acurácia, por exemplo, conforme indicado na Tabela 20, que traz as métricas dos modelos gerados a partir do *neuralmind/bert-base-portuguese-cased* na etapa de validação.

Tabela 19 – Matrizes de confusão para os modelos baseados no *neuralmind/bert-base-portuguese-cased*

		Predicted label	
		d	e
True label	D	6472	812
	E	4871	25523

(a) 2 épocas

		Predicted label	
		d	e
True label	D	6503	781
	E	5704	24690

(b) 3 épocas

		Predicted label	
		d	e
True label	D	6013	1271
	E	5355	25039

(c) 4 épocas

Fonte: Produzido pelo autor

Tabela 20 – Métricas dos modelos gerados a partir do *neuralmind/bert-base-portuguese-cased* na etapa de validação

neuralmind/bert-base-portuguese-cased			
	2 épocas	3 épocas	4 épocas
Acurácia	0.8492	0.8279	0.8241
Precisão	0.5706	0.5327	0.5289
Revocação	0.8885	0.8928	0.8255
Especificidade	0.8397	0.8123	0.8238
Medida F	0.6949	0.6672	0.6812

Fonte: Produzido pelo autor

4.2.3 Comparação entre os modelos treinados

Após a análise das métricas, foi possível identificar que em relação ao modelo base *bert-base-uncased*, o modelo gerado que obteve melhor desempenho foi o algoritmo gerado a partir de 4 épocas de treinamento. Este modelo obteve características mais coerentes em relação aos demais modelos gerados no presente trabalho a partir do *bert-base-uncased*, como uma consistência maior nas métricas e melhores índices durante a etapa de validação.

Em relação ao processo de fine-tuning do modelo *BERT neuralmind/bert-base-portuguese-cased*, o *fine-tuning* que obteve melhor desempenho foi o que passou pelo processo com 2 épocas, já que ele obteve melhores medidas em acurácia, precisão, especificidade e medida F.

4.3 Validação adicional dos modelos com melhor desempenho

Conforme indicado na Seção 3.4, dados recentes de mídias alternativas com forte viés político de direita e esquerda foram aplicados nos modelos com melhores desempenhos durante nas etapas de treinamento e validação, conforme indicado a seguir.

4.3.1 Validação adicional do modelo gerado a partir do *bert-base-uncased* com 4 épocas

Os 800 posts recentes foram aplicados no modelo gerado a partir do *bert-base-uncased*, obtendo as métricas indicadas na Tabela 21. Por outro lado, a Tabela 22 indica a matriz de confusão com o mapeamento dos acertos e erros dentro deste novo conjunto de postagens.

Tabela 21 – Métricas do modelo gerado a partir do *fine-tuning* do *bert-base-uncased* com 4 épocas de treinamento no conjunto adicional de posts

bert-base-uncased	
Acurácia	0.7113
Precisão	0.7407
Revocação	0.6500
Especificidade	0.7725
Medida F	0.6923

Fonte: Produzido pelo autor

Tabela 22 – Matriz de confusão associada ao modelo gerado a partir do *fine-tuning* do *bert-base-uncased* no conjunto adicional de posts

		Predicted label	
		d	e
True label	D	260	140
	E	91	309

Fonte: Produzido pelo autor

4.3.2 Validação adicional do modelo gerado a partir do *neuralmind/bert-base-portuguese-cased* com 2 épocas

Os posts recentes também foram aplicados no modelo gerado a partir do *neuralmind/bert-base-portuguese-cased* com a finalidade de obter as métricas indicadas na Tabela 23. De forma análoga, a Tabela 24 indica a matriz de confusão com o mapeamento dos acertos e erros dentro deste novo conjunto de postagens.

Tabela 23 – Métricas do modelo gerado a partir do *fine-tuning* do *neuralmind/bert-base-portuguese-cased* com 2 épocas de treinamento no conjunto adicional de posts

neuralmind/bert-base-portuguese-cased	
Acurácia	0.7425
Precisão	0.7904
Revocação	0.6600
Especificidade	0.8250
Medida F	0.7193

Fonte: Produzido pelo autor

Tabela 24 – Matriz de confusão associada ao modelo gerado a partir do *fine-tuning* do *neuralmind/bert-base-portuguese-cased* no conjunto adicional de posts

		Predicted label	
True label	D	264	136
	E	70	330
		d	e

Fonte: Produzido pelo autor

5 Conclusão

Com a crescente quantidade de dados gerados nas mídias sociais, analisar o conteúdo de forma sistematizada se tornou um estudo muito relevante para organizações e pesquisadores. Entender comportamentos e interações nas redes pode ajudar a compreender o que grupos existentes na mídia pensam e reagem acerca dos assuntos discutidos. No contexto político, as mídias alternativas podem ter grande alcance e impacto sobre os integrantes das redes ao levar os seus conteúdos. Utilizar os dados dessas mídias para gerar modelos capazes de classificar outros posts presentes nas redes pode ser um ponto de partida para existir cada vez mais ferramentas para analisar o conteúdo político presente nas redes no cada vez mais polarizado cenário político brasileiro.

Durante o trabalho, foi utilizada uma metodologia para seleção de páginas de mídias alternativas. O conteúdo textual das postagens presentes nas páginas selecionadas foram aplicados em modelos [BERT](#) já presentes na literatura, a fim de gerar novos modelos por meio do processo de *fine-tuning*, adaptados para classificar outras postagens nas redes sociais. O modelo base do [BERT](#) baseado na língua inglesa necessitou de mais épocas de treinamento para conseguir classificar *posts* associados a esquerda. Isso ocorreu devido o modelo *bert-base-uncased* não ter um suporte direto para a língua portuguesa [PT-BR](#). Com 3 e 4 épocas foram obtidos resultados satisfatórios em relação a 2 épocas após o modelo base ter aprendido sobre o novo contexto em [PT-BR](#) no qual ele foi exposto. Ao comparar com outros trabalhos presentes na literatura, a acurácia de 68% obtida pelos autores [Simões e Castaños \(2020\)](#) na detecção de ideologias políticas foi próxima ao resultado de 74,25% obtido pelo modelo gerado a partir do *fine-tuning* do algoritmo *neuralmind/bert-base-portuguese-cased* com 2 épocas de treinamento. Ao analisar os modelos com melhores desempenhos em posts recentes, os resultados indicam que os modelos baseados em [BERT](#) podem ser utilizados para classificações no contexto político.

Como sequência deste trabalho, os modelos com melhor desempenho podem ser utilizados para serem aplicados em períodos eleitorais específicos, a fim de identificar como a polarização foi caracterizada no período analisado. A fim de disponibilizar esta análise para outros pesquisadores, jornalistas e cientistas, pode ser gerada uma ferramenta [WEB](#) baseada nos modelos a fim de classificar conteúdos no cenário político. Uma outra sugestão é criar modelos que utilizem mais rótulos além de direita e esquerda com a finalidade de buscar outras classificações mais específicas dentro do âmbito político como centro, por exemplo.

Referências

- AHARONI, M. When mainstream and alternative media integrate: A polysystem approach to media system interactions. *Television & New Media*, v. 0, n. 0, p. 15274764221123036, 2021. Disponível em: <<https://doi.org/10.1177/15274764221123036>>. Citado 2 vezes nas páginas 15 e 19.
- ALBANESE, N. C. *Fine-Tuning BERT for Text Classification*. 2022. Acessado em: 01 Ago. de 2022. Disponível em: <<https://towardsdatascience.com/fine-tuning-bert-for-text-classification-54e7df642894>>. Citado na página 35.
- BLEI, D. M.; NG, A. Y.; JORDAN, M. I. Latent dirichlet allocation. *J. Mach. Learn. Res.*, JMLR.org, v. 3, n. null, p. 993–1022, mar 2003. ISSN 1532-4435. Citado na página 21.
- BOUDIAF, M.; OUNADI, I.; BENKHELIFA, Y. Tweets categorization using fine-tuned bert model. *1st National Conference on Applied Science and Advanced Materials*, 2021. Disponível em: <https://www.researchgate.net/profile/Moussa-Hadjer/publication/357702629_Tweets_Categorization_using_Fine-tuned_BERT_Model/links/61dc1c094e4aff4a642f97cf/Tweets-Categorization-using-Fine-tuned-BERT-Model.pdf>. Citado 2 vezes nas páginas 22 e 30.
- BOYLE, M. P.; SCHMIERBACH, M. Media use and protest: The role of mainstream and alternative media use in predicting traditional and protest participation. *Communication Quarterly*, Routledge, v. 57, n. 1, p. 1–17, 2009. Disponível em: <<https://doi.org/10.1080/01463370802662424>>. Citado na página 18.
- BROWNLEE, J. What is the difference between a batch and an epoch in a neural network. *Machine Learning Mastery*, v. 20, 2018. Citado na página 36.
- CERRI, R.; CARVALHO, A. Aprendizado de máquina: breve introdução e aplicações. *Cadernos de Ciência & Tecnologia*, v. 34, n. 3, p. 297–313, 2017. Citado na página 21.
- CHEN, Q.; PENG, Y.; LU, Z. Biosentvec: creating sentence embeddings for biomedical texts. In: *2019 IEEE International Conference on Healthcare Informatics (ICHI)*. [S.l.: s.n.], 2019. p. 1–5. Citado na página 31.
- DEVLIN, J. et al. BERT: pre-training of deep bidirectional transformers for language understanding. *CoRR*, abs/1810.04805, 2018. Disponível em: <<http://arxiv.org/abs/1810.04805>>. Citado na página 34.
- DEVLIN, J. et al. *BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding*. arXiv, 2018. Disponível em: <<https://arxiv.org/abs/1810.04805>>. Citado na página 36.
- FACELI, K. et al. *Inteligência artificial: uma abordagem de aprendizado de máquina*. [S.l.]: LTC, 2011. Citado na página 21.
- GANDOMI, A. H.; CHEN, F.; ABUALIGAH, L. Machine learning technologies for big data analytics. *Electronics*, v. 11, n. 3, 2022. ISSN 2079-9292. Disponível em: <<https://www.mdpi.com/2079-9292/11/3/421>>. Citado na página 21.

- GARIMELLA, K. Polarization on Social Media. In: . Aalto University, 2018. (Aalto University publication series DOCTORAL DISSERTATIONS; 20/2018), p. 67 + app. 127. ISBN 978-952-60-7833-5 (electronic), 978-952-60-7832-8 (printed). ISSN 1799-4942 (electronic), 1799-4934 (printed), 1799-4934 (ISSN-L). Disponível em: <<http://urn.fi/URN:ISBN:978-952-60-7833-5>>. Citado na página 15.
- GEETHA, M.; Karthika Renuka, D. Improving the performance of aspect based sentiment analysis using fine-tuned bert base uncased model. *International Journal of Intelligent Networks*, v. 2, p. 64–69, 2021. ISSN 2666-6030. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2666603021000129>>. Citado 3 vezes nas páginas 32, 33 e 34.
- GÉRON, A. *Mãos à Obra: Aprendizado de Máquina com Scikit-Learn & TensorFlow*. [S.l.]: Alta Books, 2019. Citado na página 21.
- GOES, L. T. d. Contra-hegemonia e internet: Gramsci e a mídia alternativa dos movimentos sociais na web. *IX Congresso Brasileiro de Ciências da Comunicação da Região Nordeste – Salvador – BA*, 2022. Citado na página 18.
- HAGEN, L. Content analysis of e-petitions with topic modeling: How to train and evaluate lda models? *Information Processing Management*, v. 54, n. 6, p. 1292–1307, 2018. ISSN 0306-4573. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S0306457317307240>>. Citado 2 vezes nas páginas 21 e 30.
- HALLER, A.; HOLT, K. Paradoxical populism: how pegida relates to mainstream and alternative media. *Information, Communication & Society*, Routledge, v. 22, n. 12, p. 1665–1680, 2019. Disponível em: <<https://doi.org/10.1080/1369118X.2018.1449882>>. Citado na página 19.
- HAMMES, L. O. A.; FREITAS, L. A. de. Utilizando bertimbau para a classificação de emoções em português. In: SBC. *Anais do XIII Simpósio Brasileiro de Tecnologia da Informação e da Linguagem Humana*. [S.l.], 2021. p. 56–63. Citado na página 35.
- HARCUP, T. “i’m doing this to change the world”: journalism in alternative and mainstream media. *Journalism Studies*, Routledge, v. 6, n. 3, p. 361–374, 2005. Disponível em: <<https://doi.org/10.1080/14616700500132016>>. Citado na página 18.
- IHLEBÆK, K. A.; NYGAARD, S. Right-wing alternative media in the scandinavian political communication landscape. Nordicom, University of Gothenburg, 2021. Citado na página 19.
- ISHIDA, T. et al. Do we need zero training loss after achieving zero training error? *CoRR*, abs/2002.08709, 2020. Disponível em: <<https://arxiv.org/abs/2002.08709>>. Citado 2 vezes nas páginas 33 e 40.
- KANG, H. J.; KIM, C.; KANG, K. Analysis of the trends in biochemical research using latent dirichlet allocation (lda). *Processes*, v. 7, n. 6, 2019. ISSN 2227-9717. Disponível em: <<https://www.mdpi.com/2227-9717/7/6/379>>. Citado na página 21.
- KINGMA, D. P.; BA, J. *Adam: A Method for Stochastic Optimization*. arXiv, 2014. Disponível em: <<https://arxiv.org/abs/1412.6980>>. Citado na página 36.

- LI, B.; HAN, L. Distance weighted cosine similarity measure for text classification. In: YIN, H. et al. (Ed.). *Intelligent Data Engineering and Automated Learning – IDEAL 2013*. Berlin, Heidelberg: Springer Berlin Heidelberg, 2013. p. 611–618. Citado na página 32.
- MONARD, M. C.; PRATI, R. C. Aprendizado de máquina simbólico para mineração de dados. In: *XIII Escola Regional de Informática da SBC - Santa Catarina*. 1. ed. Florianópolis: Sociedade Brasileira de Computação, 2005. p. 1–26. ISBN 8576690349. Disponível em: <<http://www.labic.icmc.usp.br/pub/mcmonard/eri05book.pdf>>. Citado na página 21.
- NYGAARD, S. On the mainstream/alternative continuum: Mainstream media reactions to right-wing alternative news media. *Digital Journalism*, Routledge, v. 0, n. 0, p. 1–17, 2021. Disponível em: <<https://doi.org/10.1080/21670811.2021.1894962>>. Citado na página 19.
- OLIVEIRA, B. S. N. et al. Processamento de linguagem natural via aprendizagem profunda. *Sociedade Brasileira de Computação*, 2022. Citado na página 29.
- PEZOA, F. et al. Foundations of json schema. In: *Proceedings of the 25th International Conference on World Wide Web*. Republic and Canton of Geneva, CHE: International World Wide Web Conferences Steering Committee, 2016. (WWW '16), p. 263–273. ISBN 9781450341431. Disponível em: <<https://doi.org/10.1145/2872427.2883029>>. Citado na página 28.
- PIMENTEL, J. F. et al. Ciência de dados com reprodutibilidade usando jupyter. *Sociedade Brasileira de Computação*, 2021. Citado na página 20.
- RASCHKA, S. An overview of general performance metrics of binary classifier systems. *arXiv preprint arXiv:1410.5330*, 2014. Citado na página 39.
- RAUCH, J. Exploring the Alternative–Mainstream Dialectic: What “Alternative Media” Means to a Hybrid Audience*. *Communication, Culture and Critique*, v. 8, n. 1, p. 124–143, 09 2014. ISSN 1753-9129. Disponível em: <<https://doi.org/10.1111/cccr.12068>>. Citado na página 18.
- RAVICHANDIRAN, S. *Getting Started with Google BERT: Build and train state-of-the-art natural language processing models using BERT*. 1th. ed. [S.l.]: Packt Publishing, 2021. Citado na página 32.
- REIMERS, N.; GUREVYCH, I. *Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks*. 2019. ArXiv cs.CL 1908.10084. Citado na página 31.
- ROSA, J. L. G. Fundamentos da inteligência artificial. *Rio de Janeiro: LTC*, v. 1, 2011. Citado na página 29.
- SARICA, S.; LUO, J. Stopwords in technical language processing. *PLOS ONE*, Public Library of Science, v. 16, n. 8, p. 1–13, 08 2021. Disponível em: <<https://doi.org/10.1371/journal.pone.0254937>>. Citado na página 30.
- SHAHREZAYE, M. et al. Estimating the political orientation of twitter users in homophilic networks. In: *AAAI Spring Symposium: Interpretable AI for Well-being*. [S.l.: s.n.], 2019. Citado na página 20.

- SIMÕES, A.; CASTAÑOS. Fine-tuned bert for the detection of political ideology. In: STANFORD. *Stanford CS224N Custom Project*. 2020. Disponível em: <<https://web.stanford.edu/class/archive/cs/cs224n/cs224n.1204/reports/custom/report43.pdf>>. Citado 2 vezes nas páginas 22 e 46.
- SOUZA, F.; NOGUEIRA, R.; LOTUFO, R. Bertimbau: Pretrained bert models for brazilian portuguese. In: CERRI, R.; PRATI, R. C. (Ed.). *Intelligent Systems*. Cham: Springer International Publishing, 2020. p. 403–417. ISBN 978-3-030-61377-8. Citado na página 34.
- SUN, X. et al. *Sentence Similarity Based on Contexts*. 2021. ArXiv cs.CL 2105.07623. Citado na página 32.
- TEIXEIRA, L. M. Ativismo em rede: crítica das mídias alternativas à atual política de brasil, espanha e portugal. 2022. Disponível em: <<https://hdl.handle.net/1822/77937>>. Acesso em: 01 out. 2022. Citado 2 vezes nas páginas 15 e 19.
- TENNEY, I.; DAS, D.; PAVLICK, E. BERT rediscovers the classical NLP pipeline. *CoRR*, abs/1905.05950, 2019. Disponível em: <<http://arxiv.org/abs/1905.05950>>. Citado na página 31.
- VASCONCELOS, M. et al. Identifying and characterizing alternative news media on facebook. In: *2020 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)*. [S.l.: s.n.], 2020. p. 448–452. Citado 3 vezes nas páginas 15, 20 e 23.
- VRIES, W. de et al. Bertje: A dutch BERT model. *CoRR*, abs/1912.09582, 2019. Disponível em: <<http://arxiv.org/abs/1912.09582>>. Citado na página 35.
- VUCETIC, D. et al. Efficient fine-tuning of bert models on the edge. In: . [S.l.: s.n.], 2022. Citado na página 34.
- WANG, M.; HU, F. The application of nltk library for python natural language processing in corpus research. *Theory and Practice in Language Studies*, v. 11, n. 9, p. 1041–1049, 2021. Citado na página 30.
- YIRAN, Y.; SRIVASTAVA, S. Aspect-based sentiment analysis on mobile phone reviews with lda. In: . New York, NY, USA: Association for Computing Machinery, 2019. (ICMLT 2019), p. 101–105. ISBN 9781450363235. Disponível em: <<https://doi.org/10.1145/3340997.3341012>>. Citado na página 22.

Apêndices

APÊNDICE A – *stopwords nltk* utilizadas

de, a, o, que, e, é, do, da, em, um, para, com, não, uma, os, no, se, na, por, mais, as, dos, como, mas, ao, ele, das, à, seu, sua, ou, quando, muito, nos, já, eu, também, só, pelo, pela, até, isso, ela, entre, depois, sem, mesmo, aos, seus, quem, nas, me, esse, eles, você, essa, num, nem, suas, meu, às, minha, numa, pelos, elas, qual, nós, lhe, deles, essas, esses, pelas, este, dele, tu, te, vocês, vos, lhes, meus, minhas, teu, tua, teus, tuas, nosso, nossa, nossos, nossas, dela, delas, esta, estes, estas, aquele, aquela, aqueles, aquelas, isto, aquilo, estou, está, estamos, estão, estive, estive, estivemos, estiveram, estava, estávamos, estavam, estivera, estivéramos, esteja, estejamos, estejam, estivesse, estivéssemos, estivessem, estiver, estivermos, estiverem, hei, há, havemos, hã, houve, houvemos, houveram, houvera, houvéramos, haja, hajamos, hajam, houvesse, houvéssemos, houvessem, houver, houvermos, houverem, houverei, houverá, houveremos, houverão, houveria, houveríamos, houveriam, sou, somos, são, era, éramos, eram, fui, foi, fomos, foram, fora, fôramos, seja, sejamos, sejam, fosse, fôssemos, fossem, for, formos, forem, serei, será, seremos, serão, seria, seríamos, seriam, tenho, tem, temos, têm, tinha, tínhamos, tinham, tive, teve, tivemos, tiveram, tivera, tivéramos, tenha, tenhamos, tenham, tivesse, tivéssemos, tivessem, tiver, tivermos, tiverem, terei, terá, teremos, terão, teria, teríamos, teriam

APÊNDICE B – Código utilizado para obter a classificação de um texto de entrada a partir do modelo treinado

```
new_sentence = 'bolsonaro bom'

test_ids = []
test_attention_mask = []

encoding = preprocessing(new_sentence, tokenizer)

test_ids.append(encoding['input_ids'])
test_attention_mask.append(encoding['attention_mask'])
test_ids = torch.cat(test_ids, dim = 0)
test_attention_mask = torch.cat(test_attention_mask, dim = 0)

with torch.no_grad():
    output = model(test_ids.to(device), token_type_ids = None,
                  attention_mask = test_attention_mask.to(device))

prediction = 'Direita' if np.argmax(output.logits.cpu().numpy()).
    flatten().item() == 1 else 'Esquerda'

print('Predicted Class: ', prediction)
```