



**UNIVERSIDADE FEDERAL DE CAMPINA GRANDE
CENTRO DE ENGENHARIA ELÉTRICA E INFORMÁTICA
CURSO DE BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO**

MARIANA VICTÓRIA SOUZA COIMBRA

**ANÁLISE DE SENTIMENTOS E EMOÇÕES DE TWEETS SOBRE
A GUERRA DA UCRÂNIA**

CAMPINA GRANDE - PB

2023

MARIANA VICTÓRIA SOUZA COIMBRA

**ANÁLISE DE SENTIMENTOS E EMOÇÕES DE TWEETS SOBRE
A GUERRA DA UCRÂNIA**

**Trabalho de Conclusão Curso
apresentado ao Curso Bacharelado em
Ciência da Computação do Centro de
Engenharia Elétrica e Informática da
Universidade Federal de Campina
Grande, como requisito parcial para
obtenção do título de Bacharel em
Ciência da Computação.**

Orientador : Claudio Elízio Calazans Campelo

CAMPINA GRANDE - PB

2023

MARIANA VICTÓRIA SOUZA COIMBRA

**ANÁLISE DE SENTIMENTOS E EMOÇÕES DE TWEETS SOBRE
A GUERRA DA UCRÂNIA**

**Trabalho de Conclusão Curso
apresentado ao Curso Bacharelado em
Ciência da Computação do Centro de
Engenharia Elétrica e Informática da
Universidade Federal de Campina
Grande, como requisito parcial para
obtenção do título de Bacharel em
Ciência da Computação.**

BANCA EXAMINADORA:

**Cláudio Elísio Calazans Campelo
Orientador – UASC/CEEI/UFCG**

**Marcus Salerno de Aquino
Examinador – UASC/CEEI/UFCG**

**Melina Mongiovi Sabino
Professor da Disciplina TCC – UASC/CEEI/UFCG**

Trabalho aprovado em: 17 de Novembro de 2023.

CAMPINA GRANDE - PB

RESUMO

O presente artigo trata-se de uma análise de sentimentos e emoções expressos em Tweets relacionados à Guerra da Ucrânia, mediante análise dos tópicos discutidos pelos usuários da plataforma Twitter. Este estudo visa compreender como os usuários reagem ao evento em curso, quais aspectos da guerra as pessoas estão discutindo na plataforma, e como se sentem a respeito deste acontecimento. Além disso, visa identificar correlações entre as variáveis presentes nos Tweets, como localização, informações de perfil do usuário autor da postagem, e a natureza de suas opiniões. Tais análises foram conduzidas através de tarefas de processamento de linguagem natural como análises exploratórias dos dados e a aplicação de classificadores de sentimentos de Tweets utilizando modelos de dados pré-treinados. Os dados analisados contém Tweets coletados desde o início do conflito, que se deu em fevereiro de 2022 até outubro de 2023, e foram coletados a partir de hashtags relacionadas à Guerra. Para a realização das análises de sentimento e emoção foram utilizados a variante RoBERTa. Os Tweets foram classificados em sentimentos como positivos, negativos ou neutros, e em emoções como alegria, raiva, medo, nojo, otimismo, pessimismo, surpresa e amor. Os resultados mostraram que a maioria dos tweets em inglês expressam raiva e antecipação como emoções predominantes, e sentimentos negativos e neutros com maior predominância, atingindo mais de 50% da amostragem analisada. Algumas das frases mais recorrentes na análise fazem alusão ao apoio à Ucrânia e pedindo o fim da guerra. Da mesma forma, frases de preocupação com a crise, armas e fatalidades são recorrentes. Na maioria das postagens, pessoas demonstram preocupação com o conflito armado e apoio à Ucrânia. Trabalhos futuros poderiam utilizar mais tweets para abranger a análise e visualizar a correlação de mais atributos relacionados às postagens como os engajamentos e curtidas.

SENTIMENT AND EMOTION ANALYSIS OF TWEETS ABOUT THE UKRAINE WAR

ABSTRACT

The present article involves an analysis of sentiments and emotions expressed in Tweets related to the Ukraine War, through an examination of topics discussed by users on the Twitter platform. This study aims to comprehend how users react to the ongoing event, which aspects of the war people are discussing on the platform, and how they feel about this occurrence. Additionally, it seeks to identify correlations among variables present in the Tweets, such as location, user profile information of the post author, and the nature of their opinions. These analyses were conducted through natural language processing tasks, including exploratory data analysis and the application of sentiment classifiers for Tweets using pre-trained data models. The analyzed data includes Tweets collected from the beginning of the conflict, which started in February 2022, until October 2023, gathered through hashtags related to the War. For sentiment and emotion analyses, the RoBERTa variant was employed. Tweets were categorized into sentiments such as positive, negative, or neutral, and emotions including joy, anger, fear, disgust, optimism, pessimism, surprise, and love. The results indicated that the majority of English tweets express anger and anticipation as predominant emotions, with negative and neutral sentiments having greater prevalence, exceeding 50% of the analyzed sample. Some of the most recurrent phrases in the analysis reference support for Ukraine and call for an end to the war. Similarly, phrases expressing concern about the crisis, weapons, and fatalities are common. In most posts, individuals demonstrate concern about the armed conflict and express support for Ukraine. Future work could incorporate more tweets to encompass the analysis and visualize the correlation of additional attributes related to posts, such as engagements and likes.

Análise de Sentimentos e Emoções de Tweets sobre a Guerra da Ucrânia

Trabalho de Conclusão de Curso

Mariana Victoria Souza Coimbra
Departamento de Sistemas e Computação
Universidade Federal de Campina Grande
Campina Grande, Paraíba - Brasil
mariana.coimbra@ccc.ufcg.edu.br

Cláudio Campelo
Departamento de Sistemas e Computação
Universidade Federal de Campina Grande
Campina Grande, Paraíba - Brasil
campelo@computacao.ufcg.edu.br

RESUMO

O presente artigo trata-se de uma análise de sentimentos e emoções expressos em Tweets relacionados à Guerra da Ucrânia, mediante análise dos tópicos discutidos pelos usuários da plataforma Twitter. Este estudo visa compreender como os usuários reagem ao evento em curso, quais aspectos da guerra as pessoas estão discutindo na plataforma, e como se sentem a respeito deste acontecimento. Além disso, visa identificar correlações entre as variáveis presentes nos Tweets, como localização, informações de perfil do usuário autor da postagem, e a natureza de suas opiniões. Tais análises foram conduzidas através de tarefas de processamento de linguagem natural como análises exploratórias dos dados e a aplicação de classificadores de sentimentos de Tweets utilizando modelos de dados pré-treinados. Os dados analisados contém Tweets coletados desde o início do conflito, que se deu em fevereiro de 2022 até outubro de 2023, e foram coletados a partir de hashtags relacionadas à Guerra. Para a realização das análises de sentimento e emoção foram utilizados a variante RoBERTa. Os Tweets foram classificados em sentimentos como positivos, negativos ou neutros, e em emoções como alegria, raiva, medo, nojo, otimismo, pessimismo, surpresa e amor. Os resultados mostraram que a maioria dos tweets em inglês expressam raiva e antecipação como emoções predominantes, e sentimentos negativos e neutros com maior predominância, atingindo mais de 50% do da amostragem analisada. Algumas das frases mais recorrentes na análise fazem alusão ao apoio à Ucrânia e pedindo o fim da guerra. Da mesma forma, frases de preocupação com a crise, armas e fatalidades são recorrentes. Na maioria das postagens, pessoas demonstram preocupação com o conflito armado e apoio à Ucrânia. Trabalhos futuros poderiam utilizar mais tweets para abranger a análise e visualizar a correlação de mais atributos relacionados às postagens como os engajamentos e curtidas.

PALAVRAS-CHAVE

Guerra da Ucrânia, Ucrânia, Machine Learning, Aprendizado de Máquina, Modelos de Classificação, NLP, Rússia, Modelos pre-treinados, RoBERTa

Os autores retêm os direitos, ao abrigo de uma licença Creative Commons Atribuição CC BY, sobre todo o conteúdo deste artigo (incluindo todos os elementos que possam conter, tais como figuras, desenhos, tabelas), bem como sobre todos os materiais produzidos pelos autores que estejam relacionados ao trabalho relatado e que estejam referenciados no artigo (tais como códigos fonte e bases de dados). Essa licença permite que outros distribuam, adaptem e evoluam seu trabalho, mesmo comercialmente, desde que os autores sejam creditados pela criação original.

1 INTRODUÇÃO

Em fevereiro de 2022, a Guerra na Ucrânia teve seu início e os confrontos ainda perduram nos dias atuais. Desde 2014, a Rússia e a Ucrânia possuem desavenças e o estopim da guerra revela o ápice de um conflito que já vinha sendo construído devido a uma série de acontecimentos como, por exemplo, a ordem de invasão no leste da Ucrânia pelo presidente russo Vladimir Putin e constantes ofensivas de bombardeamentos [10].

Por suas vastas implicações internacionais no presente e possivelmente no futuro, a invasão da Ucrânia pela Rússia causou uma guerra problemática e divisionista. Dessa forma, diante da era dos dados e das mídias sociais, em que diversas pessoas expressam suas opiniões e reflexões através de plataformas, surge a oportunidade de sabermos o que uma parcela da população mundial expõe opiniões e sentimentos sobre esse conflito armado que afeta de forma direta a sociedade, como também influencia em acordos políticos e na economia mundial, como por exemplo, pela alta do petróleo após medidas como as sanções dos Estados Unidos e da União Europeia (UE) contra o petróleo exportado pela Rússia, em represália pela guerra [14].

A cada avanço da guerra, novas opiniões e críticas diante desse conflito podem surgir e tomar novas perspectivas, e entender o que as pessoas pensam e como expressam suas opiniões ao longo do tempo pode auxiliar o entendimento do conhecimento coletivo sobre aspectos como geopolítica, expressões ideológicas e opiniões presentes nos discursos relativos a este conflito. Nesse sentido, em meio à era dos dados, com o avanço de tecnologias e dos métodos de aprendizado de máquina, torna-se possível realizar classificações dos Tweets com uso de técnicas de programação de linguagem natural (PLN). Tais classificações são viabilizadas através de recursos e abordagens como modelos de aprendizagem de máquina e Deep Learning, ambas subáreas da inteligência artificial. A classificação de emoções e sentimentos de um texto são atualmente campos amplamente estudados e debatidos. Existem diferentes abordagens sendo defendidas neste contexto, como por exemplo, as três principais abordagens são as baseadas em léxico (baseada em conhecimento), aprendizado de máquina (métodos estatísticos) e abordagens híbridas [7]. Neste artigo, foi empregado o uso de métodos estatísticos.

Neste artigo foi empregado o uso de modelos baseados em RoBERTa para a classificação de sentimentos e emoções presentes nas postagens analisadas. Dois dos modelos mais conhecidos para tarefas de PLN são BERT (Bidirectional Encoder Representations from Transformers) [8] e RoBERTa (a Recursive Variant of BERT) [11], tais

modelos são baseados em redes neurais do tipo Transformers e compartilham uma arquitetura base semelhante, mas o RoBERTa introduz algumas otimizações e modificações tais como a remoção de algumas das tarefas de treinamento auxiliar usadas no treinamento original do BERT e aumenta o tamanho do conjunto de dados de pré-treinamento. Estas alterações resultam em um modelo mais aprimorado em relação ao desempenho em tarefas de NLP.

Os sentimentos presentes das postagens são classificados como positivos, negativos e neutros. Já as emoções são classificadas como alegria, tristeza, raiva, otimismo, pessimismo, nojo, amor, antecipação e desgosto. Para a visualização das análises foram utilizadas técnicas como gráfico de barras, gráfico de linhas, heatmaps (mapas de calor) e wordcloud para facilitar a realização de inferências. Estas visualizações se deram através de bibliotecas de visualização de dados como Matplotlib e Seaborn, que são populares ferramentas de visualização de dados em Python que permitem analisarmos por exemplo a correlação entre os atributos presentes nos dados e responder perguntas de forma mais clara e visual.

Após a realização das classificações dos dados, avaliação das classificação se deu através de cálculos de métricas de avaliação como cálculo de precisão (acurácia), recall e F1-Score.

O conteúdo deste artigo consiste no seguinte: seção 1 são as introduções da pesquisa, a seção 2 mostra pesquisas neste campo, os modelos e metodologia da pesquisa serão apresentadas na seção 3 e o resultados e a conclusão estarão nas seções 5 e 6.

2 TRABALHOS RELACIONADOS

Nesta seção, analisamos pesquisas relacionadas à análise de sentimentos na plataforma Twitter e classificação de sentimentos e emoções inseridos no contexto de Tweets.

2.1 Análise de sentimento de Tweets

Na análise de sentimentos no contexto de redes sociais, como o Twitter, é essencial adotar abordagens específicas. Um conjunto substancial de estudos tem contribuído significativamente para o progresso desse campo. Giachanou e Crestani [9] conduzem uma análise abrangente das metodologias relacionadas à análise de sentimentos em ambientes de redes sociais, com foco especial no contexto do Twitter. Eles identificam as abordagens que têm obtido os melhores resultados em tais cenários. Essa pesquisa reconhece a análise de sentimentos de Tweets como uma tarefa de classificação, pois a meta típica é classificar as opiniões expressas em um Tweet como positivas ou negativas, e é exatamente esse tipo de análise que foi realizada neste estudo.

Os artigos investigados nesta seção abordam metodologias e definições de aprendizado de máquina que enriqueceram o desenvolvimento deste estudo. Braig et al. [5] destacam que as técnicas de classificação com aprendizado de máquina, no âmbito da análise de sentimentos, geralmente seguem uma abordagem supervisionada. Isso implica a necessidade de conjuntos de dados de treinamento que contenham classes de sentimentos rotuladas. Utilizando esses conjuntos de dados, os modelos de classificação são treinados e aprimorados. Contudo, Mathew [12] demonstra que a utilização de modelos pré-treinados baseados na arquitetura Deep Learning (aprendizagem profunda) podem realizar estas mesmas tarefas de maneira eficaz usando abordagem de transferência de aprendizagem.

Seguindo essas definições, neste estudo, optamos por adotar modelos pré-treinados e realizar o ajuste fino (finetuning) para o contexto de análise de sentimentos. Essa abordagem permitiu uma análise mais precisa e eficaz das emoções e sentimentos expressos nos textos, demonstrando a aplicação prática dessas inovações no cenário de pesquisa em processamento de linguagem natural.

2.2 Classificadores Deep Learning

As pesquisas conduzidas no âmbito da análise de sentimentos em Tweets [5, 9] têm proporcionado percepções quanto à metodologia que mais se destaca em termos de precisão: a utilização de modelos de conjunto, que incorporam algoritmos de aprendizado de máquina. Notavelmente, os modelos BERT (Bidirectional Encoder Representations from Transformers) e RoBERTa (A Robustly Optimized BERT Pretraining Approach) têm emergido como líderes no neste contexto. Ambos são modelos de linguagem que se baseiam na arquitetura de Transformers e têm apresentado resultados altamente promissores quando adaptados para análise de sentimentos em dados do Twitter.

Consequentemente, a escolha de modelos baseados em Deep Learning, como BERT e RoBERTa, representa um avanço significativo na análise de sentimentos e emoções no contexto do Twitter. E foi desta forma que se condiziu estas etapas de classificação.

3 METODOLOGIA

A seção de Metodologia descreve a abordagem adotada nesta pesquisa para a classificação de sentimento e emoções de Tweets sobre a guerra da Ucrânia. É apresentado o conjunto de dados utilizado, as técnicas de aprendizado de máquina aplicadas e as métricas de avaliação utilizadas. O objetivo é explorar diferentes abordagens e fornecer as inferências realizadas durante a pesquisa. A Figura 13 demonstra o fluxo completo da metodologia adotada para as análises e inferências realizadas na pesquisa.

3.1 Coleta dos Dados

Os dados empregados na condução desta pesquisa foram obtidos a partir da plataforma de rede social Twitter. O Twitter é uma rede social muito popular, que permite que o usuário faça publicações e cada publicação tem o limite de 280 caracteres. Atualmente, estima-se que existe cerca de 229 milhões de usuários ativos mensais na plataforma [15]. O Twitter é caracterizado por possuir algumas features e nomeclaturas específicas como o compartilhamento de postagens e Hashtags. Inicialmente, a estratégia de coleta planejada consistia em extrair Tweets utilizando técnicas como raspagem de dados, um método de mineração de dados que possibilita a extração de informações de websites e sua conversão em dados estruturados, prontos para análise. Outra alternativa considerada era o uso da API do Twitter, juntamente com as ferramentas e recursos de desenvolvedor anteriormente disponibilizados pela plataforma de forma gratuita.

Entretanto, ao longo dos últimos meses, houve mudanças nas políticas do Twitter [3] decorrentes da transição na presidência da plataforma. Essas mudanças afetaram substancialmente a viabilidade das alternativas anteriormente planejadas. Como resultado, a coleta de dados com base nesses métodos tornou-se praticamente inviável.

Diante dessa nova realidade, a opção foi a utilização de um conjunto de dados disponibilizado pela plataforma Kaggle. A Kaggle é uma plataforma online que oferece uma ampla gama de recursos e ferramentas para a comunidade de ciência de dados. Dentre seus principais componentes e recursos oferecem os Datasets e um vasto repositório de conjuntos de dados. Isso facilita o acesso a dados de qualidade para análise e modelagem. E foi dessa ferramenta que foram extraídos os Tweets utilizados nessa pesquisa. O conjunto de dados escolhido recebe o nome de "Sunset UA Ukraine Conflict Twitter Dataset". Este conjunto foi compilado por um autor que coletou Tweets periodicamente, abordando tópicos relacionados ao conflito na Ucrânia, quando ainda não havia restrições significativas de política e alterações na plataforma Twitter.

Os dados foram baixados e submetidos a tratamentos necessários para viabilizar a análise exploratória e a análise de sentimentos com o uso de modelos de aprendizado de máquina.

3.2 Conjunto de dados

O conjunto de dados utilizado nesta pesquisa representa uma amostra representativa de Tweets relacionados ao conflito na Ucrânia. A seleção dos Tweets foi realizada com base em uma lista de hashtags que abordam temas relacionados à guerra e seu contexto. O volume de dados original disponibilizado pelo autor do conjunto de dados no Kaggle atingiu até 18GB, com arquivos compactados no formato gzip. Um dos principais desafios enfrentados durante a pesquisa foi a extração e processamento dos dados, notadamente devido às considerações sobre a infraestrutura de hardware, uma questão que pode envolver custos substanciais. A gestão de recursos e otimização de custos se tornou uma tarefa complexa, atrasando a análise devido à necessidade de terceirizar o processamento de dados, resultando em uma extração de amostragem de cerca de 11.9GB.

Devido ao grande volume de dados e aos desafios relacionados à infraestrutura de hardware, foi imperativo solicitar acesso remoto a uma máquina equipada com uma Unidade de Processamento Gráfico (GPU), um processador especializado projetado para executar cálculos relacionados a gráficos e processamento paralelo. Essa abordagem está em consonância com o trabalho de Owens et al.[13], que discutem as vantagens e a eficácia do uso de GPU em atividades que demandam alto poder de processamento.

Cada Tweet no conjunto de dados está associado a atributos relevantes para a análise, incluindo o ID do usuário, nome de usuário, descrição da conta no Twitter, localização, idioma, número de seguidores, número de contas seguidas, quantidade de compartilhamentos do Tweet, hashtags, número de interações e data de publicação. Como a coleta de dados foi realizada ao longo do período do conflito, ela foi continuamente aprimorada com o tempo. A classificação de sentimentos e emoções é baseada no texto dos Tweets, enquanto a coluna de localização e a data permitem a correlação entre essas informações.

Devido ao formato original dos dados, foi necessário realizar um processo de transformação e conversão para arquivos CSV a fim de viabilizar as análises com a biblioteca Pandas, que desempenhou um papel fundamental na pesquisa. A maior parte das análises de sentimentos foi realizada em Tweets em língua inglesa, uma escolha que reflète a disponibilidade de dados e recursos para essa língua.

A exploração deste conjunto de dados diversificado visa identificar padrões, tendências e correlações entre as variáveis, com o objetivo de desenvolver visualizações e inferências significativas. Essa análise detalhada do conjunto de dados é essencial para uma compreensão aprofundada do contexto da análise de sentimentos e das nuances presentes nos dados coletados.

3.3 Pré-processamento dos dados

A análise de Tweets pode vir acompanhada de diversos desafios em razão de diversos fatores como por exemplo a forma incorreta de se usar a gramática na plataforma, uma vez que nas redes sociais as pessoas escrevem de forma informal. Os Tweets contêm peculiaridades textuais, incluindo desde letras maiúsculas enfáticas, alongamento enfático, abreviações até o uso de gírias. Isso pode implicar em muitos erros gramaticais e semânticos. Com isso, é ocasionada uma esparsidade nos dados por possuírem tantos erros, isso se torna um grande fator de impacto na análise de sentimento. Portanto, a etapa de pré-processamento dos dados desempenha um papel fundamental na análise de dados e no desenvolvimento de modelos de aprendizado de máquina, uma vez que é a etapa que visa preparar os dados brutos para análises subsequentes e a construção de modelos preditivos.

Após a extração dos Tweets em inglês, a etapa inicial do pré-processamento consistiu na remoção de postagens duplicadas, o que ocorre devido à função de compartilhamento presente na plataforma. A repetição de Tweets pode causar redundância nos dados, prejudicando a qualidade da análise. A eliminação de textos duplicados foi realizada com a função "drop duplicates" da biblioteca Pandas, com base na coluna de texto.

Durante a fase de pré-processamento para a análise de sentimentos usando o modelo RoBERTa, foram adotadas várias abordagens para garantir a qualidade e consistência do conjunto de dados. O primeiro passo envolveu a eliminação de fatores textuais que têm menos influência na classificação do modelo e que poderiam enviesar as previsões. Isso incluiu a substituição de emojis, que são combinações de símbolos não textuais, por palavras que possuem um significado linguístico mais claro para o modelo. Também foi realizada a remoção de "stopwords", que são basicamente palavras consideradas irrelevantes para a análise de texto e recuperação de informações. A biblioteca NLTK em Python foi utilizada para identificar as stopwords. As hashtags foram mantidas, uma vez que fornecem informações relevantes e contribuem para uma melhor compreensão do sentimento de cada Tweet. Em seguida, o texto foi submetido à lematização, um processo que visa reduzir palavras flexionadas ou derivadas às suas formas básicas, conhecidas como "lemas" ou "radicais". Como última etapa de pré-processamento para a classificação com modelos do pacote Transformers, foi empregado um tokenizer da classe AutoTokenizer, também do pacote Transformers, compatível com o modelo pré-treinado escolhido para a classificação.

Posteriormente, para a análise e cálculo da precisão dos modelos de classificação, antes de iniciar o treinamento dos dados, foram realizadas substituições de padrões, como URLs e menções de usuários (iniciando com '@', por exemplo), além da remoção de caracteres não alfabéticos. Para palavras contendo URLs, menções de usuário e caracteres não numéricos, ou aquelas que seguíam um padrão de

letras subsequentes, foi aplicada uma substituição por meio de tags indicativas de URL e usuário. Essas substituições e remoções foram baseadas em expressões regulares.

O conjunto de técnicas de pré-processamento mencionado, que inclui a identificação de padrões, substituições por tags, remoção de stopwords e lematização, é conhecido como "normalização de texto". Esse processo desempenha um papel crucial na preparação dos dados, contribuindo para a qualidade da análise de sentimentos e a eficácia dos modelos de aprendizado de máquina.

3.4 Análise Exploratória dos Dados

Nesta subseção, apresentamos a análise exploratória conduzida nos dados, visando compreender suas características gerais, identificar padrões, tendências e extrair ideias relevantes para a análise subsequente. Para alcançar esses objetivos, foram empregadas técnicas de visualização e estatísticas descritivas, proporcionando uma visão abrangente do conjunto de dados.

Durante a análise exploratória, observou-se a predominância de Tweets em língua inglesa, conforme ilustrado na Figura 1. Além disso, uma quantidade considerável de Tweets foi proveniente de usuários localizados em países da América do Norte e da Europa Ocidental como evidenciado na Figura 2. É possível também observar que muitos usuários optam por preencher suas informações de localização com dados não reais como "internet" ou "planeta terra", e essas informações foram posteriormente preenchidas pelo valor "Not Specified" ou "Não especificado" para indicar que o atributo não foi informado.

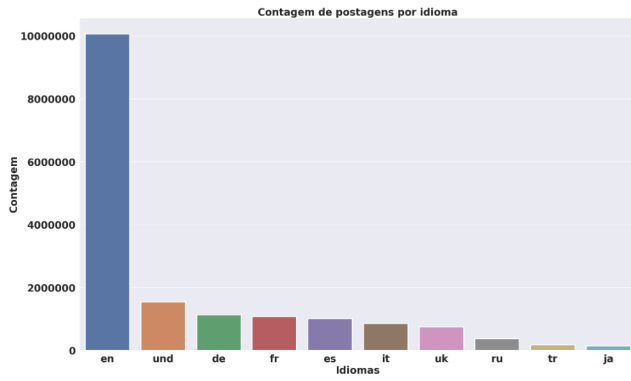


Figura 1: Contagem de postagens por idioma

No Twitter, os usuários frequentemente utilizam hashtags para referenciar tópicos específicos. O uso de hashtags permite a expressão de apoio ou oposição a determinados assuntos, bem como o registro de opiniões sobre diversos temas. A análise da recorrência de hashtags revelou uma predominância de tags que demonstram apoio e solidariedade à Ucrânia, como ilustrado na Figura 3.

Além disso, a análise da relação entre a quantidade de postagens e a data (Figura 4) proporcionou entendimentos valiosos sobre a reação dos usuários aos acontecimentos. Notou-se um aumento significativo no volume de postagens durante o período entre fevereiro de 2023 e março de 2023, coincidindo com o primeiro aniversário do início do conflito. Esse período é marcado por uma concentração




Figura 2: Relação de quantidade de postagens de tweets por localização

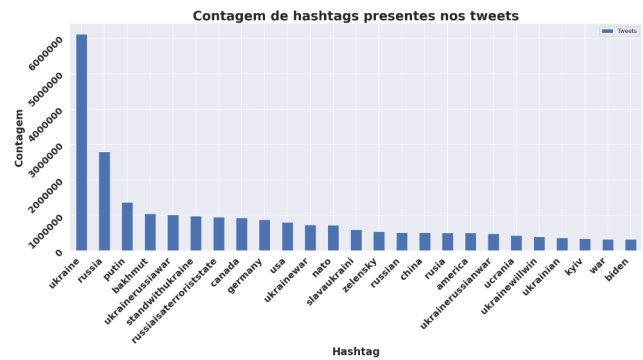


Figura 3: Hashtags com maior predominância nos Tweets relacionados ao conflito

expressiva de postagens, indicando um interesse crescente da comunidade em discutir e compartilhar informações sobre o evento.




Figura 4: Quantidade de Tweets no decorrer da Guerra

A Word Cloud da Figura 5 mostra os Tweets referentes a essas datas com maior número de postagens. É possível analisar pelo uso das palavras como "Esperança", "Russia é um estado terrorista", "Zelensky criminoso de guerra", "ataque" e "tropas" que durante esse período as opiniões se divergiam entre esperança, acusações contra as ações de Putin e comentários a respeito dos acontecimentos.




Figura 7: Proporções de Sentimentos dos Tweets por localização

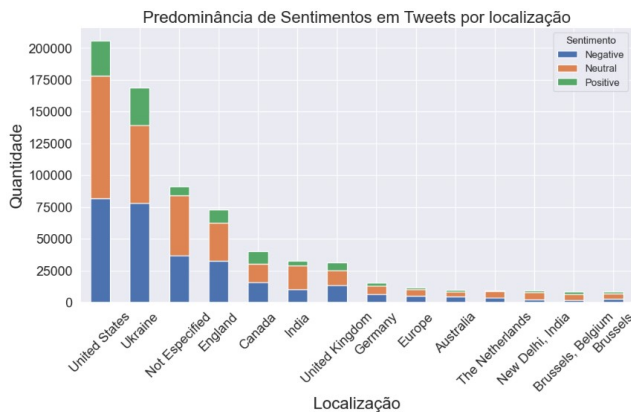


Figura 8: Predominância de Sentimentos dos Tweets por localização de acordo com número de postagens

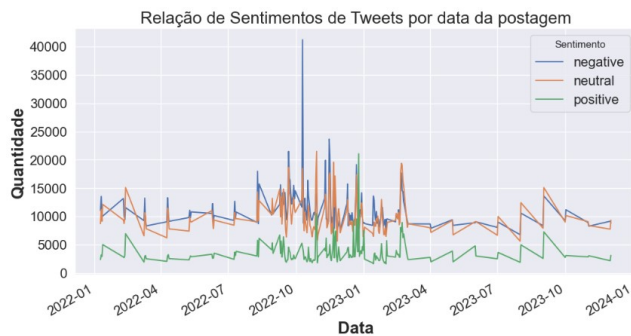


Figura 9: Predominância de sentimentos por data da postagem dos tweets

Para aprofundar nossa análise de sentimentos e identificar as palavras mais relevantes associadas a cada classe de sentimento, empregamos a criação de word clouds específicas para cada categoria identificada. Com o objetivo de aprimorar a qualidade visual dessas representações gráficas, procedemos à inclusão de termos como "http" e "user" no conjunto de stopwords a serem excluídas durante




Figura 10: Distribuição de Polaridades

a geração das word clouds, ampliando o conjunto de stopwords fornecido pela biblioteca NLTK. A incorporação desses termos foi necessária devido ao pré-processamento dos dados, que envolveu a remoção de URLs e nomes de usuários precedidos pelo caractere "@" dos textos analisados. Essa etapa de pré-processamento é fundamental para a obtenção de ideias mais precisas e significativas a partir das word clouds.

3.6 Análise e Classificação de Emoções

Nesta subseção, descrevemos a metodologia adotada para a realização da análise de emoções presentes nos Tweets.

Para a análise e classificação de emoção, mais especificamente para Tweets em inglês, foi selecionado o modelo twitter-roberta-base-emotion-multilabel-latest ([6]), um modelo de processamento de linguagem natural pré-treinado e programado em Python. A documentação do modelo pode ser encontrada no site Hugging Face. Este modelo é adequado para inglês e baseado em roBERTa,

O modelo "twitter-roberta-base-emotion-multilabel-latest" é uma versão refinada do modelo "cardiffnlp/twitter-roberta-base-2022-154m" que foi treinado para a tarefa de classificação multirrotulo do Sentimento em Tweets (Affect in Tweets) no contexto do SemEval 2018 - Task 1.

Este modelo se destaca por seu desempenho em várias métricas de avaliação. Nas avaliações feitas no conjunto de teste, o modelo atingiu os seguintes resultados:

- F1 (micro): 0.7169
- F1 (macro): 0.5464
- Jaccard Index (amostras): 0.5970

Em termos simples, essas métricas indicam o quão bem o modelo é capaz de prever os sentimentos expressos em Tweets, considerando várias classes possíveis. Um F1 (micro) de 0.7169 indica um bom desempenho geral do modelo em termos de precisão e recall. O F1 (macro) de 0.5464 fornece uma média das pontuações F1 para cada classe individual, enquanto o Jaccard Index de 0.5970 mede a similaridade entre as previsões do modelo e os rótulos reais.

Essas métricas refletem a capacidade do modelo de compreender e classificar os sentimentos expressos em Tweets de acordo com várias categorias, tornando-o uma ferramenta valiosa para análise de sentimentos em textos curtos, como aqueles encontrados no Twitter.

Para otimização do processo de classificação de emoções, optamos por extrair uma amostra de dados de 250MB, garantindo uma abordagem viável em termos de processamento computacional. Essa

estratégia de amostragem permite a análise eficiente de emoções em textos extensos, mantendo a representatividade dos dados coletados. Essa abordagem é essencial para atender às necessidades de processamento em cenários onde a escala completa dos dados pode ser proibitiva do ponto de vista computacional.

Este modelo de classificação de emoções é capaz de identificar uma variedade de emoções com base nas seguintes classes:

- Raiva (anger)
- Antecipação (anticipation)
- Medo (fear)
- Alegria (joy)
- Amor (love)
- Otimismo (optimism)
- Pessimismo (pessimism)
- Tristeza (sadness)
- Surpresa (surprise)
- Confiança (trust)

Essas classes representam as emoções presentes nos textos analisados e são avaliadas com base em pontuações, conhecidas como "Scores". O Score é uma medida numérica que quantifica a intensidade de uma emoção específica em um texto. O modelo de análise de sentimentos atribui esses valores numéricos a cada classe de emoção, indicando a probabilidade daquela emoção estar presente no texto.

Para fins de análise, associamos cada Tweet à emoção com o maior Score em sua classificação, permitindo-nos identificar a emoção predominante em cada mensagem.

Nossas observações revelam uma predominância de emoções como raiva, antecipação e medo, e total ausência do sentimento de amor e surpresa (conforme mostrado na Figura 11). Além disso, notamos que a distribuição dessas emoções se destaca, especialmente em países como Bélgica e Islândia (conforme ilustrado na Figura 12).

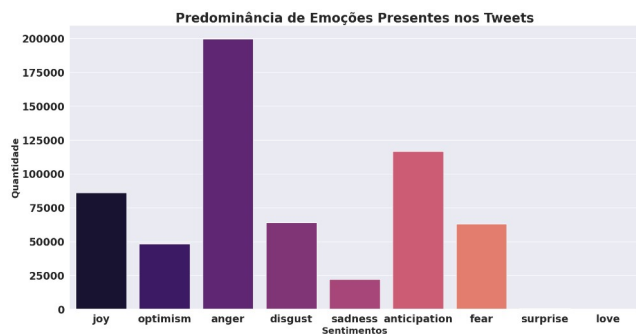


Figura 11: Predominância de Emoções nos Tweets

4 AVALIAÇÃO

Esta seção discute o processo de validação, seu objetivo e as métricas utilizadas para medir o desempenho dos modelos.

A validação desempenha um papel fundamental na avaliação do desempenho e na confiabilidade dos modelos de análise de sentimentos e emoção. O objetivo desta etapa é determinar quão eficazes e confiáveis são os modelos de análise de sentimentos e emoção,




Figura 12: Proporção de Emoções dos Tweets com base na localização




Figura 13: Fluxo da metodologia adotada no estudo

neste contexto, mais especificamente o modelo RoBERTa, que foi utilizado para realização das classificações de sentimento e emoção. Para atingir esse objetivo, seguimos um procedimento estruturado que envolve o treinamento e teste dos modelos, bem como o cálculo de métricas de avaliação

Para avaliar o desempenho, aplicamos vários algoritmos de classificação, incluindo Bernoulli, K Nearest Neighbors, Decision Tree Classifier, Random Forest Classifier, Logistic Regression e Support Vector Classification. O processo de avaliação envolve o cálculo de várias métricas-chave para cada modelo, que incluem:

$$\text{Acurácia} = \frac{\text{Verdadeiros Positivos} + \text{Verdadeiros Negativos}}{\text{Total de Amostras}} \quad (1)$$

$$\text{Recall} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Negativos}} \quad (2)$$

$$\text{Precisão} = \frac{\text{Verdadeiros Positivos}}{\text{Verdadeiros Positivos} + \text{Falsos Positivos}} \quad (3)$$

$$\text{F1-score} = 2 \cdot \frac{\text{Precisão} \cdot \text{Recall}}{\text{Precisão} + \text{Recall}} \quad (4)$$

Inicialmente foi realizada a seleção dos modelos com a instância de algoritmos de classificação da biblioteca scikit-learn, que é um conjunto abrangente de ferramentas para aprendizado de máquina em Python.

O treinamento dos modelos foi conduzido utilizando os dados recém classificados pelo modelo RoBERTa que é pré-treinado. A classificação do RoBERTa forneceu as categorias dos sentimentos e emoções para cada Tweet no conjunto de dados de teste. Essas classificações foram utilizadas como rótulos para o treinamento dos modelos de classificação. Essa abordagem permitiu que os modelos aprendessem a mapear os recursos dos Tweets para as categorias de sentimentos de maneira supervisionada.

Após o treinamento dos modelos, foi realizada a etapa de avaliação para medir o desempenho de cada algoritmo de classificação. Foi utilizada a biblioteca metrics do scikit-learn para o cálculo das métricas de avaliação.

As Tabelas 1, 2, 3, 4 e 5 apresentam as métricas de avaliação para cada modelo referente a classificação de sentimentos pelo modelo Roberta.

Tabela 1: Avaliações do Modelo Bernoulli

	Precision	Recall	F1-Score	Support
Negative	0.94	0.92	0.93	4794
Neutral	0.79	0.93	0.86	3698
Positive	0.99	0.62	0.76	1537
Accuracy			0.88	10029

5 RESULTADOS E DISCUSSÃO

Durante as análises foram identificados padrões e tendências interessantes relacionados aos Tweets analisados. Os resultados são apresentados através de uma combinação de gráficos de linhas,

Tabela 2: Avaliações do Modelo de Regressão Logística

Classe	Precision	Recall	F1-Score	Support
Negative	0.95	0.96	0.95	4794
Neutral	0.91	0.92	0.92	3698
Positive	0.93	0.89	0.91	1537
			Accuracy	0.93

Tabela 3: Avaliações do Modelo Árvore de decisão

Classe	Precision	Recall	F1-Score	Support
Negativo	0.92	0.90	0.91	4794
Neutro	0.85	0.88	0.87	3698
Positivo	0.86	0.84	0.85	1537
			Accuracy	0.93

Tabela 4: Avaliações do Modelo K-Nearest Neighbors

Classe	Precision	Recall	F1-Score	Support
Negative	1.00	0.71	0.83	4794
Neutral	0.67	0.97	0.79	3698
Positive	0.87	0.71	0.78	1537
			Accuracy	0.93

Tabela 5: Avaliações do Modelo Support Vector Classification

Classe	Precision	Recall	F1-Score	Support
Negative	0.95	0.96	0.96	4794
Neutral	0.92	0.92	0.92	3698
Positive	0.93	0.90	0.92	1537
			Accuracy	0.93

wordclouds, Heatmaps e gráficos de barras empilhadas, que correlacionam sentimentos, emoções e atributos, como tempo e localização.

Observou-se uma predominância de Tweets originários de países ocidentais, incluindo Estados Unidos, Ucrânia, Canadá, Inglaterra, França e Índia. Essa concentração sugere um maior volume de postagens provenientes desses locais (Figura 2).

Quanto à análise de sentimentos, observou-se uma prevalência de sentimentos negativos e neutros nos Tweets. No entanto, vale ressaltar que os Tweets classificados como positivos se destacam por apresentarem mensagens de apoio aos ucranianos, expressando palavras de afirmação e esperança. Esse fator contribuiu para um aumento significativo nas pontuações de sentimentos positivos.

Além disso, evidenciou-se um viés notável nos Tweets com sentimentos positivos. Foram identificadas práticas inadequadas, como o uso inadequado de hashtags relacionadas à Ucrânia para discutir assuntos pessoais ou não relacionados ao tema. Além disso, alguns Tweets apresentaram um tom irônico e debochado, uma característica comum na plataforma Twitter.

A Tabela 6 exhibe exemplos de Tweets classificados com sentimentos positivos com base na análise do modelo Roberta:

Foi observado um número significativo de uso das hashtags "Ukraine," "Bakhmut," "StandWithUkraine," e "RussiasATerrorist-State" nas mensagens analisadas 3, demonstrando um notável apoio

veja-como-conflito-afetou-a-economia-do-brasil-e-do-mundo. Acesso em: 17 set. 2023.

[15] Reuters. 2023. Musk diz que plataforma X atingiu novo recorde de usuários mensais. Disponível em: <https://www.infomoney.com.br/negocios/musk-diz->

que-plataforma-x-atingiu-novo-recorde-de-usuarios-mensais/. Acesso em: 21 out. 2023.