



**Universidade de Brasília
Faculdade de Tecnologia**

**Análise Sentimental Espaço-temporal em
Relação ao Benefícios e Desvantagens do Uso
da IA com Base em Dados do Twitter**

Gabriely Souza Mendes Montes

TRABALHO DE CONCLUSÃO DE GRADUAÇÃO
ENGENHARIA DE REDES DE COMUNICAÇÃO

Brasília
2023

**Universidade de Brasília
Faculdade de Tecnologia**

**Análise Sentimental Espaço-temporal em
Relação ao Benefícios e Desvantagens do Uso
da IA com Base em Dados do Twitter**

Gabriely Souza Mendes Montes

Trabalho de Graduação submetido ao Departamento de Engenharia Elétrica como requisito parcial para obtenção do grau de Engenheira de Redes de Comunicação

Orientador: Prof. Dr. Fábio Lúcio Lopes de Mendonça

Brasília
2023

M769a Montes, Gabriely Souza Mendes. , .
Análise Sentimental Espaço-temporal em Relação ao
Benefícios e Desvantagens do Uso da IA com Base em
Dados do Twitter / Gabriely Souza Mendes Montes; orientador Fábio Lúcio Lopes de Mendonça. -- Brasília, 2023.
72 p.

Trabalho de conclusão de Graduação (Engenharia de
Redes de Comunicação) -- Universidade de Brasília, 2023.

1. Inteligência Artificial (IA). 2. Análise de Sentimentos.
3. Plataforma X. 4. Processamento de Linguagem Natural
(PLN). I. Lúcio Lopes de Mendonça, Fábio , orient. II. Título

**Universidade de Brasília
Faculdade de Tecnologia**

**Análise Sentimental Espaço-temporal em Relação ao
Benefícios e Desvantagens do Uso da IA com Base em
Dados do Twitter**

Gabriely Souza Mendes Montes

Trabalho de Graduação submetido ao Departamento de Engenharia Elétrica como requisito parcial para obtenção do grau de Engenharia de Redes de Comunicação

Prof. Dr. Fábio Lúcio Lopes de Mendonça,
(EnE/UnB)
Orientador

Prof. Dr. Daniel Alves da Silva,
(EnE/UnB)
Examinador interno

Profa. Dra Edna Dias Canedo, (CIC/UnB)
Examinador externo

Brasília
2023

Eu dedico esse trabalho a minha família que sempre esteve ao meu lado.

Agradecimentos

Agradeço primeiramente a Deus por ter me destinado pessoas incríveis para estarem ao meu lado durante esse momento árduo que é a escrita do trabalho de conclusão de curso. Agradeço aos meus pais, por terem me dado o dom da vida, pelo incentivo e motivação...

*“Escolheremos o nosso próximo mundo através daquilo
que aprendermos neste. Não aprender nada
significa que o próximo mundo será igual a este,
com as mesmas limitações e
pesos de chumbo a vencer.”
(Richard Bach)*

Resumo

A análise sentimental é uma área de pesquisa que utiliza métodos de mineração de textos com o objetivo de entender o comportamento humano com base em escritas e falas. Tais técnicas têm sido utilizadas para identificar tendências e obter informações de grandes bases de dados textuais.

Dando um passo adiante, este trabalho tem como objetivo propor um Framework para investigar as emoções dos usuários do *X (ex-Twitter)* em relação aos benefícios e desvantagens do uso da Inteligência Artificial (IA). O Framework utiliza ferramentas de processamento de linguagem natural, que incluem o pré-processamento dos dados de entrada. Ele aplica algoritmos de aprendizado de máquina para classificar novos textos, baseando-se em conjuntos de dados previamente analisados.

Este estudo se destaca pela utilização do algoritmo *SVM* para uma análise dos sentimentos, complementada pela análise temporal que revela como as percepções sobre a IA evoluem. A validação dos resultados é reforçada pela matriz de confusão, garantindo confiabilidade.

As métricas de *Accuracy*, *Precision*, *Recall* e *F1-Score* são cruciais para ilustrar a eficácia do modelo. Elas demonstram não apenas a precisão e a abrangência do framework, mas também sua aplicabilidade prática, oferecendo insights valiosos para a análise de sentimentos no contexto da Inteligência Artificial.

Palavras-chave: Inteligência Artificial (IA). Análise de Sentimentos. Plataforma X. Processamento de Linguagem Natural (PLN).

Abstract

Sentiment analysis is a research area that utilizes text mining methods to understand human behavior based on writings and speeches. Such techniques have been used to identify trends and gather information from large textual databases.

Taking a step further, this work aims to propose a Framework for investigating the emotions of users of *X* (*ex-Twitter*) regarding the benefits and disadvantages of using Artificial Intelligence (AI). The Framework employs natural language processing tools, including the preprocessing of input data. It applies machine learning algorithms to classify new texts based on previously analyzed data sets.

This study stands out for its use of the *SVM* algorithm for sentiment analysis, complemented by temporal analysis that reveals how perceptions of AI evolve. The validation of the results is enhanced by the confusion matrix, ensuring reliability.

The metrics of *Accuracy*, *Precision*, *Recall*, and *F1-Score* are crucial in illustrating the model's effectiveness. They demonstrate not only the precision and comprehensiveness of the framework but also its practical applicability, offering valuable insights for sentiment analysis in the context of Artificial Intelligence.

Keywords: Artificial Intelligence (AI). Sentiment Analysis. Plataform X. Natural Language Processing (NLP).

Lista de ilustrações

Figura 2.1 – Tipos de Métodos de Aprendizagem (BARRETO, 2018)	21
Figura 2.2 – Treinamento de um modelo de aprendizado de máquina supervisionado (PRUDÊNCIO, 2014)	22
Figura 3.1 – Arquitetura utilizada Fonte: Elaborado pela autora (2023)	27
Figura 3.2 – Fluxo de Construção do <i>dataseet</i> Fonte: Elaborado pela autora (2023) . .	28
Figura 3.3 – Fluxograma das etapas de extração, Fonte: Elaborado pela autora (2023)	31
Figura 3.4 – Erro CSP, Fonte: Coletado pela autora (2023)	31
Figura 3.5 – Antes do CSP, Fonte: Coletado pela autora (2023)	32
Figura 3.6 – Abrindo Chrome sem CSP, Fonte: Coletado pela autora (2023)	33
Figura 3.7 – Depois CSP, Fonte: Coletado pela autora (2023)	33
Figura 3.8 – Processo de escolha e construção de tópicos e filtro, Fonte: Elaborado pela autora (2023)	34
Figura 3.9 – Configuração da seleção de palavras chaves, Fonte: Elaborado pela autora (2023)	34
Figura 3.10–Filtro final, Fonte: Elaborado pela autora (2023)	35
Figura 3.11–Interface do Azure Blob Storage, Fonte: Coletado pela autora (2023) . .	37
Figura 3.12–Termo de Consentimento aplicado no questionário <i>Survey</i> , Fonte: Elaborado pela autora (2023)	43
Figura 4.1 – Gráfico representando a quantidade de dados armazenados no BlobStorage em relação ao tempo de extração. Fonte: Servidor BlobStorage. Tradução para o Português realizada pela autora em Dezembro de 2023.	45
Figura 4.2 – Gráfico de <i>posts</i> coletados por mês. Fonte: Servidor BlobStorage. Tradução para o Português realizada pela autora em Dezembro de 2023.	46
Figura 4.3 – Gráfico de marcos da IA interseccionado com <i>posts</i> coletados por mês. Fonte: Realizada pela autora em Dezembro de 2023.	47
Figura 4.4 – Gráfico de marcos da IA interseccionado com <i>posts</i> coletados por mês. Fonte: Realizada pela autora em Dezembro de 2023.	47
Figura 4.5 – Matriz de Confusão Fonte: Elaborado pela autora (2023)	49
Figura 4.6 – Gráfico de respostas sobre impactos da IA no emprego Fonte: Elaborado pela autora (2023)	51
Figura 4.7 – Relação entre crença na criação de empregos pela IA e a percepção de preparo Fonte: Elaborado pela autora (2023)	51
Figura 4.8 – Confiabilidade na justiça da IA e na precisão da em relação à análise de sentimentos Fonte: Elaborado pela autora (2023)	53
Figura 4.9 – Confiabilidade na justiça da IA e na precisão da em relação à análise de sentimentos relacionada à idade Fonte: Elaborado pela autora (2023) . .	53

Figura 4.10–Percepção da influência da IA na educação Fonte: Elaborado pela autora (2023)	54
Figura 4.11–Gráfico de pessoas que acreditam que a IA poderá substituir os seres humano em suas tomadas de decisão Fonte: Elaborado pela autora (2023)	55
Figura 4.12–Grupo de Tecnologia quem acham que a IA irá substituir os Seres Humanos. Fonte: Elaborado pela autora (2023)	55
Figura 4.13–Nuvem de palavras do Survey Fonte: Elaborado pela autora (2023) . . .	56
Figura 4.14–Gráfico com frequência das Naturezas nas Respostas Fonte: Elaborado pela autora (2023)	57
Figura 4.15–Gráficos sobre Categorias Opinião e Assunto Fonte: Elaborado pela autora (2023)	57
Figura 4.16–Gráfico sobre Natureza sentimentos e sugestões	58
Figura 4.17–Gráfico representando emoções positivas, negativas e neutras entre as duas fontes de dados Fonte: Elaborado pela autora (2023)	59
Figura 4.18–Resultados de análises após treino do dataset expressando natureza do sentimento, como euforia, medo, preocupação e satisfação Fonte: Elaborado pela autora (2023)	59
Figura 4.19–Nuvens de palavras antes da limpeza de dados Fonte: Elaborado pela autora (2023)	60
Figura 4.20–Nuvens de palavras antes da limpeza de dados	60

Lista de tabelas

Tabela 3.1 – Classificação de Naturezas e Categorias	36
Tabela 3.2 – Questionário aplicado	44
Tabela 4.1 – Exemplo de <i>posts</i> após retirada de Stopwords e Caracteres Indesejados .	48
Tabela 4.2 – Exemplo de <i>posts</i> após a aplicação de técnicas de Tokenização e Lemmatization.	48
Tabela 4.3 – Exemplo de dados classificados para treinamento	49

Lista de abreviaturas e siglas

API	<i>Application Programming Interface</i>	15
ASLN	<i>Aprendizagem Supervisionada para Linguagem Natural</i>	15
CSP	<i>Política de Segurança de Conteúdo</i>	15
CSV	<i>Comma-Separated Values</i>	15
HTTPS	<i>Hyper Text Transfer Protocol Secure</i>	15
IA	<i>Inteligência Artificial</i>	15
LLM	<i>Large Language Models</i>	15
ML	<i>Machine Learning ou Aprendizado de Máquina</i>	15
MNB	<i>Multinomial Naive Bayes</i>	15
NLTK	<i>Natural Language Toolkit</i>	15
PLN	<i>Processamento de Linguagem Natural</i>	15
SA	<i>Análise de Sentimentos</i>	15
SGDC	<i>SGDClassifier</i>	15
SVM	<i>Support Vector Machines</i>	15
SVM	<i>Support Vector Machines</i>	18
TF	<i>Term Frequency</i>	15
TF-IDF	<i>Term Frequency-Inverse Document Frequency</i>	15
XSS	<i>Cross-Site Scripting</i>	15

Sumário

1	Introdução	15
1.1	Contextualização	15
1.2	Formulação do Problema	16
1.3	Objetivo Geral	16
1.4	Objetivos Específicos	16
1.5	Justificativa	17
1.6	Organização do Trabalho	17
2	Fundamentação Teórica e trabalhos correlatos	18
2.1	Plataforma X (<i>ex-Twitter</i>)	19
2.2	Inteligência Artificial e Machine Learning	20
2.2.1	Técnicas de Machine Learning	20
2.2.2	Aprendizado Supervisionado	20
2.3	Mineração de dados	22
2.3.1	Processamento de Linguagem Natural (PLN)	22
2.3.2	Análise de Sentimentos	23
2.3.3	Teorias e Modelos de Análise de Sentimentos	25
3	Metodologia de Pesquisa e Arquitetura Proposta	26
3.1	Caracterização da Pesquisa	26
3.2	Delimitações do Trabalho	26
3.3	Modelo de Arquitetura para Análise de Sentimentos	27
3.4	Elaboração do Database	27
3.4.1	Escolha da Ferramenta de Extração	29
3.4.2	Seleção de Filtros e Categorização de Texto	34
3.4.3	Armazenamento de Dados	37
3.5	Machine Learning	38
3.5.1	Pré-processamento de Dados	38
3.5.2	Treinamento do Modelo	41
3.6	Desenvolvimento do Questionário	42
4	Resultados e Discussões	45
4.1	Análise de Dados da Plataforma X	45
4.1.1	Coleta de Dados e elaboração do database	45
4.1.2	Pré-processamento de Dados	47
4.1.3	Treinamento do dataset	49

4.2	Análise de dados do Survey	50
4.2.1	Percepções sobre Impactos da IA no Emprego	50
4.2.2	Confiabilidade na precisão da IA	52
4.2.3	Futuro da IA	54
4.3	Análise de tendências sobre a IA um comparativo entre a PlataformaX e o Survey	58
5	Conclusão	61
5.1	Trabalhos Futuros	62
	Referências	63
	Apêndice A Códigos e Scripts	66
A.1	Script de Raspagem de Tweets	66
A.2	Armazenamento de Dados de Tweets em Azure Blob Storage	67
A.3	Automação de Coleta e Armazenamento de Dados de Tweets	68
A.4	Código Python para Geração de Nuvem de Palavras	69
A.5	Código Python para Limpeza de Dados	70
A.6	Código Python para Treinamento de Sentimento	71

1 Introdução

Nos últimos anos, a Inteligência Artificial (IA) emergiu como uma tecnologia disruptiva que está transformando diversos aspectos da sociedade. Uma das áreas onde a IA tem tido um impacto significativo é na análise de dados em tempo real, especialmente em mídias social, como a Plataforma X (*ex-Twitter*).

A IA envolve o agrupamento de várias tecnologias, como redes neurais artificiais, algoritmos, sistemas de aprendizado, entre outros, que conseguem simular capacidades humanas ligadas ao aprendizado, solução de problemas, compreensão da linguagem e tomada de decisões (GOMES, 2010). Além disso, ela sistematiza e automatiza tarefas e, portanto, é potencialmente relevante para qualquer esfera da atividade intelectual humana, tornando-se multidisciplinar.

Com bilhões de *posts* gerados diariamente em todo o mundo, a Plataforma X tornou-se uma rica fonte de informações que podem ser exploradas para entender as opiniões e sentimentos das pessoas sobre uma ampla gama de tópicos (WE ARE SOCIAL, 2023). Neste contexto, este trabalho de pesquisa concentra-se na análise sentimental espaço-temporal para investigar os benefícios e desvantagens do uso da IA na interpretação de dados da Plataforma X.

Este estudo se destaca pela abordagem única na extração de dados da Plataforma X, superando limitações da API e analisando cuidadosamente as políticas de segurança da plataforma. Este trabalho visa unir estudos prévios sobre análise de sentimentos relacionados à IA, coletando uma quantidade significativa de *posts* da Plataforma X, de forma que enriquece a compreensão das percepções públicas sobre a IA e estabelece uma base sólida para futuras pesquisas neste campo dinâmico.

1.1 Contextualização

A trajetória da inteligência artificial (IA) iniciou-se na metade do século XX, quando cientistas começaram a explorar a criação de mecanismos digitais capazes de realizar atividades anteriormente exclusivas à inteligência humana. Composta por um conjunto de ferramentas que unem dados, alta capacidade de processamento e algoritmos sofisticados, a IA é capaz de processar e aprender com grandes volumes de informações (MEDEOT, 2023)

Na atualidade, a IA visa agregar inteligência às máquinas, melhorando processos e assumindo tarefas complexas, como influenciar opiniões e entender dinâmicas sociais (GANTORI, 2017) e por esse motivo, é fundamental considerar as oscilações de humor e expectativas em relação à IA (SICHMAN, 2021).

Do âmbito do cenário social, oferece grandes benefícios mas enfrenta grandes desafios, como questões éticas e riscos de segurança cibernética. A análise de sentimentos na Plataforma X, como um estudo de caso, visa realizar uma análise dos dados, permitindo uma reflexão à essa dualidade, explorando como a sociedade percebe a IA, buscando compreender esses sentimentos e tendências (SICHMAN, 2021).

No contexto da utilização da Inteligência Artificial (IA) na educação, observa-se um potencial transformador tanto em metodologias de ensino quanto na preparação para o futuro do trabalho. E, ao ser integrada nos processos educativos, possibilita a personalização do ensino, adaptando-se às necessidades e ao ritmo de aprendizado de cada aluno. Ferramentas baseadas em IA podem analisar interações e desempenhos dos alunos para otimizar estratégias de ensino, tornando a educação mais eficiente e alinhada com as habilidades individuais.

Sendo assim, a compreensão destes aspectos, conforme sugerido por Sichman, permite insights significativos e uma interpretação mais completa e responsável dos sentimentos e tendências. E a análise sentimental espaço-temporal não só revela percepções e opiniões públicas, mas também reflete a evolução contínua da relação da sociedade com a IA e implicações sociais, além de tendências emergentes no campo (SICHMAN, 2021).

1.2 Formulação do Problema

A crescente integração da IA em diversas esferas sociais e econômicas tem levantado questões significativas sobre seus benefícios e desvantagens. A Plataforma X, uma plataforma de mídia social amplamente utilizada, serve como um rico repositório de dados para explorar essas dinâmicas. Esta pesquisa visa investigar como a IA pode ser aplicada para analisar sentimentos de usuários da Plataforma X em diferentes contextos espaciais e temporais, considerando as implicações éticas, sociais e técnicas dessa aplicação.

1.3 Objetivo Geral

Propor um framework para entender e prever sentimentos a partir de textos da Plataforma X, refletindo opiniões dos usuários sobre o impacto da IA em suas vidas diárias e na sociedade como um todo.

1.4 Objetivos Específicos

- Realizar uma revisão literária abrangente, incluindo estudos recentes, sobre análise de sentimentos no contexto da IA.

- Utilizar técnicas de *Web Scraping* para extrair dados da Plataforma X.
- Implementar um algoritmo para classificar as percepções das pessoas usuárias da Plataforma X sobre o impacto do avanço da Inteligência Artificial.
- Utilizar técnicas de Aprendizado de Máquina ou *Machine Learning (ML)* detectar padrões e tendências em textos curtos da Plataforma X.
- Utilizar um algoritmo de clustering para analisar a distribuição das objeções por categoria.
- Conduzir um *survey* detalhado para correlacionar as emoções detectadas com a experiência real dos usuários, através de um questionário.
- Propor um modelo de análise de emoções no contexto da IA.

1.5 Justificativa

A análise de sentimentos é uma ferramenta poderosa para compreender as percepções públicas e pode ter implicações significativas em campos como saúde, negócios e educação. A compreensão das dimensões espaciais e temporais desses sentimentos oferece insights valiosos sobre como as atitudes públicas se formam e mudam. Este estudo também abordará os desafios éticos e sociais da IA, como o potencial para viés e manipulação, buscando orientar práticas responsáveis e éticas no uso da IA, especialmente em plataformas de mídia social como a Plataforma X.

1.6 Organização do Trabalho

Este trabalho é composto por cinco capítulos, incluso este primeiro de introdução.

O segundo capítulo trata das tecnologias e técnicas utilizadas para construção e validação dos resultados, como: Técnicas de Inteligência Artificial, *Machine Learning (ML)*, mineração de dados e Processamento de Linguagem Natural - PLN, os conceitos do que foi aplicado e dos desafios encontrados.

O terceiro capítulo apresenta implantação da arquitetura proposta, com a coleta de dados da Plataforma X, as instalações e configurações realizadas, procedimentos de coleta de dados e apresentação dos dados. Também é neste onde serão apresentados os diferentes cenários utilizados nos testes, e por fim a arquitetura final.

O quarto capítulo apresenta os testes e resultados realizados em cada cenário e a análise dos resultados obtidos.

O quinto capítulo conclui este trabalho trazendo a consolidação dos resultados e a validação da proposta, além da indicação de trabalhos futuros.

2 Fundamentação Teórica e trabalhos correlatos

Este capítulo dedica-se a explorar profundamente as tecnologias e teorias subjacentes à análise de sentimentos, com foco especial no uso de Inteligência artificial (IA) e Processamento de Linguagem Natural (PNL) para avaliar dados da Plataforma X. A discussão será ancorada em uma variedade de artigos e documentos que fornecem insights relevantes ou orientações para este trabalho.

Será abordado o que constitui de análise de sentimento, enfocando como as emoções e opiniões são interpretadas e categorizadas através do uso de tecnologias avançadas de IA. Além disso, será detalhadas as técnicas específicas de PNL e algoritmos de aprendizado de máquina que serão cruciais para analisar eficientemente grandes volumes de dados da Plataforma X.

A importância de compreender os aspectos espaços-temporais dos dados da Plataforma X será enfatizada, ilustrando como a análise de sentimentos pode variar em diferentes contextos e períodos. Isso inclui uma discussão sobre métodos e ferramentas usados para capturar e analisar esses nuances.

O papel da IA na melhoria e nos desafios que ela apresenta na análise de dados também será discutido. Explorar-se-á como a IA pode ampliar a compreensão dos sentimentos humanos expressos online e os desafios técnicos e éticos que acompanham essa tecnologia. Serão examinados estudos de caso e exemplos práticos para ilustrar esses conceitos.

O capítulo também discutirá o papel dual da IA na análise de dados da Plataforma X, abordando tanto as melhorias quanto os desafios técnicos e éticos associados. Além disso, integrará exemplos práticos e estudos de caso para ilustrar a aplicação dessas tecnologias, consolidando uma compreensão holística do tema.

2.1 Plataforma X (ex-Twitter)

A Plataforma X, agora nomeado como X, é uma plataforma de microblogging influente desde seu lançamento em 2006 por suas listas de tendências, destacando tópicos mais discutidos em âmbito global, incentivando debates atuais e criando amplas redes de comunicação e discussões.

Segundo Kaplan, as mídias sociais é definida como "um grupo de aplicações baseadas na Internet que constroem a ideologia e a base tecnológica da Web 2.0 e que permitem a criação e troca de conteúdo gerado pelo usuário"(KAPLAN; HAENLEIN, 2010), tornando-as fundamentais para entender as dinâmicas de comunicação modernas.

Até outubro de 2023, a Plataforma X já ultrapassou 1.3 bilhões de contas, com mais de 660 milhões de usuários atingidos mensalmente por anúncios na plataforma, um aumento de 18% em apenas 90 dias, e espera-se que esse número alcance 652,23 milhões até 2028. Em agosto de 2023, o site *Twitter.com* registrou mais de 1.4 bilhões de visitantes únicos, consolidando-se como um dos destinos mais populares na web"(WE ARE SOCIAL, 2023).

Em termos **demográficos**, a maioria do público (38,5%) pertence ao grupo etário de 25 a 34 anos, com uma divisão de gênero de 56,4% masculino e 43,6% feminino (WE ARE SOCIAL, 2023). Esses dados demográficos fornecem uma base substancial para análises detalhadas de sentimentos e comportamentos (SPINDOLA; SANTOS, 2023).

Além disso, a **natureza do uso** da rede social é significativa para pesquisas em IA pois um usuário passa cerca de 30,9 minutos na plataforma todos os dias, acumulando mais de 15 horas mensais (WE ARE SOCIAL, 2023). A tendência dos usuários de se engajar mais com eventos ou tendências oferece uma janela única para entender como as pessoas reagem a estímulos específicos em tempo real (SPINDOLA; SANTOS, 2023) .

E embora a Plataforma X ocupe a 15ª posição em termos de usuários ativos mensais, sua popularidade como a 7ª mídia social mais usada globalmente o torna um recurso valioso para a pesquisa acadêmica. E ao contrário de outras plataformas de mídia social que priorizam conteúdo visual ou interações prolongadas, ele se destaca por sua brevidade e imediatismo.

Essa característica não só influencia a maneira como as pessoas expressam sentimentos e opiniões, mas também oferece um conjunto único de dados para análise de sentimentos, capturando reações instantâneas, fornecendo dados concisos e diretos para análise (SPINDOLA; SANTOS, 2023).

2.2 Inteligência Artificial e Machine Learning

A intersecção entre Inteligência Artificial (IA) e Aprendizado de Máquina (ML), também conhecido como Machine Learning, representa um campo dinâmico e em constante evolução, crucial para a análise de Big data. Os modelos de ML, aplicados no contexto da IA, são fundamentais para interpretar e classificar sentimentos expressos, utilizando técnicas que permitem que computadores aprendam ao processar grandes volumes de dados e identificando padrões complexos. Eles são especialmente úteis em análises de sentimentos, onde a IA, através de algoritmos de ML e Processamento de Linguagem Natural, analisa opiniões e emoções expressas em linguagem natural, oferecendo insights valiosos sobre percepções públicas e tendências sociais.

2.2.1 Técnicas de Machine Learning

O *Aprendizado de Máquina (ML)* é uma ramificação vital da inteligência artificial e está reformulando não apenas como o ser humano interage com a tecnologia, mas também como entende e processa a imensa quantidade de dados gerados diariamente.

Em seu trabalho pioneiro, Samuel descreve *Machine Learning* como "a área da inteligência artificial que se concentra no desenvolvimento de sistemas capazes de aprender a partir de dados, identificar padrões e tomar decisões com mínima intervenção humana" (SAMUEL, 1959). Este estudo é considerado um dos primeiros e mais influentes na área de ML, e descreve como o campo de estudo que dá aos computadores a capacidade de aprender sem serem explicitamente programados.

Enquanto Samuel (SAMUEL, 1959) enfatiza a capacidade das máquinas de aprender autonomamente através da experiência, Shalev-Shwartz e Ben-David apresentam um contraponto, destacando a importância dos fundamentos teóricos e algoritmos (SHALEV-SHWARTZ; BEN-DAVID, 2014). Este último oferece uma perspectiva mais aprofundada sobre os princípios matemáticos que regem o aprendizado de máquina.

Explorando as distintas abordagens, em sequência serão abordados os tipos de Machine Learning e algoritmos, como mostra na figura 2.1, seguidos de uma análise detalhada das técnicas de aprendizado supervisionado não supervisionado e aprendizado por reforço, culminando na discussão sobre a aplicabilidade desses métodos em diversos setores de pesquisa.

2.2.2 Aprendizado Supervisionado

O Aprendizado supervisionado onde o algoritmo é treinado com base em dados rotulados, ou seja, os dados em que a saída desejada é conhecida e está associada a cada exemplo de treinamento. Esses modelos são alimentados com amostras rotuladas e o objetivo

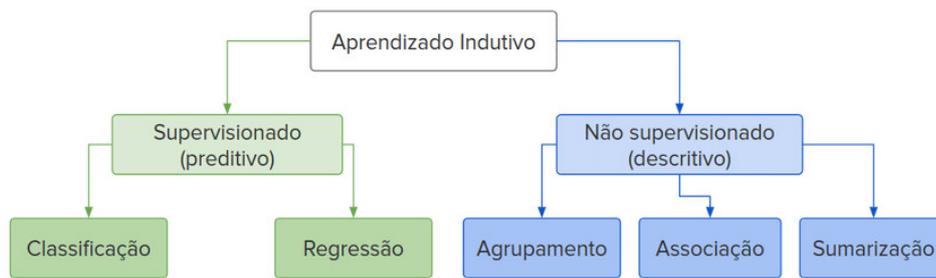


Figura 2.1 – Tipos de Métodos de Aprendizagem (BARRETO, 2018)

é que aprendam a fazer previsões precisas para novos dados. Os exemplos de algoritmos são regressão linear, árvore de decisão e redes neurais.

No aprendizado supervisionado depende de um conjunto de dados bem treinado para garantir a precisão usando função de perda e se ajusta ao longo do tempo para minimizar o erro.

Os algoritmos mais utilizados para o aprendizado supervisionado são: Support Vector Machines (SVM), Naive Bayes, Árvore de Decisão e Redes Neurais Artificiais

2.2.2.1 Support Vector Machines (SVM)

O SVM é um poderoso algoritmo de aprendizado supervisionado que é comumente usado para resolver problemas de classificação, mas também pode ser aplicado a problemas de regressão. Esse tipo de algoritmo possui três características importantes:

- **Fronteira de Separação:** O SVM procura encontrar a melhor fronteira de separação entre as classes de dados. Essa fronteira é chamada de "hiperplano de separação" e é definida de tal forma que maximiza a margem entre as classes. A margem é a distância entre o hiperplano e os pontos de dados mais próximos de cada classe, e o objetivo é encontrar o hiperplano que maximiza essa distância.
- **Classificação de Alta Dimensionalidade:** O SVM é eficaz em problemas de classificação em alta dimensionalidade, o que significa que ele pode lidar com conjuntos de dados que têm muitas características (ou dimensões). Isso o torna adequado para tarefas como processamento de imagem e reconhecimento de padrões, onde os dados podem ser representados em espaços de alta dimensionalidade.
- **Dados Linearmente Inseparáveis:** SVM pode lidar com dados que não podem ser separados por um hiperplano linear. Para fazer isso, ele utiliza uma técnica chamada "Kernel Trick". O Kernel Trick mapeia os dados originais para um espaço de maior dimensionalidade, onde eles se tornam linearmente separáveis. Isso permite que o SVM encontre um hiperplano de separação mesmo em casos em que a separação não seria possível no espaço original.

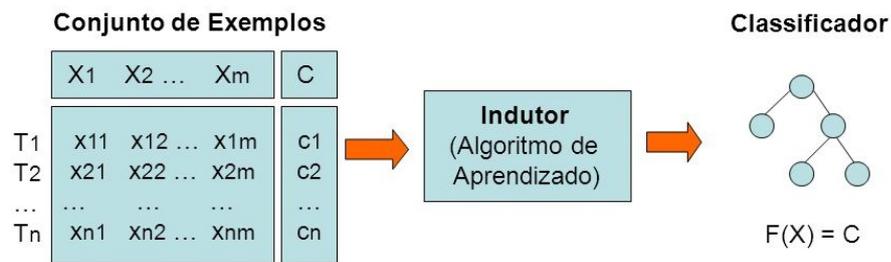


Figura 2.2 – Treinamento de um modelo de aprendizado de máquina supervisionado (PRUDÊNCIO, 2014)

O SVM é amplamente utilizado em uma variedade de domínios, incluindo classificação de texto, detecção de imagem, diagnóstico médico e muito mais.

Dois problemas comuns nesse tipo de aprendizado é o "underfitting" (quando o modelo é muito simples para o problema) e "overfitting" (quando o modelo se ajusta demais aos dados de treinamento). E esses problemas podem ser resolvidos utilizando técnicas de regularização, redução de dimensionamento e aumento de número de dados treinado.

2.3 Mineração de dados

2.3.1 Processamento de Linguagem Natural (PLN)

O entendimento da estrutura textual é um passo importante para que os computadores mediante tecnologias de processamento de linguagem natural (PLN) sejam capazes de compreender o significado em um texto.

Para tanto, além de soluções complexas de aprendizado de máquina que incorporam dicionários e modelos de dados específicos, também é importante frisar que conceitos que utilizam a estrutura textual e as respectivas ferramentas que realizam PLN também necessitam de técnicas específicas que auxiliem o reconhecimento de entidades da fonte de dados textual.

A PNL realiza o processamento e o entendimento linguístico das palavras em um texto e depois comparando a quantidade e qualidade das entidades que foram reconhecidas nos textos processados (SOUZA, E. N. P.; CLARO, 2014), (FINATTO; LOPES; SILVA, A. C., 2015). Nesse sentido, esse projeto propõe a construção de uma estrutura de processamento de dados, suportados por dicionários de dados específicos, com abordagem de aprendizado de máquina e processamento de linguagem natural e que seja capaz de fazer o reconhecimento de entidades em fontes de dados oficiais do estado brasileiro e criar estruturas de relacionamento automáticas.

A abordagem proposta fará uso de métodos de aprendizado supervisionado e a construção de modelos de linguagem grandes (Large Language Models - LLM) para que

possa ser criada uma estrutura própria para identificação, rotulagem, extração de entidades nomeadas com melhor qualidade do que os modelos de linguagem genéricos disponíveis atualmente.

De maneira mais específica, este propõe criar uma estrutura de processamento de dados que seja capaz de realizar a extração de informação significativa em termos do processo de aprendizagem de máquina para o processamento de linguagem natural, tendo como fonte de dados as informações oficiais de órgãos do estado brasileiro.

Existe uma grande dificuldade de processamento, pois a maior parte das informações disponíveis em informações oficiais não é estruturada. Na prática é mais complexo organizar e encontrar dados significativos. Por outro lado, os avanços em aprendizado de máquina e, mais especificamente, PLN trouxeram a possibilidade de explorar novas arquiteturas e modelos de linguagem que podem aumentar significativamente o desempenho de tarefas de reconhecimento de entidades e criar estruturas de processamento para a extração de relacionamentos de interesse automaticamente. (ALLES; GIOZZA; OLIVEIRA ALBURQUERQUE, 2018).

Nos últimos anos muitas ferramentas de PLN foram disponibilizadas publicamente nas mais variadas linguagens de programação, como Java, Python, R e C++. Entretanto a seleção de uma ferramenta de PLN adequada aos objetivos deste trabalho, envolve critérios específicos que requerem um conhecimento prévio dos recursos de extração, das possibilidades de extensão do modelo pretendido, dos documentos disponíveis, bem como a condição de aplicar os conceitos específicos de PLN ao idioma português do Brasil (RODRIGUES et al., 2022).

A ideia engloba a capacidade de processar textos em português brasileiro de fontes oficiais com suas restrições e características e analisar o que pode ser extraído de acordo com o que se deseja.

2.3.2 Análise de Sentimentos

A Análise de Sentimentos (SA) é uma área do Processamento de Linguagem Natural que permite detectar a presença de polaridade positiva, negativa ou neutra em um texto. O SA tornou-se um elemento de maior interesse devido ao aumento da geração de dados a partir da internet e aos esforços necessários para processar esse volume de dados.

Diante dessa demanda, busca-se obter resultados precisos que permitam a interpretação automática do sentimento inserido no texto. Vários métodos podem ser aplicados nesta tarefa, porém, nesta tese se destacam os aspectos e desafios em explorar a estrutura linguística da frase, para os quais as soluções são direcionadas a regras com as propriedades da gramática que descrevem a linguagem natural.

Vale ressaltar que estudos de soluções baseadas em regras também são motivados

pela exclusão de custos que envolvem treinamento de dados. Uma revisão do estado da arte, mostra que existem avanços nos estudos da linguística formal que contribuem para a linguística computacional, como regras de uma descrição sintática do português brasileiro já disponível na literatura, e não foram explorados para análise de sentimento.

Em particular, trabalhos com modelos restritos de regras e o uso de parsers foram detectados para definir as classes gramaticais, a estrutura da sentença e as relações de dependência. No entanto, nenhuma solução foi encontrada envolvendo uma gramática construída para descrever uma linguagem natural incorporada a um parser que analisa a estrutura da frase caracterizada especificamente pelo sentimento.

O principal resultado obtido com esta tese foi um novo modelo de análise de sentimento baseado em uma gramática regular expansível definida por regras de composição semântica. Assim, foi desenvolvido um parser que identifica estruturas de sentenças caracterizadas ou não com polaridade positiva ou negativa.

Para atender a essa solução, um conjunto de relações de sentimento entre categorias gramaticais foi estudado e desenvolvido a partir da descrição formal da estrutura da frase. Foi implementado um protótipo para testar a aplicação do modelo em corpora de sentenças e posteriormente para uma avaliação comparativa dos resultados, que apresentaram índices nos mesmos níveis obtidos por outros métodos.

A dificuldade de lidar com as emoções talvez explique a maior quantidade de léxico de polaridades do que de palavras de emoções ou sentimentos. No que se refere à língua portuguesa. Neste sentido existem métodos baseados em abordagens de aprendizado de máquina que compara métodos de classificação supervisionada.

Existem vários softwares que realizam análise baseada em sentimento. Dentre eles o O LIWC (TAUSCZIK; PENNEBAKER, 2010) é um software para análise de textos, baseado em um léxico que classifica as palavras de acordo com categorias psicologicamente significativas. As palavras se distribuem em 4 dimensões, e uma delas, *Psychological Processes*, contém a categoria *Affective Processes*, que por sua vez compreende as subcategorias *positive emoticons* (happy, pretty, good), *negative emotions* (hate, worthless, enemy), *anxiety* (nervous, afraid, tense), *anger* (hate, kill, pissed) e *sadness* (grief, cry, sad).

A existência de uma dimensão afetiva torna o recurso interessante para a Análise de Sentimento, e nesse contexto foi feita uma avaliação do LIWC desenvolvido para a língua portuguesa. Na versão em português, o *Brazilian Portuguese LIWC 2007 Dictionary 1* foi construído por três equipes que, com o auxílio de dicionários bilíngues, inseriram de forma automática categorias preexistentes do LIWC. De acordo com as informações na página de apresentação do LIWC em português, a parcela de trabalho manual de tradução não foi revisada. Em uma comparação com outros recursos do português (*OpLexicon e SentiLex*), o desempenho do LIWC ficou na média dos demais recursos. O *OpLexicon* (SOUZA, M.;

VIEIRA, 2012).

2.3.3 Teorias e Modelos de Análise de Sentimentos

Considerando um texto subjetivo que representa a avaliação de um usuário sobre um determinado item, este pode ser classificado utilizando-se técnicas binárias ou multiclasse. Na classificação binária, o objetivo é rotular essa avaliação como positiva ou negativa (boa ou ruim), com relação ao sentimento expressado pelo usuário.

Um exemplo de ferramenta criada para analisar o sentimento de uma opinião é a *Sentimental*. É possível verificar o sentimento em relação a uma entidade (empresa, produto, serviço etc) utilizando *tweets* sobre a entidade em análise. Essa ferramenta seleciona os *tweets* de acordo com a palavra-chave informada pelo usuário e classifica os *tweets* encontrados como positivos ou negativos.

Além disso, é apresentado um gráfico com a porcentagem total de *tweets* positivos e negativos. Outros sites também exemplificam o uso da análise de sentimentos, como o NLTK Text Classification, no qual o usuário digita um texto sobre algo e o sistema determina se é uma opinião (texto subjetivo) e, caso positivo, se a polaridade desta é positiva ou negativa. Outro exemplo é o site Skyttle, no qual a opinião informada também é classificada como boa ou ruim e, além disso, as frases com sentimento bom são marcadas em verde e as frases com sentimento ruim são marcadas em vermelho.

A classificação ou análise multiclasse analisa uma avaliação considerando escalas com mais de dois (valores de sentimento), como por exemplo, "bom, neutro ou ruim". Em diversos cenários, os produtos ou serviços são classificados em escalas de valores múltiplos. Pode-se citar como exemplo o site Booking, no qual os hotéis são classificados com notas que variam de 0 a 10. Assim sendo, uma forma típica de análise multiclasse é o Problema de Inferência de Rating (Rating-inference Problem- RIP), baseada em escalas de rating que tipicamente variam de 1 a 5 estrelas (PANG; LEE et al., 2008).

Em alguns casos, essa escala pode ser analisada como 4 classes, na qual a classe 3 (neutra) é desconsiderada, ou como 3 classes, nas quais as classes 1 e 2 são unidas, assim como as classes 4 e 5.

3 Metodologia de Pesquisa e Arquitetura Proposta

Neste capítulo, será explorada a arquitetura e métodos desta pesquisa, detalhando as técnicas empregadas para analisar e interpretar dados complexos, visando descobertas significativas no campo da análise sentimental espaço-temporal utilizando inteligência artificial e um survey.

3.1 Caracterização da Pesquisa

Serão utilizar métodos qualitativos e quantitativos para interpretar os resultados, observando tendências, padrões e discrepâncias.

3.2 Delimitações do Trabalho

O trabalho se limita à análises de dois universos de dados, onde um encontra-se no *X* (*ex-Twitter*) e outro entre participantes de um questionário (*Survey*).

O conjunto de dados do *Survey* permitirá uma análise quantitativa. Foi obtido através de uma pesquisa conduzida sobre desafios éticos da inteligência artificial. Este conjunto de dados incluiu respostas de participantes de diferentes idades, gêneros, níveis de educação, áreas de atuação profissional.

Essa aleatoriedade do perfil foi proposital para possibilitar uma melhor compreensão de suas percepções e opiniões sobre a inteligência artificial e seus desafios éticos.

3.3 Modelo de Arquitetura para Análise de Sentimentos

A Figura 3.1 representa a arquitetura utilizada para implementar a solução proposta e corresponde aos processos envolvidos para esse estudo, desde a extração e coleta de dados, até a análise final de sentimentos.

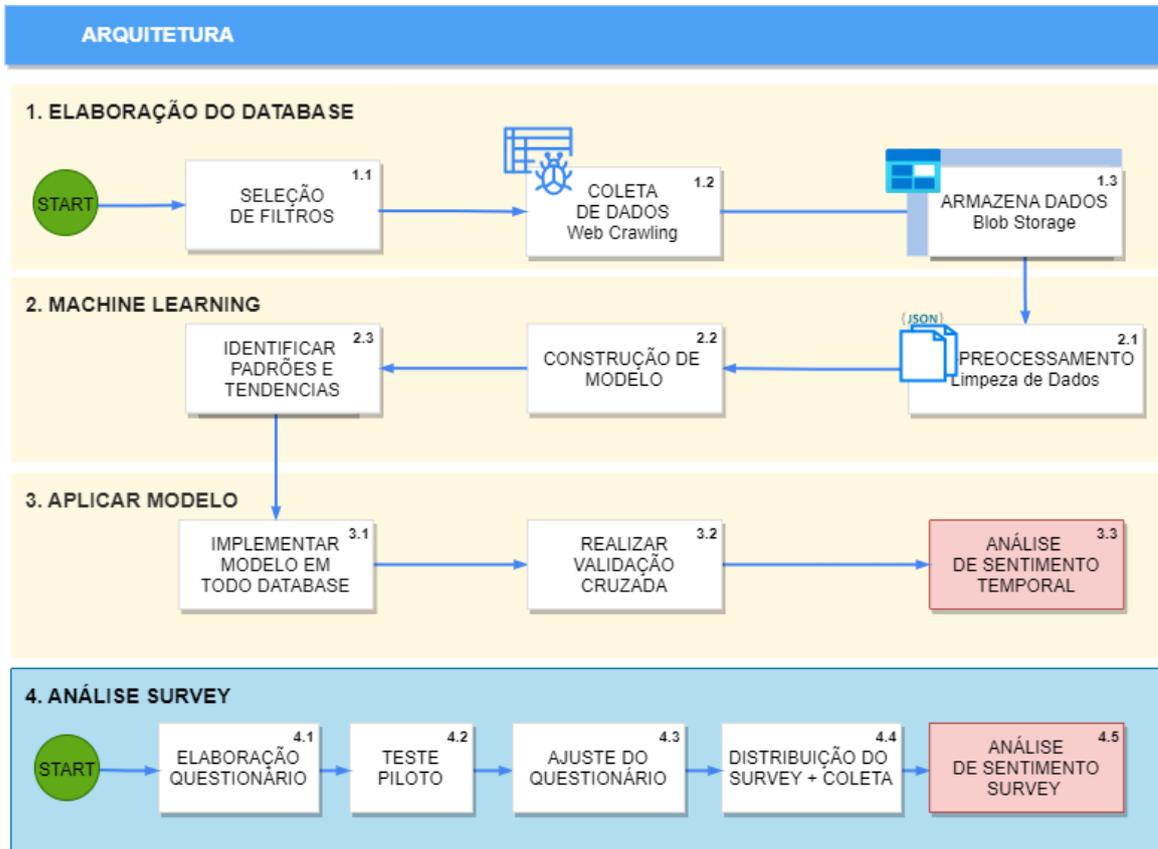


Figura 3.1 – Arquitetura utilizada Fonte: Elaborado pela autora (2023)

3.4 Elaboração do Database

A Figura 3.1 destaca a Elaboração do Database como parte fundamental da arquitetura metodológica. A Figura 3.2 detalha a primeira etapa deste processo, evidenciando a abordagem estratégica adotada na elaboração do database.

- **Entendimento do contexto** - Foi estabelecida a base para o projeto, focando no impacto e na percepção pública da inteligência artificial.
- **Escolha da ferramenta de extração** - Foi considerada a API da Plataforma X, mas devido ao custo elevado para acessar um volume substancial de dados, conduziram à decisão de utilizar técnicas de web crawling. Esta abordagem, embora mais trabalhosa, permitiu contornar as limitações da API, fornecendo a capacidade de extrair uma quantidade maior de dados sem incorrer em custos exorbitantes.

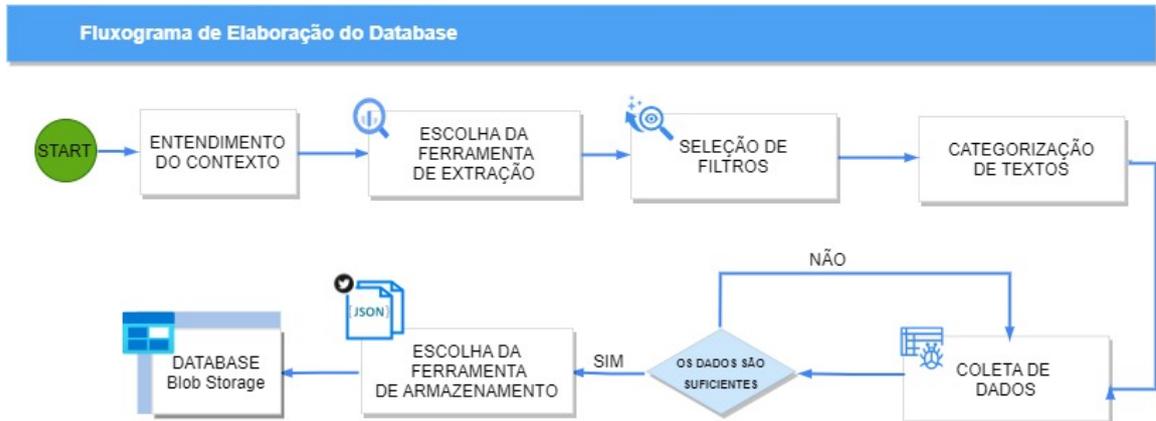


Figura 3.2 – Fluxo de Construção do *dataseet* Fonte: Elaborado pela autora (2023)

- **Seleção de filtros** - Foi realizada, optando-se por uma abordagem intuitiva inicial, coletando hashtags e termos comuns relacionados à IA, tais como #ia, #ai, #openai, #chatgpt e #bard.
- **Categorização de texto** utilizou o modelo de **Latent Dirichlet Allocation (LDA)** para o refinamento sistemático desses filtros, proporcionando um entendimento mais profundo dos tópicos discutidos.
- **Extração de dados** - Foi executada por meio de web crawling, aplicando os filtros selecionados para capturar dados pertinentes das redes sociais. Uma vez coletados, os dados foram armazenados no Blob Storage, aproveitando suas vantagens em termos de confiabilidade e custo-benefício, facilitando a gestão e o acesso aos dados, armazenados em Json.
- **Escolha da ferramenta de armazenamento** - A escolha recaiu sobre o *Blob Storage* devido à sua escalabilidade, durabilidade e eficiência no gerenciamento de grandes volumes de dados desestruturados, proporcionando benefícios como acessibilidade e integração com ferramentas de análise.
- **Análise exploratória** - inicialmente os dados armazenados permitiu identificar as conversas mais influentes e os sentimentos gerais em relação à inteligência artificial, estabelecendo o terreno para análises mais detalhadas e aprofundadas.

3.4.1 Escolha da Ferramenta de Extração

Nessa subseção, será explorada a *Escolha da Ferramenta de Extração*, analisando o uso da API da Plataforma X seguido pelo *Web Crawling*, detalhando ambos os procedimentos em subseções específicas.

3.4.1.1 API da Plataforma X

Para dar início ao uso da API da Plataforma X, foi necessário criar uma conta de desenvolvedor e seguir o passo a passo disponível no site oficial da Plataforma X (GETTING..., 2023). Após registrar a aplicação, as chaves de API e tokens de acesso necessários foram obtidas para utilizar a API v2 da Plataforma X.

No ambiente de desenvolvimento, foi escolhido o Python como linguagem e a biblioteca Tweepy (TWEETPY..., 2023) foi instalada, facilitando a interação com a API v2. O fragmento de código inicial para configurar a autenticação é o seguinte:

Código 3.1 – Fragmento de código Python

```
1 import tweepy
2
3 consumer_key = "API_KEY"
4 consumer_secret = "API_SECRET_KEY"
5 access_token = "ACCESS_TOKEN"
6 access_token_secret = "ACCESS_TOKEN_SECRET"
7
8 auth = tweepy.OAuthHandler(consumer_key, consumer_secret)
9 auth.set_access_token(access_token, access_token_secret)
10
11 api = tweepy.API(auth)
```

A data da tentativa de coleta com a API v2 foi de 20 de Agosto de 2023 e o script Python abaixo utiliza Tweepy para interagir com a API da Plataforma X, realizando buscas de *posts* com base em parâmetros específicos. Os dados coletados são armazenados em um dicionário, seguindo critérios estabelecidos pela documentação da API, incluindo o termo de pesquisa e o limite de *posts* a serem recuperados.

Código 3.2 – Fragmento de código Python

```
1 for tweet in tweepy.Cursor(api.search_tweets, q="inteligencia
   artificial").items(10):
2     print(tweet.text)
```

Para a análise de bookmarks na Plataforma X, funcionalidade que permite aos usuários salvar *posts* para leitura ou referência futura, foi utilizado o endpoint **GET /2/users/:id/bookmarks** da API da Plataforma X (GETTING..., 2023). Este endpoint permite acessar *posts* favoritados por um usuário autenticado, exigindo autenticação via OAuth 2.0. Respeitamos os limites de taxa, que são de 180 solicitações a cada 15 minutos por usuário. Este

recurso oferece a flexibilidade de selecionar campos específicos de *posts*, expansões para dados relacionados e opções de paginação, essenciais para a coleta eficiente de dados no nosso estudo.

Apesar da facilidade de uso, as limitações do plano gratuito, como o acesso a *posts* dos últimos 7 dias e restrições de taxa, levaram à decisão de não usar a API para coleta de dados em grande escala. Os planos premium e empresariais, que oferecem maior acesso, foram considerados, mas os custos associados excediam o orçamento do projeto, excedendo o valor de 100 dólares por mês.

3.4.1.2 Extração de Dados (Web Crawling)

Para realizar uma análise espaço-temporal detalhada, a estratégia de extração de dados evoluiu para o *Web Crawling*. Esta técnica provou ser notavelmente eficaz, superando as restrições impostas pela API da Plataforma X. Com o *Web Crawling*, foi capturado com sucesso posts públicos filtrados por palavras-chave e hashtags, garantindo uma coleta de dados abrangente e pertinente para a análise de sentimentos.

O código em JavaScript, encontrado em [A.1](#), desempenha um papel fundamental na metodologia de coleta de dados, especificamente na estruturação dos dados extraídos da Plataforma X. A função **isNewTweet** verifica se um tweet específico já foi incluído na coleta, evitando duplicatas.

```
1 let isNewTweet = (tweet) => {  
2   return !tweetsAcc.includes(tweet);  
3 }
```

Já a **createDto** serve para a criação de um objeto de transferência de dados (DTO). Esta função extrai detalhes de um tweet, como nome do usuário, texto do tweet, data, comentários, retweets, curtidas, visualizações e o HTML completo do tweet.

```
1 function createDto(tweet) {  
2  
3   let name = tweet.querySelector('[data-testid=User-Name]').textContent  
4   let tweetText = tweet.querySelector('[data-testid="tweetText"]').textContent  
5   let tweetDate = tweet.querySelector('time').getAttribute('datetime')  
6   let comments =  
7     tweet.querySelectorAll('[data-testid="app-text-transition-container"]')  
8   let retweets =  
9     tweet.querySelectorAll('[data-testid="app-text-transition-container"]')  
10  let likes =  
11    tweet.querySelectorAll('[data-testid="app-text-transition-container"]')  
12  let views =  
13    tweet.querySelectorAll('[data-testid="app-text-transition-container"]')
```

```

10   let html = tweet.outerHTML
11 }

```

Após criar o objeto, os dados são armazenados num repositório, que será explicado melhor na Seção 3.4.3, salva o *post* e inicia a rolagem automática da tela. Ele verifica novos posts na página, acumulando-os em um array e filtrando duplicatas. Cada post é processado e verificado no Blob Storage antes de ser salvo, assegurando a coleta de dados relevantes e não duplicados.

As etapas são as seguintes, ilustrada também na Figura 3.3:

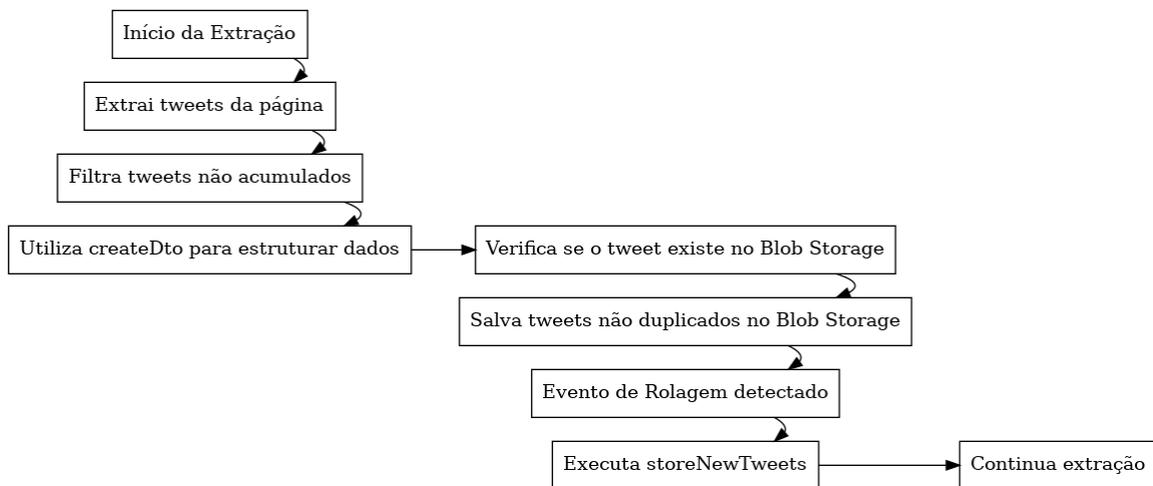


Figura 3.3 – Fluxograma das etapas de extração, Fonte: Elaborado pela autora (2023)

Automação de Rolagem: Utiliza um *setInterval* para rolar automaticamente a página, permitindo carregar *posts* progressivamente.

Acumulação de Tweets: Utiliza um array *tweetsAcc* para acumular *posts* coletados.

Processamento e Salvamento de Novos Tweets: Define a função *storeNewTweets*, que segue o algoritmo a seguir.

Implementação de Proxy CSP para Minimizar Restrições

Conforme a Figura 3.4, durante a aplicação do script, a mensagem de erro de CSP foi apresentada.

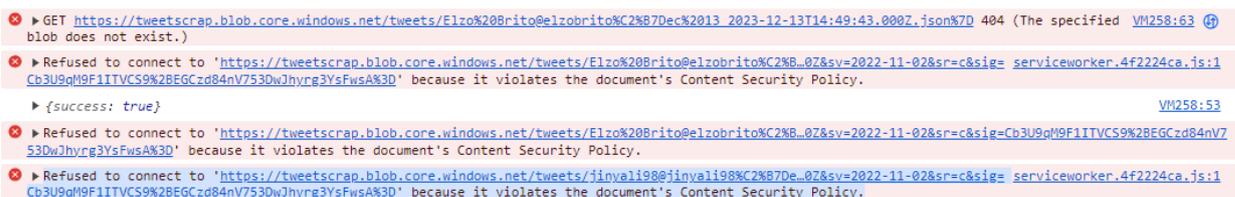


Figura 3.4 – Erro CSP, Fonte: Coletado pela autora (2023)

De acordo com o repositório de desenvolvedor do Mozilla, a mensagem de erro indica que uma página da Web ou aplicativo está se recusando a se conectar a um URL específico

porque viola a Política de Segurança de Conteúdo (CSP) (MDN WEB DOCS, 2023). A CSP é uma medida de segurança adicional que ajuda a detectar e mitigar certos tipos de ataques, como Cross-Site Scripting (XSS) e ataques de injeção de dados (MDN WEB DOCS, 2023).

Os ataques XSS são uma preocupação significativa na segurança da web. A implementação eficaz de uma CSP pode mitigar esses ataques, controlando as fontes de scripts executáveis e reduzindo vetores de ataque (YUSOF; PATHAN, 2016). Além disso, a análise segura de CSPs pode ser aprimorada através do uso de técnicas como o agrupamento não supervisionado, conforme explorado em estudos recentes (REN; YUE, 2023).

A desativação da Política de Segurança de Conteúdo (CSP) foi uma etapa essencial para realizar o web scraping efetivo dos dados da Plataforma X. Esta medida foi tomada para facilitar a coleta de informações específicas, permitindo uma análise mais profunda das tendências e padrões de uso da plataforma.

No entanto, é crucial ressaltar que tal ação não infringiu as políticas de segurança da Plataforma X (TWITTER, 2023b). Isso foi possível graças ao uso do "academic research product track" da Plataforma X, um serviço desenvolvido especialmente para pesquisadores (TWITTER, 2023a). Este recurso proporciona acesso autorizado e ético ao vasto arquivo de posts públicos históricos do Twitter, mesmo sem utilizar API.

Dessa forma, o uso do "academic research product track" garantiu a aderência às normas de segurança da Plataforma X. A coleta de dados, realizada dentro dos limites desse programa, assegurou que a integridade e segurança da plataforma fossem mantidas. Assim, a pesquisa foi conduzida de forma responsável e em conformidade com as diretrizes estabelecidas pela plataforma.

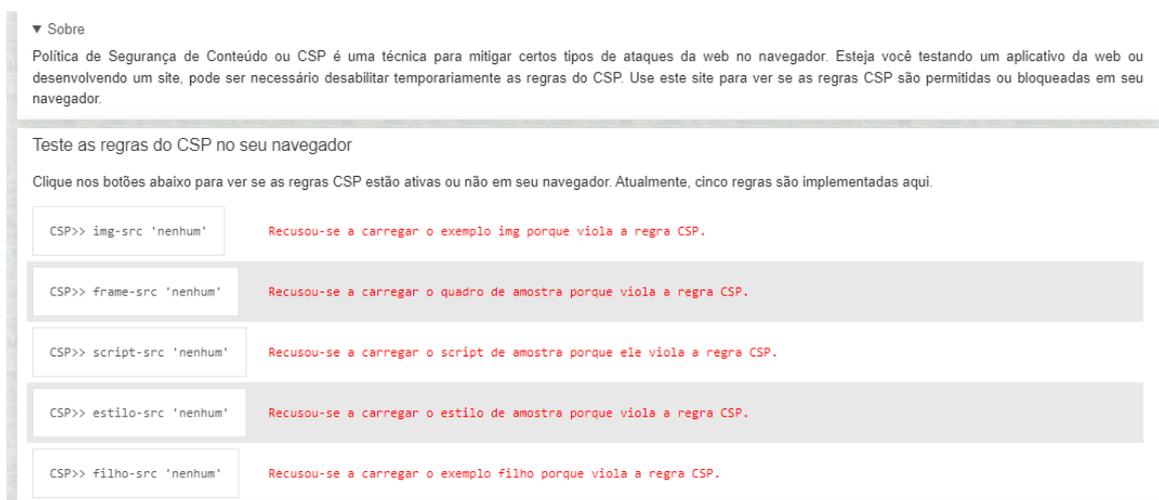


Figura 3.5 – Antes do CSP, Fonte: Coletado pela autora (2023)

Finalmente, foi implementado um proxy de Política de Segurança de Conteúdo (CSP) no Chrome. Vale ressaltar que antes da aplicação da configuração do proxy, foi utilizado um testador de CSP (TOOLS, 2023), que segue na Figura 3.5.

O procedimento realizado para configuração do Proxy CSP iniciou-se pela configuração do proxy, onde o browser Chrome foi executado conforme Figura 3.6.

```
C:\Program Files\Google\Chrome\Application>.chrome.exe --disable-web-security --user-data-dir="C:/ChromeDevSession"  
C:\Program Files\Google\Chrome\Application>
```

Figura 3.6 – Abrindo Chrome sem CSP, Fonte: Coletado pela autora (2023)

Configuração do Proxy: Foi utilizado um servidor proxy, Fiddler Classic (FIDDLER, 2023), para interceptar e alterar as respostas HTTPS, ajustando ou removendo os cabeçalhos CSP que impõem restrições.

Instalação e Configuração do Fiddler: Após a instalação do Fiddler, a captura foi ativada e decodificação do tráfego HTTPS, o que requer a instalação de um certificado de segurança e a subsequente reinicialização do Fiddler.

Ajustes no Navegador: No Chrome, foi configurada a conexão para o proxy, direcionando-a para a porta utilizada pelo Fiddler (127.0.0.1:8888).

Modificação das Respostas HTTP: O proxy é ajustado para modificar os cabeçalhos CSP, facilitando o acesso ao conteúdo sem violar as políticas de segurança.

Testes de Verificação: Com a configuração completa, foram feitos os testes no site da Plataforma X para assegurar que as modificações CSP permitem a extração de dados.

Após os procedimentos, o mesmo teste (TOOLS, 2023) de CSP feito apresentou o resultado na Figura 3.7, além de que a mensagem de erro apresentada na Figura 3.4 não foi mais apresentada, permitindo a extração de dados.

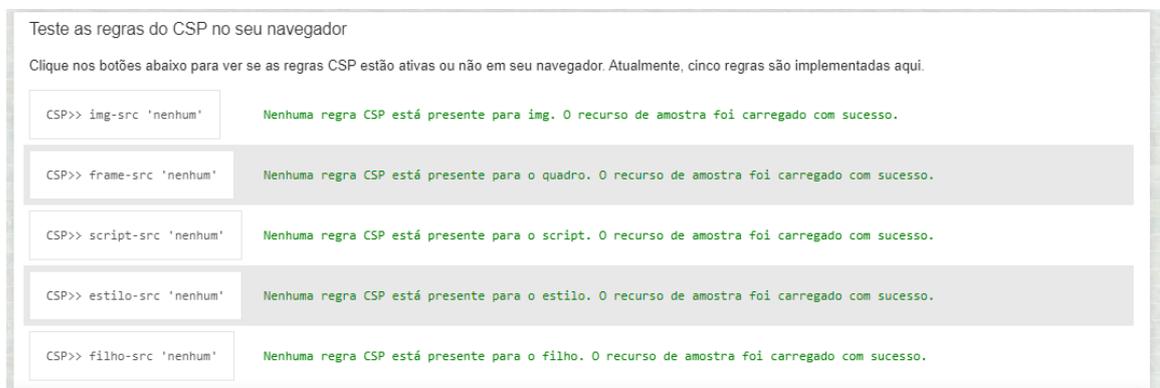


Figura 3.7 – Depois CSP, Fonte: Coletado pela autora (2023)

3.4.2 Seleção de Filtros e Categorização de Texto

Neste subcapítulo, serão detalhados os métodos empregados na seleção de filtros e hashtags para análise de sentimentos na Plataforma X, conforme ilustrado na Figura 3.1. Esta escolha, essencial na fase de elaboração do banco de dados, influencia significativamente a qualidade dos dados coletados.

Segundo estudos recentes, a escolha acertada de características no processamento dos dados é crucial, como evidenciado pelo aumento da eficácia e precisão, chegando a cerca de 94.13% em um determinado dataset (PARVEEN et al., 2023).

A Figura 3.8 ilustra o processo de escolha de tópicos e filtros ideais feitos antes da extração para construção do dataset.

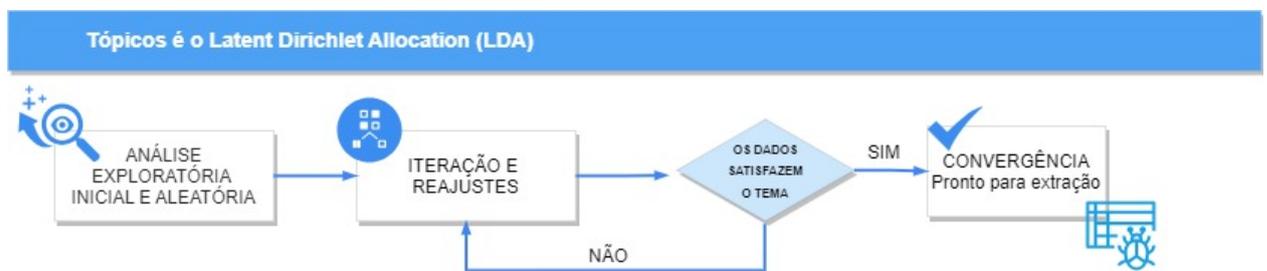


Figura 3.8 – Processo de escolha e construção de tópicos e filtro, Fonte: Elaborado pela autora (2023)

1. **Análise Exploratória Inicial:** Começar com uma seleção intuitiva de hashtags e termos relacionados à IA (como #ia, #ai, #openai, #chatgpt, #bard). É possível observar a configuração feita na figura 3.9.

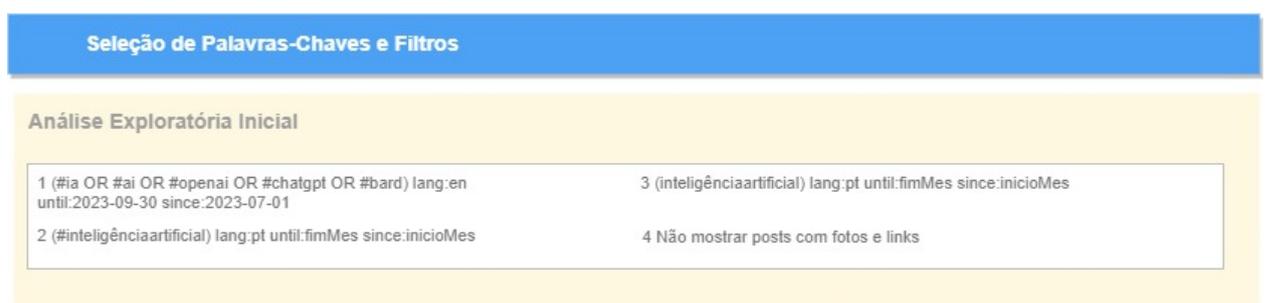


Figura 3.9 – Configuração da seleção de palavras chaves, Fonte: Elaborado pela autora (2023)

2. **Refinamento através de Métodos Sistemáticos:** Foram aplicados 3 tipos de modelos sistemáticos de refinamento de pesquisa, sendo eles:
 - a) **Análise de Frequência:** Verificar a frequência de termos relacionados à IA em posts existentes para identificar os mais comuns.
 - b) **Análise de Tópicos:** A Análise de Tópicos, empregando técnicas como o Latent Dirichlet Allocation (LDA), é fundamental para identificar termos e hashtags

recorrentes em conversas sobre Inteligência Artificial (IA). Essa técnica é uma ferramenta poderosa no Processamento de Linguagem Natural (PLN) e análise de dados textuais. Ela é especialmente valiosa para revelar estruturas ocultas, chamadas de tópicos, em grandes conjuntos de documentos. O LDA é um dos modelos mais populares para esse fim.

c) **Análise de Sentimento:** Filtrar termos que tendem a estar associados a sentimentos positivos ou negativos sobre IA.

3. **Feedback Iterativo:** Refinar os filtros com base nos resultados obtidos é essencial para aprimorar a relevância e a abrangência. O objetivo é alcançar a convergência antes de prosseguir com a extração e a construção do dataset. A Figura 3.10 apresenta o filtro final, onde se constatou que filtrar apenas a palavra "inteligência artificial", excluindo hashtags, links e imagens, é a abordagem ideal. Isso ocorre porque, anteriormente, surgiram problemas de leitura de imagens fora de contexto, dificultando a análise de sentimentos.

FILTRO NO X (ex-Twitter)

Palavras

Todas essas palavras
inteligência artificial
Exemplo: o que está acontecendo - contém "o que está" e "acontecendo"

Esta frase exata
Exemplo: happy hour - contém a frase exata "happy hour"

Qualquer uma dessas palavras
Exemplo: gatos cães - contém "gatos" ou "cachorros" (ou ambos)

Nenhuma dessas palavras
Exemplo: gatos cães - não contém "gatos" e não contém "cachorros"

Essas hashtags
Exemplo: #ThrowbackThursday - contém a hashtag #ThrowbackThursday

Linguagem

Filtros

Respostas

Incluir respostas e postagens originais

Mostrar apenas respostas

Ligações

Noivado

Respostas mínimas
Exemplo: 280 - postagens com pelo menos 280 respostas

Curtidas mínimas
10
Exemplo: 280 - postagens com pelo menos 280 curtidas

Repostagens mínimas

datas

De

Mês: Janeiro Dia: 1 Ano: 2023

Para

Mês: Janeiro Dia: 31 Ano: 2023

Figura 3.10 – Filtro final, Fonte: Elaborado pela autora (2023)

3.4.2.1 Categorização de Texto

A categorização de texto é um processo fundamental no manejo de grandes quantidades de conteúdos textuais, conforme discutido nos trabalhos de Cavnar e Trenkle (CAVNAR; TRENKLE et al., 1994) e Pawar e Gawande (PAWAR; GAWANDE, 2012).

Cavnar e Trenkle realçam a importância de um sistema de categorização que seja eficiente e capaz de tolerar erros textuais, como erros ortográficos e de reconhecimento de caracteres. Eles introduzem uma metodologia baseada em N-gramas para a categorização de texto, destacando sua robustez e rapidez, essencial para processar eficientemente enormes fluxos de textos eletrônico.

Por outro lado, Pawar e Gawande apresentam a categorização de texto como uma tarefa de classificação de padrões vital para a mineração de texto e gerenciamento eficaz de sistemas de informação textuais (PAWAR; GAWANDE, 2012).

A utilização da categorização de texto desempenhou um papel fundamental na filtragem dos dados e no desenvolvimento controlado do conjunto de dados. Inicialmente, uma análise dos dados filtrados revelou que a maioria das publicações era categorizada por natureza e sentimentos.

Para uma melhor compreensão do progresso e estrutura do conjunto de dados, recorreu-se à técnica de nuvem de palavras, conforme descrito no Código do Apêndice A.4. Essa abordagem foi essencial na mineração de dados, fornecendo insights sobre se o *dataset* estava sendo compilado conforme o planejado, tendo o resultado apresentado na Tabela 3.1. Mostrando um padrão que emergiu, facilitando a identificação dos sentimentos mais comuns, temas e suas naturezas predominantes.

Tabela 3.1 – Classificação de Naturezas e Categorias

Sugestão	Sentimento	Assunto/Contexto	Opinião	Análise
Inovadora	Felicidade	Tecnologia	Manipuladora	Detalhada
Prática	Satisfação	Ética	Facilitadora	Objetiva
Conservadora	Neutro	Impacto Social	Útil	Subjetiva
Arriscada	Preocupação	Futuro da IA	Cética	Superficial
Irrealista	Medo	Riscos e Desafios	Crítica	Teórica

3.4.3 Armazenamento de Dados

O Código encontrado no Apêndice A.2 faz Armazenamento de Dados dos *posts* em *Azure Blob Storage*, onde sua interface é mostrada na Figura 3.11.

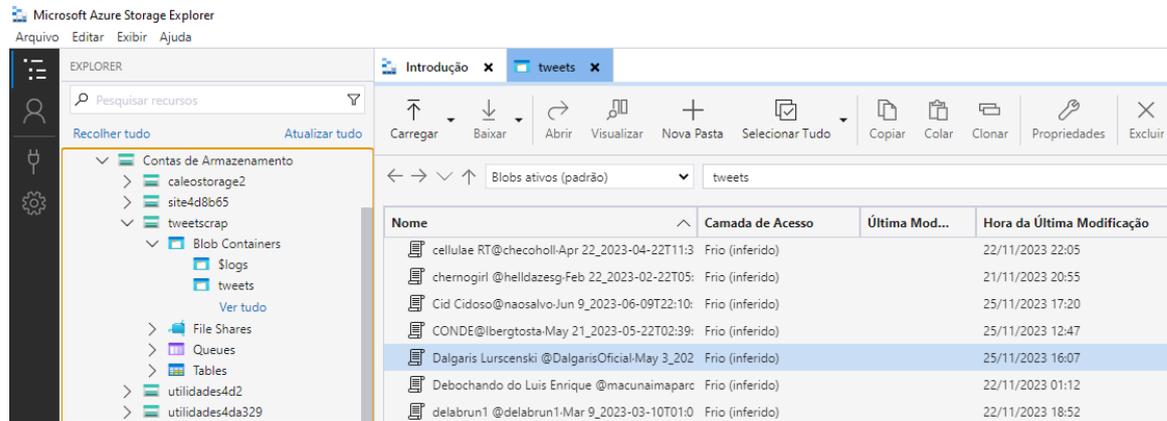


Figura 3.11 – Interface do Azure Blob Storage, Fonte: Coletado pela autora (2023)

O *Azure Blob Storage* da *Microsoft* é uma solução de armazenamento de objetos para a nuvem, otimizada para armazenar grandes quantidades de dados não estruturados (MICROSOFT, 2023). Esses dados incluem textos e informações binárias, como imagens, documentos, arquivos de vídeo e áudio.

Além disso, é útil para gravação de logs, backup e restauração de dados, recuperação de desastres e arquivamento (MICROSOFT AZURE BLOG, 2018). Os objetos no Blob Storage são acessíveis globalmente via *HTTP/HTTPS* e podem ser gerenciados por meio de várias interfaces de programação e protocolos, como a *API REST* do Azure Storage e *CLI*. (MICROSOFT AZURE BLOG, 2018)

A função **SalvarBlob(dto)** no código *JavaScript* apresentado é usada para salvar dados no *Blob Storage* da *Azure*, Figura 3.11.

```

1 function SalvarBlob(dto) {
2   const accountName = 'tweetScrap';
3   const sasToken = 'token';
4   const containerName = 'tweets';
5   const blobName = `${dto.name}_${dto.tweetDate}.json`;
6
7   const url = 'urlBlob';
8 }

```

Declaração de Variáveis: As variáveis *accountName*, *sasToken*, *containerName* e *blobName* são inicializadas. Estas armazenam informações cruciais para a autenticação e localização no *Blob Storage*.

Construção da URL: url é definida para indicar o endpoint de armazenamento do blob.

Chamada fetch: Esta função realiza uma requisição HTTP PUT para a URL do Blob Storage. Ela utiliza as informações do DTO (dto), convertendo-as em JSON para o corpo da requisição.

```
1 fetch(url, {
2   method: 'PUT',
3   headers: {
4     'x-ms-blob-type': 'BlockBlob',
5     'Content-Type': 'application/json',
6     'Access-Control-Allow-Origin': '*'
7   },
8   body: JSON.stringify(dto)
9 })
10 .then(response => response.json())
11 .then(data => console.log(data))
12 .catch(error => console.error('Error:', error));
```

Cabeçalhos HTTP: Cabeçalhos específicos são definidos, como o tipo de blob e o tipo de conteúdo, para garantir o correto processamento do blob.

Tratamento de Resposta: O código captura a resposta e possíveis erros. Em caso de sucesso, os dados retornados são registrados no console; em caso de erro, o erro é exibido.

3.4.3.1 Nuvem de Palavras

Foi utilizado o código [A.4](#) para gerar uma nuvem de palavras a partir dos tweets. Foram utilizadas as bibliotecas wordcloud e matplotlib, com stopwords personalizadas, para extrair e visualizar as palavras mais frequentes, refletindo as tendências emocionais dos dados.

3.5 Machine Learning

Dando continuidade à arquitetura apresentada na Figura [3.1](#), a segunda etapa é a de Machine Learning, onde possui 3 segmentos, sendo elas: pré-processamento de dados, construção de modelo e identificação de padrões e tendências.

3.5.1 Pré-processamento de Dados

Em aprendizagem de máquina, preparar dados é crucial, especialmente no processamento de linguagem natural, onde ferramentas como NLTK (**NLTK**) e expressões regulares

em Python otimizam o tratamento de texto, melhorando significativamente os resultados dos modelos.

3.5.1.1 Remoção de caracteres indesejados

A remoção de caracteres indesejáveis, como pontuação e espaços, é importante para limpar dados de texto antes do treinamento de modelos. Funções de manipulação de strings, como **trim()**, **substring()**, **split()**, e especialmente **re.sub** em Python, são eficazes para eliminar tais caracteres, aumentando a clareza do texto e melhorando a precisão das previsões.

A biblioteca **'re'** foi utilizada para remoção de caracteres indesejados e, segundo a documentação Python, "o nome do módulo vem das iniciais do termo em inglês *regular expressions*, também frequentemente chamadas de *regex*"(TWEOPY..., 2023).

A função **limpar_texto(texto)**: foi definida para limpar o texto que recebe um texto como entrada.

A função **re.sub** recebe os seguintes parâmetros: **re.sub(pattern, repl, string, count=0, flags=0)**:. Tendo como *pattern* o padrão da expressão regular e indicar que tudo que não for uma palavra ou espaço em branco será substituído. Já o *texto.lower()* é um método para converter todas as letras do texto em minúsculas, facilitando a manipulação dos dados.

```
1 import re
2
3 def limpar_texto(texto):
4     # Remove caracteres especiais e pontuação usando expressões regulares
5     texto_limpo = re.sub(r'^\w\s/<>()|\\+\\-\\$%&#@\\'\\'+', '', texto)
6
7     # Converte o texto para minúsculas
8     texto_limpo = texto_limpo.lower()
9
10    return texto_limpo
```

3.5.1.2 Stopwords, Tokenização e Stemming

Inicialmente, foi feito o tratamento das *stopwords* - palavras comuns com pouca relevância analítica - removendo-as para diminuir a dimensionalidade dos dados. Foi utilizada a lista pré-definida da biblioteca NLTK.

Importação das bibliotecas:

spaCy é uma biblioteca avançada de Processamento de Linguagem Natural (PLN) que é utilizada para tarefas como tokenização e lematização.

scikit-learn: Biblioteca de aprendizado de máquina utilizada para a vetorização de textos através do CountVectorizer.

NLTK: Biblioteca de PLN para o processamento de linguagem natural, usada aqui para acessar uma lista de stopwords em português e para stemming.

```
1 import spacy
2 from sklearn.feature_extraction.text import CountVectorizer
3 from nltk.corpus import stopwords
4 from nltk.stem import RSLPStemmer
```

A *tokenização*, que segmenta textos em unidades menores (palavras ou frases), é outra prática importante. Para isso, foi empregada a funcionalidade de tokenização da biblioteca spaCy, preparando os textos para análise computacional.

A função **preparar_texto** utiliza o modelo de língua portuguesa do spaCy para processar o texto, remove stopwords usando a lista do NLTK, aplica stemming com o RSLPStemmer do NLTK. Retorna o texto processado.

```
1 # Função para limpar, tokenizar e aplicar stemming
2 def preparar_texto(texto):
3     Carrega o modelo spaCy em portugues
4     nlp = spacy.load('pt_core_news_sm')
5
6     Lista de stopwords em portugues
7     stop_words_pt = set(stopwords.words('portuguese'))
8
9     Inicializa o stemmer
10    stemmer = RSLPStemmer()
11
12    Processa o texto
13    doc = nlp(texto)
14
15    Filtra tokens, remove stopwords, pontuações e aplica stemming
16    tokens = [stemmer.stem(token.text) for token in doc if token.text not in
17              stop_words_pt and not token.is_punct]
18    return ' '.join(tokens)
```

A biblioteca da NLTK foi pensada para essa finalidade, entretanto segundo a pesquisa de (Barras2022), o spaCy é geralmente mais rápido do que o NLTK e tem melhor desempenho em tarefas de processamento de linguagem natural (PLN) de grande escala, além disso, fornece uma análise mais precisa e possui modelos pré-treinados que são otimizados para tarefas específicas, além de que a NLTK exige uma abordagem mais experimental e personalizada, não sendo necessária para a finalidade dessa pesquisa.

Posteriormente, os tokens foram transformados em vetores e identificou a presença ou ausência de palavras nos textos. A função **vetorizar_textos** converte os textos processados em vetores numéricos utilizando *CountVectorizer* do scikit-learn, que transforma o *dataset* em uma matriz de contagens de tokens.

```

1 def vetorizar_textos(textos):
2     vectorizer = CountVectorizer()
3     X = vectorizer.fit_transform(textos)
4     return X, vectorizer.get_feature_names_out()
5
6 # Função principal para processar e vetorizar textos
7 def analisar_sentimentos_ai(lista_textos):
8     textos_preparados = [preparar_texto(texto) for texto in lista_textos]
9     vetores, vocabulario = vetorizar_textos(textos_preparados)
10    return vetores.toarray(), vocabulario

```

A *lemmatização* foi incorporada, convertendo palavras para suas formas básicas, para simplificar os textos. Esta técnica é implementada através das bibliotecas *NLTK* e *Spacy*, sendo esta última particularmente eficiente para o português.

Abaixo está um exemplo aplicado em um *post*, antes de ser aplicado no *dataset* inteiro

```

1 textos = ["A inteligencia artificial vai revolucionar o mundo.", "Os robos
           serão nossos amigos ou inimigos?"]
2 vetores, vocabulario = analisar_sentimentos_ai(textos)
3
4 print("Vocabulário:", vocabulario)
5 print("Vetores de texto:\n", vetores)

```

Ao combinar remoção de stop words, tokenização, vetorização e lemmatização, a precisão e eficácia dos modelos de ML foram aprimoradas, facilitando tarefas a análise de sentimentos e classificação de texto.

3.5.2 Treinamento do Modelo

A classificação dos dados foi conduzida de forma manual, levando em conta as experiências pessoais da autora do projeto e suas interações nas redes sociais. É importante reconhecer que essa abordagem pode conter algumas situações enviesadas devido à natureza subjetiva das experiências individuais.

A Tabela 4.3 será apresentada no Capítulo 4.1.3 que corresponde aos resultados do treinamento. O Código A.6 foi responsável pelo treinamento e encontra-se disponível no Apêndice A.

O processo de treino começou com a leitura de desse conjunto de dados, contendo os *posts* e seus respectivos sentimentos *Sentiment*, *TweetText*.

Os sentimentos foram convertidos em valores numéricos através da função *process_sentiment*, facilitando o tratamento computacional.

Posteriormente, o conjunto de dados foi dividido em partes para treinamento (75%) e teste (25%), utilizando a função *train_test_split*. Para a vetorização dos textos, foi empregado o *TfidfVectorizer*, transformando os textos em vetores numéricos que representam a importância relativa das palavras.

Adicionalmente, a matriz de confusão foi gerada para visualizar o desempenho do modelo nas diferentes classes de sentimentos, usando a biblioteca *seaborn* para uma representação gráfica eficaz.

O modelo SVM foi treinado com os vetores TF-IDF, e sua performance foi avaliada no conjunto de teste, utilizando métricas como precisão, recall e pontuação F1, fornecidas pelo *classification_report*.

O modelo selecionado para a análise de sentimentos foi o SVM (Support Vector Machine) com vetorização *TF-IDF*, implementado pela biblioteca *Scikit-learn*. Esta decisão foi baseada em literatura acadêmica relevante (PRACIANO, 2018) e (SILVA, G. d. M.; GONÇALVES, 2023), que demonstrou precisão e acurácia comparáveis entre o SVM e outros modelos. Portanto, a exploração de alternativas foi considerada fora do escopo deste trabalho.

Modelos não testados incluem:

- CountVectorizer com SGDClassifier
- TfidfVectorizer com MultinomialNB
- CountVectorizer com MultinomialNB

Esses modelos não foram empregados pois as investigações citadas indicaram que a precisão e a acurácia obtidas com o SVM eram equivalentes, tornando desnecessária a aplicação de métodos alternativos.

3.6 Desenvolvimento do Questionário

Para obter dados mais precisos e objetivos, que dispensassem a análise de sentimentos e permitissem uma comparação com os dados da Plataforma X, desenvolveu-se um questionário online estruturado. Este instrumento de pesquisa incluiu tanto perguntas fechadas quanto abertas, sendo as respostas coletadas no período de 15º de Novembro a 15 de Dezembro de 2023.

O **público-alvo** do *survey* englobou uma ampla diversidade de participantes, abrangendo diferentes faixas etárias, gêneros, níveis de escolaridade e profissões. A participação foi inteiramente voluntária, com os participantes consentindo o uso de suas respostas para fins científicos, conforme evidenciado pelo termo de consentimento apresentado na Figura 3.12.

Termo de Consentimento de Participação na Pesquisa

1. **Objetivo da Pesquisa:** O objetivo geral desta pesquisa é propor um framework para entender opiniões sobre o impacto da Inteligência Artificial (IA) em suas vidas diárias e na sociedade. Especificamente, o estudo busca analisar sentimentos em diferentes contextos espaciais e temporais, considerando as implicações éticas, sociais e técnicas dessa aplicação.
2. **Procedimentos:** Como parte da pesquisa, você será convidado a responder um **questionário anônimo** que inclui perguntas sobre suas percepções e opiniões relacionadas à IA. A participação envolve responder a perguntas baseadas em escalas de Likert, bem como algumas perguntas abertas.
3. **Voluntariedade:** Sua participação nesta pesquisa é completamente **voluntária**. Você tem o direito de retirar-se da pesquisa a qualquer momento, sem necessidade de justificar a sua decisão e sem que isso traga qualquer prejuízo a você.
4. **Confidencialidade:** As informações coletadas durante a pesquisa serão mantidas em estrita confidencialidade. Nenhum dado que permita sua identificação pessoal será divulgado, e todas as respostas serão processadas de forma agregada para garantir o anonimato.
5. **Contato:** Se tiver perguntas sobre a pesquisa, você pode entrar em contato com: **ia.impactos.unb@gmail.com**

O tempo médio de resposta é de 4 minutos. Possui 5 sessões, tendo entre 2 a 5 perguntas cada.

Ao selecionar "**Concordo**" abaixo, você indica que leu e compreendeu as informações acima e concorda voluntariamente em participar desta pesquisa.

Figura 3.12 – Termo de Consentimento aplicado no questionário *Survey*, Fonte: Elaborado pela autora (2023)

O questionário abrangeu uma série de tópicos, incluindo demografia, idade, gênero, nível de escolaridade, profissão e localização. As questões objetivas focaram em opiniões e percepções sobre a IA, abordando temas como o impacto da IA na sociedade, sua influência nas tomadas de decisão, a possibilidade de substituição humana por IA em decisões futuras, os efeitos da IA na educação, além de permitir observações abertas sobre o tema.

As seções do questionário foram organizadas conforme indicado abaixo, com as respectivas perguntas detalhadas na Tabela 3.2:

1. Percepções sobre Impactos da IA no Emprego.
2. Confiabilidade e Precisão da IA.
3. Ética na IA.

4. Percepção Geral sobre IA em Redes Sociais.
5. Futuro da IA.

Antes do lançamento oficial do questionário, conduziu-se um **teste piloto com 10 indivíduos**. Esta etapa preliminar envolveu a análise dos dados coletados para assegurar que as respostas obtidas atendessem às expectativas do estudo. Foi durante este teste que surgiu a ideia de incluir uma seção de observações abertas, possibilitando uma análise combinada com os dados da Plataforma X.

Tabela 3.2 – Questionário aplicado

Seção	Pergunta	Tipo de Resposta
Impactos no emprego	Você acredita que a inteligência artificial criará mais empregos ao invés de eliminar?	Escala Linear 0-5
	Você se sente preparada(o) para utilização da IA como facilitador de tarefas?	Escala Linear 0-5
Confiabilidade	Na sua opinião, até que ponto você confia na precisão dos sistemas de IA em identificar e interpretar corretamente os sentimentos expressos nas postagens em Redes Sociais?	Escala Linear 0-5
	Você acha que as decisões tomadas por IA são mais justas do que as tomadas por humanos?	Escala Linear 0-5
Ética na IA	Você acredita que os desenvolvedores de IA estão considerando questões éticas suficientemente?	Escala Linear 0-5
	Você está ciente de que suas postagens em Redes Sociais podem ser analisadas por sistemas de IA para análise de sentimentos?	Múltipla Escolha
Percepção sobre IA	Você acredita que a IA interfere em suas decisões políticas?	Escala Linear 0-5
	Qual é a sua opinião sobre o uso de Inteligência Artificial para analisar sentimentos em plataformas de mídia social? Você acha que é mais benéfico ou prejudicial?	Escala Linear 0-5

4 Resultados e Discussões

Nesse capítulo serão apresentados os principais resultados da análise de sentimentos em relação à Inteligência Artificial, realizando um comparativo entre resultados obtidos a partir de um modelo de treinamento de *Machine Learning* e os resultados obtidos a partir de um *Survey*.

4.1 Análise de Dados da Plataforma X

Foram utilizados dados extraídos da Plataforma X para a análise de sentimento. Conforme descrito na Seção 3.4.1.2 e no código apresentado no Apêndice A.1, foram obtidos 82700 posts únicos, sem repetições, empregando a função **isNewTweet**.

4.1.1 Coleta de Dados e elaboração do database

Os dados foram coletados durante um período de 11 meses em 2023, começando em 01 de Janeiro e terminando em 30 de Novembro. Este processo de coleta durou 7 semanas, um período relativamente curto para extrair um volume expressivo de dados. Essa eficiência se destaca mesmo quando comparada à API da Plataforma X, que permite 180 solicitações a cada 15 minutos por usuário, conforme explicado na seção 3.4.1.1.

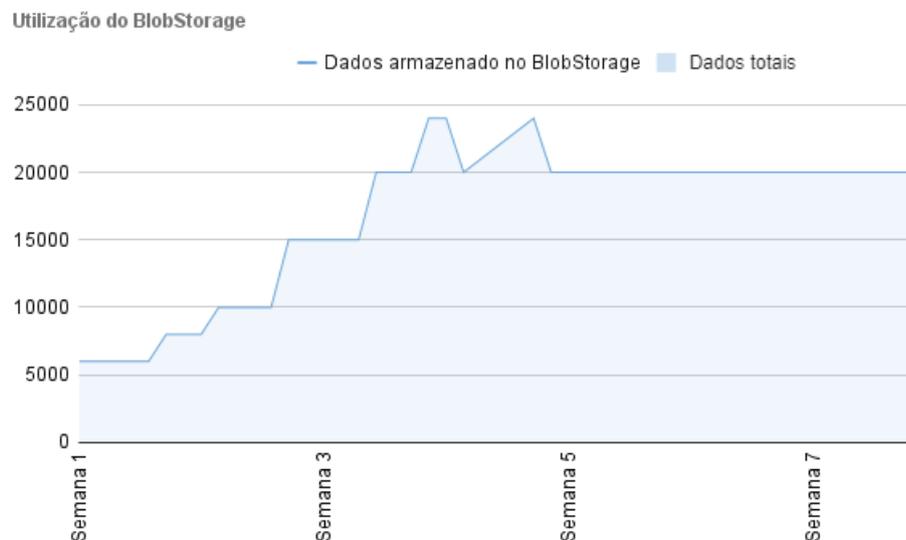


Figura 4.1 – Gráfico representando a quantidade de dados armazenados no BlobStorage em relação ao tempo de extração. Fonte: Servidor BlobStorage. Tradução para o Português realizada pela autora em Dezembro de 2023.

O gráfico na Figura 4.1 ilustra o acúmulo de *posts* no BlobStorage (MICROSOFT,

2023) ao longo das 7 semanas de coleta. Cada *post* foi armazenado como um arquivo Json. Observa-se um aumento progressivo na quantidade de dados coletados, uma consequência do incremento nas tentativas de extração massiva.

O aumento progressivo na coleta de dados ocorreu devido aos erros iniciais associados ao CSP (MDN WEB DOCS, 2023) (conforme discutido no Capítulo 3.4.1.2) e à preocupação em cumprir as Políticas de Segurança da Plataforma X (TWITTER, 2023b). Eventualmente, foi alcançado um limite máximo de 24000 *posts* diários salvos no BlobStorage, sem enfrentar problemas para coletar essa quantidade de dados em um único dia.

Uma das informações extraídas dos *posts* foi a data de publicação. Foi possível identificar os meses que mais tiveram extração de *posts*, mostrada na Figura 4.2

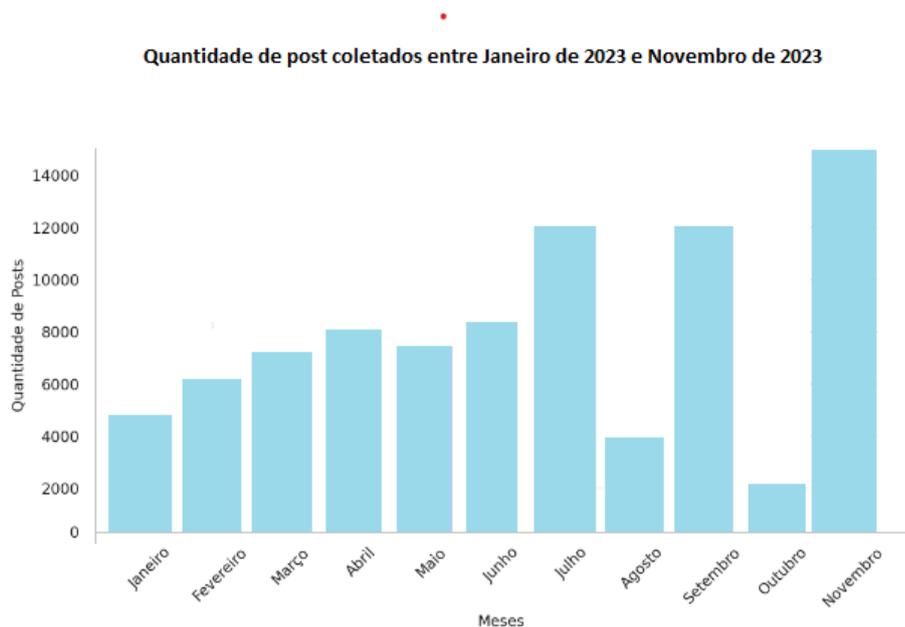


Figura 4.2 – Gráfico de *posts* coletados por mês. Fonte: Servidor BlobStorage. Tradução para o Português realizada pela autora em Dezembro de 2023.

Para entender o motivo de alguns meses terem maiores quantidades de *posts*, foi feita uma pesquisa em fontes de blogs de informações, plataformas e jornais para tentar identificar algum marco histórico que justificasse o aumento de engajamento. Os marcos históricos estão representados no gráfico da Figura 4.3.

Fazendo um cruzamento de dados, feito com a biblioteca *matplotlib*, foi feita a intersecção de informações obtidas nos gráficos 4.2 e 4.3. Com isso, concluiu-se que alguns marcos históricos, como os lançamentos das ferramentas de IA ChatGPT, Bard e Grok, contribuíram para o engajamento sobre IA.

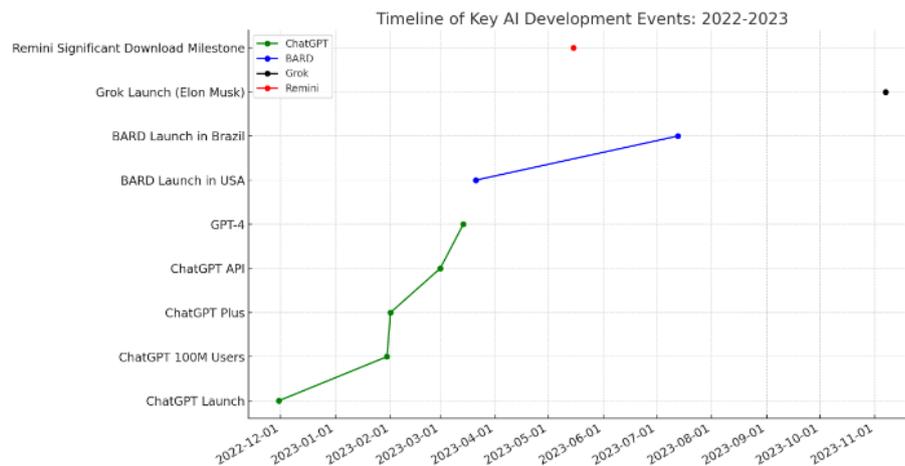


Figura 4.3 – Gráfico de marcos da IA interseccionado com *posts* coletados por mês. Fonte: Realizada pela autora em Dezembro de 2023.

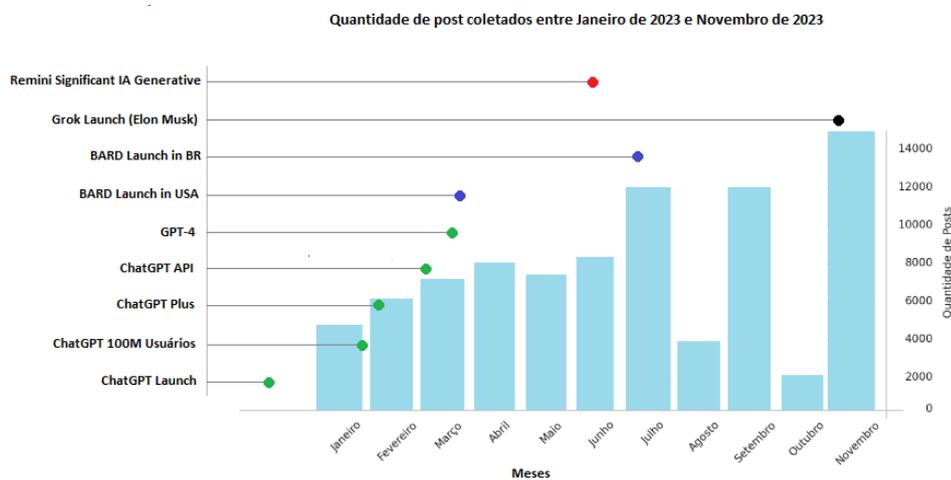


Figura 4.4 – Gráfico de marcos da IA interseccionado com *posts* coletados por mês. Fonte: Realizada pela autora em Dezembro de 2023.

4.1.2 Pré-processamento de Dados

Os resultados do pré-processamento de dados são detalhados nas Tabelas 4.1 e 4.2, conforme descrito no Capítulo 3.5.1. Estes incluem a remoção de caracteres indesejados, stopwords, tokenização e stemming.

Devido à significativa quantidade de dados, essa tarefa exigiu um consumo intenso de processamento, totalizando aproximadamente 15 horas para ser concluída em toda a base de dados. As tabelas fornecem alguns exemplos ilustrativos do dataset após o processamento de dados, com alterações para proteger informações pessoais, mantendo a integridade e precisão das análises.

O processo, transformou significativamente o conjunto original, melhorando a eficiência e precisão da análise subsequente.

A lematização normalizou textos para formas base, enquanto a remoção de stopwords

eliminou palavras redundantes, focando em conteúdo mais relevante.

Tabela 4.1 – Exemplo de *posts* após retirada de Stopwords e Caracteres Indesejados

Dados Originais	Dados Sem Stopwords e Caracteres Indesejados
chatGPT: inteligência artificial nota 1000 redação ENEM	chatGPT inteligência artificial nota 1000 redação ENEM
Caia fora acenda incenso ou faça mentalização limpeza	Caia fora acenda incenso faça mentalização limpeza
Para consolar confesso debate perfil estranho respondia coisas estranhas Depois percebi inteligência artificial	consolar confesso debate perfil estranho respondia coisas estranhas percebi inteligência artificial
redes sociais robôs usam inteligência artificial censura prévia será feroz contra esquerda	redes sociais robôs usam inteligência artificial censura prévia será feroz contra esquerda
PS liberdade certo ponto expor opinião twitter Isso pode acabar	PS liberdade certo ponto expor opinião twitter pode acabar
jornalulas serão substituídos Inteligência Artificial plano comunoglobalista Rua Amargura será destino Ninguém será poupado	jornalulas substituídos Inteligência Artificial plano comunoglobalista Rua Amargura destino Ninguém poupado

Tabela 4.2 – Exemplo de *posts* após a aplicação de técnicas de Tokenização e Lemmatization.

Lematização Aplicada	Tokenização
chatGPT inteligência artificial notar 1000 redação ENEM	[CHATGPT, INTELIGÊNCIA, ARTIFICIAL, NOTAR, 1000, REDAÇÃO, ENEM]
Cair fora acender incenso fazer mentalização limpar	[CAIR, FORA, ACENDER, INCENSO, FAZER, MENTALIZAÇÃO, LIMPAR]
consolar confessar debater perfil estranho responder coisa estranho perceber inteligência artificial	[CONSOLAR, CONFESSAR, DEBATER, PERFIL, ESTRANHO, RESPONDER, COISA, ESTRANHO, PERCEBER, INTELIGÊNCIA, ARTIFICIAL]
rede social robô usar inteligência artificial censura prévio ser feroz contra esquerdo	[REDE, SOCIAL, ROBÔ, USAR, INTELIGÊNCIA, ARTIFICIAL, CENSURA, PRÉVIO, SER, FERROZ, CONTRA, ESQUERDO]
PS liberdade certo ponto expor opinião twitter poder acabar	[PS, LIBERDADE, CERTO, PONTO, EXPOR, OPINIÃO, TWITTER, PODER, ACABAR]
jornalula substituir Inteligência Artificial plano comunoglobalista Rua Amargura destino Ninguém poupar	[JORNALULA, SUBSTITUIR, INTELIGÊNCIA, ARTIFICIAL, PLANO, COMUNOGLOBALISTA, RUA, AMARGURA, DESTINO, NINGUÉM, POUPAR]
Ver Ana Maria medo inteligência artificial	[VER, ANA, MARIA, MEDO, INTELIGÊNCIA, ARTIFICIAL]

4.1.3 Treinamento do dataset

A classificação dos dados foi conduzida de forma manual, levando em conta as experiências pessoais da autora do projeto e suas interações nas redes sociais. É importante reconhecer que essa abordagem pode conter algumas situações enviesadas devido à natureza subjetiva das experiências individuais.

Tabela 4.3 – Exemplo de dados classificados para treinamento

Dados Originais	Sentimento
chatGPT: inteligência artificial nota 1000 redação ENEM	Positivo
Caia fora acenda incenso ou faça mentalização limpeza	Neutro
Para consolar confesso debate perfil estranho respondia coisas estranhas Depois percebi inteligência artificial	Negativo
redes sociais robôs usam inteligência artificial censura prévia será feroz contra esquerda	Negativo
PS liberdade certo ponto expor opinião twitter Isso pode acabar	Neutro
jornalulas serão substituídos Inteligência Artificial plano comunoglobalista Rua Amargura será destino Ninguém será poupado	Negativo
Hoje último dia Product Manager hygraph	Positivo

O enviesamento é uma dificuldade inerente ao processo de classificação, uma vez que cada pessoa tem sua própria perspectiva.

A tarefa de classificar dados foi desafiadora, especialmente quando se lida com uma grande quantidade de informações. Neste projeto, foram treinados 20.000 *posts*, o que corresponde a aproximadamente 25% do total de dados disponíveis. A Tabela 4.3 representa exemplos dos dados treinados manualmente.

Os dados classificados foram submetidos ao processo descrito no Capítulo 4.1.3. Na Figura 4.5 foi possível observar a matriz de confusão.

		Valores Previstos		
		Positivo	Neutro	Negativo
Valores Verdadeiros	Positivo	89%	0,70%	0,20%
	Neutro	32%%	98,80%	2,80%
	Negativo	8,70%	3,50%	79%

Figura 4.5 – Matriz de Confusão Fonte: Elaborado pela autora (2023)

A matriz de confusão é uma ferramenta utilizada para avaliar o desempenho de modelos de classificação. A interpretação foi a seguinte:

Dos *posts* classificados como positivos, 89% foram previstos corretamente como positivos pelo modelo. No entanto, 0,70% dos *posts* positivos foram incorretamente classificados como neutros, e 0,20% como negativos (falsos negativos).

A maioria dos *posts* neutros foi identificada corretamente, com 98,80% de precisão. Por outro lado, 32% dos *posts* que foram verdadeiramente positivos foram falsos neutros, e 2,80% dos que eram verdadeiramente negativos foram falsos neutros.

Para os *posts* negativos, o modelo acertou 79% das vezes. Ainda assim, houve casos em que *posts* negativos foram confundidos como positivos (8,70%) ou neutros (3,50%) pelo modelo.

4.2 Análise de dados do Survey

O Formulário obteve 51 respostas coletadas no período de um mês entre os dias 15 de Novembro de 2023 e 15 de Dezembro de 2023 e contém um conjunto de dados da pesquisa sobre a percepção pública da inteligência artificial. Os principais temas analisados foram:

1. Percepções sobre impactos da IA no emprego.
2. Confiabilidade e precisão da IA.
3. Ética e futuro da IA.
4. Percepção geral sobre IA em redes sociais.

4.2.1 Percepções sobre Impactos da IA no Emprego

As respostas para as três perguntas sobre percepções de impactos da inteligência artificial no emprego encontram-se a seguir juntamente com seu gráfico na Figura 4.6.

1. **Você acredita que a inteligência artificial criará mais empregos ao invés de eliminar?** As respostas variam, com 25% dos participantes expressando forte crença de que a IA criará mais empregos, enquanto outros 13% são mais céticos e acreditam mais que empregos serão extintos.
2. **Você se sente preparado(a) para utilizar a IA como facilitador de tarefas?** Aqui, 43% se sentem muito preparados, enquanto 12% não se sentem preparados.
3. **Quão preparado(a) você se sente para trabalhar com tecnologias de IA no futuro?** Aqui, apenas 15% sentem-se altamente preparados para trabalhar com tec-

nologias de IA no futuro contrastando em 30% que sentem-se neutro e 15% pouco preparado.

Abaixo, na Figura 4.6, encontram-se as os números obtidas nas perguntas relatadas.

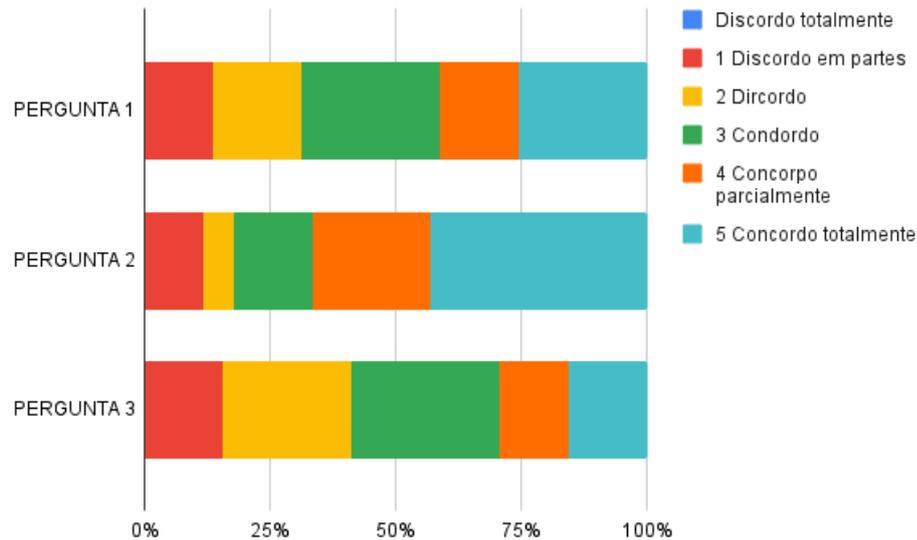


Figura 4.6 – Gráfico de respostas sobre impactos da IA no emprego Fonte: Elaborado pela autora (2023)

No gráfico da Figura 4.7, cada linha representa como a média das percepções de preparação varia de acordo com a crença na criação de empregos pela IA (em uma escala de 1 a 5). À medida que a crença na criação de empregos pela IA aumenta, a percepção de preparação também tende a aumentar.

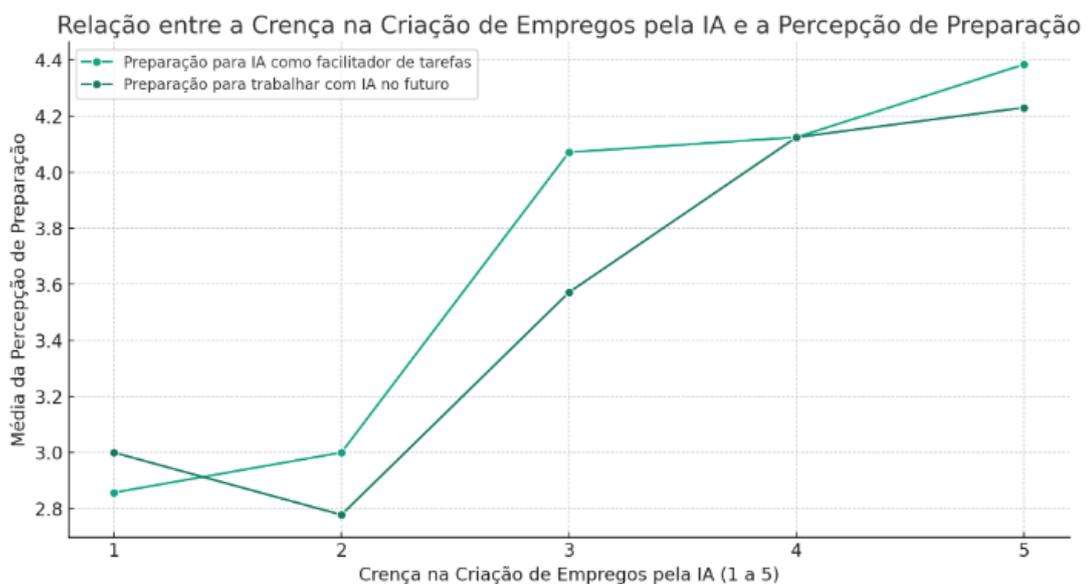


Figura 4.7 – Relação entre crença na criação de empregos pela IA e a percepção de preparo Fonte: Elaborado pela autora (2023)

O resultado sugere também uma crença relacionada às percepções, onde a visão mais otimista sobre o impacto da IA na criação de empregos está associada a um maior senso de preparação para o envolvimento com tecnologias de IA.

Analisando os resultados, não foi possível entender a área de atuação correlacionada com a crença da criação ao invés da exterminação de empregos, e isso porque 61% das respostas foram de pessoas da tecnologia, deixando o resultado enviesado.

4.2.2 Confiabilidade na precisão da IA

Em relação à confiabilidade na precisão da IA em tomar decisões e ser justa, as perguntas feitas foram:

1. **Na sua opinião, até que ponto você confia na precisão dos sistemas de IA em identificar e interpretar corretamente os sentimentos expressos nas postagens em Redes Sociais?** O gráfico à esquerda da Figura 4.8 apresenta a distribuição das respostas sobre a confiança na IA para interpretar sentimentos em redes sociais. A maior parcela dos participantes, com 29,4%, demonstra uma confiança moderada. Aproximadamente 27% dos respondentes se mantêm neutros, indicando uma posição de cautela ou incerteza. Por outro lado, 19,6% expressam desconfiança quanto à capacidade da IA, enquanto um grupo comparável de 15,7% mostra uma alta confiança, e 7,8% não depositam confiança alguma na IA para essa tarefa.
2. **Você acha que as decisões tomadas por IA são mais justas do que as tomadas por humanos?** No que se refere à justiça das decisões tomadas pela IA, o segundo gráfico da Figura 4.8, revela uma tendência de neutralidade, com 29,4% dos respondentes sem uma opinião definida. Isto sugere uma hesitação em comparar a justiça das decisões da IA com as tomadas por humanos, refletindo possivelmente um reconhecimento da complexidade envolvida na moralidade e ética das decisões. Além disso, 25% discordam que as decisões da IA sejam mais justas, o que pode apontar para preocupações com o viés e a transparência dos algoritmos de IA. Em contraste, um grupo de 15% concorda plenamente que a IA pode tomar decisões mais justas, o que sugere uma crença na objetividade e na ausência de preconceitos que os sistemas de IA podem oferecer.

A neutralidade expressa pode também indicar uma falta de informação suficiente para formar uma opinião forte, destacando a necessidade de mais educação e transparência sobre as capacidades e limitações da IA.

Observando as tendências por idade, Figura 4.8, as respostas tornam-se mais neutras ou desconfiadas com o aumento da faixa etária. Os indivíduos entre 45 e 54 anos mostram uma maior tendência a confiar nas decisões da IA, enquanto os participantes acima de 55

anos demonstram uma tendência maior para a desconfiança. Isso pode refletir diferenças geracionais na familiaridade e no conforto com a tecnologia de IA.

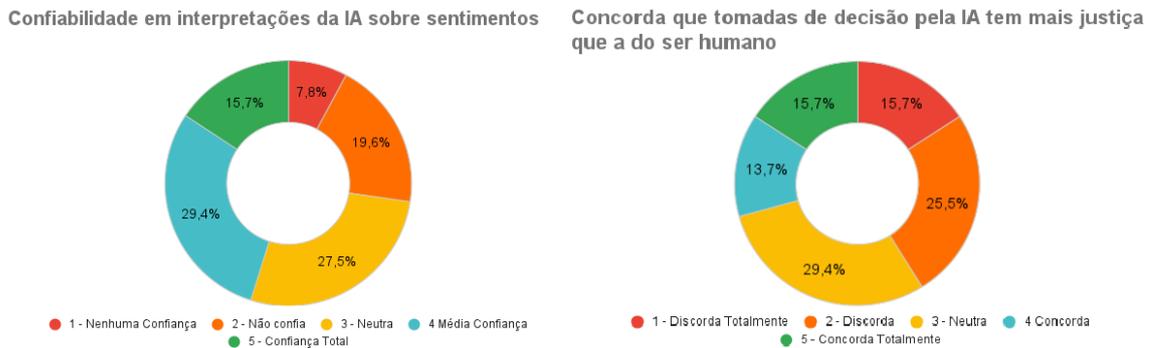


Figura 4.8 – Confiabilidade na justiça da IA e na precisão da em relação à análise de sentimentos
Fonte: Elaborado pela autora (2023)

É possível concluir que, apesar de uma confiança razoável na habilidade da IA de interpretar sentimentos, a confiança na sua tomada de decisão justa permanece moderada. Este fenômeno pode ser atribuído à complexidade de codificar princípios éticos e morais em sistemas algorítmicos e à conscientização sobre os possíveis decisões enviesadas.

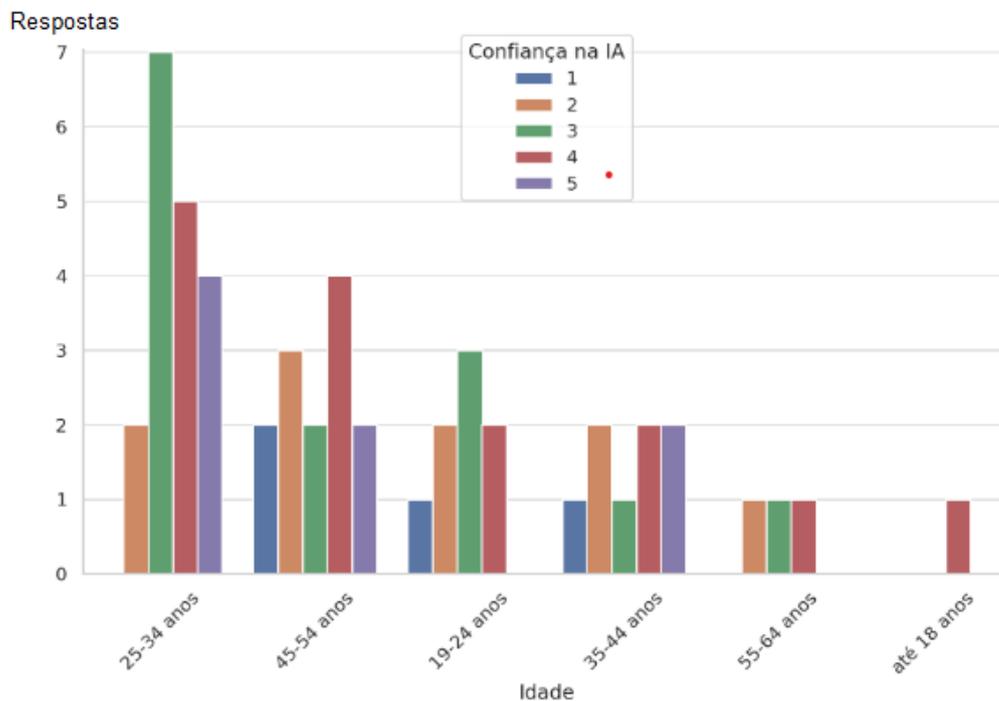


Figura 4.9 – Confiabilidade na justiça da IA e na precisão da em relação à análise de sentimentos relacionada à idade Fonte: Elaborado pela autora (2023)

4.2.3 Futuro da IA

Sobre o Futuro da IA, as seguintes perguntas foram feitas:

1. "Você acha que a tecnologia vai melhorar ou complicar o processo educacional no futuro?"
2. Qual habilidade você considera mais importante para se adaptar ao futuro do trabalho
3. Descreva suas impressões sobre inteligência artificial utilizando palavras ou frases curtas. Sinta-se à vontade para listar tantas palavras quanto achar necessário para expressar sua visão sobre IA.
4. Em sua opinião, até que ponto o uso de IA pode influenciar nas tomadas de decisão da sociedade
5. Você acredita que em um futuro próximo a IA poderá substituir os seres humanos em suas tomadas de decisão?

Com as respostas, foi possível verificar a percepção geral positiva sobre o impacto da tecnologia e da IA na educação, com a maioria das respostas inclinando-se a acreditar que terá um impacto positivo, mostrado na Figura 4.10. No entanto, as tentativas de correlacionar estas opiniões com fatores demográficos como idade, gênero e nível de educação não resultaram em padrões claros ou conclusivos.

A IA irá prejudicar ou agregar na educação?

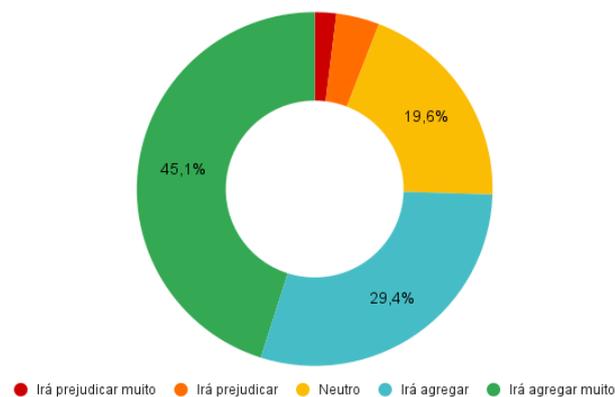


Figura 4.10 – Percepção da influência da IA na educação Fonte: Elaborado pela autora (2023)

Essa falta de correlação mostram que opiniões positivas sobre a IA na educação podem ser bastante generalizadas entre os diferentes grupos demográficos dos respondentes, sem distinções significativas baseadas nessas variáveis.

Já nas correlações demográficas, quando se analisa por idade, existe uma distribuição variada de opiniões, por exemplo, na faixa etária de 45-54 anos, a resposta "Sim" é mais

comum, enquanto nas outras faixas etárias a resposta "Não" ou "Talvez" é mais frequente. Não há padrão quando se trata de gênero, já por nível de educação, as respostas também variam entre os diferentes níveis de educação, onde entre os que têm ensino superior completo, a resposta "Não" é mais comum.

Já sobre o tema polêmico das pessoas acreditarem se a IA irá substituir os seres humanos no futuro, Figura 4.11, a maioria das respostas foram "não" com 41%, e "talvez" 31%, mostrando um ceticismo nessa possibilidade.

Pessoas que acreditam que a IA poderá substituir os seres humanos em suas tomadas de decisão

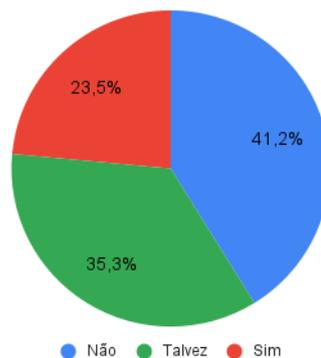


Figura 4.11 – Gráfico de pessoas que acreditam que a IA poderá substituir os seres humano em suas tomadas de decisão Fonte: Elaborado pela autora (2023)

Um ponto interessante que se observou é que, mostrado na Figura 4.12 pessoas que atuam na área da tecnologia, não acreditam que os seres humanos serão substituídos pela IA. E o grupo que atuam na área de direito e contabilidade não acredita de forma alguma.

Grupo da Tecnologia que acham que a IA irá substituir os Seres Humanos

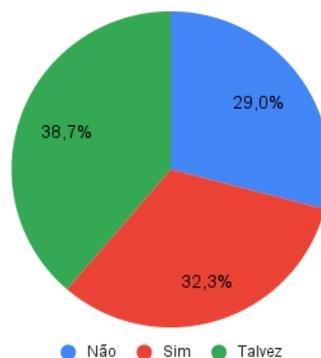


Figura 4.12 – Grupo de Tecnologia quem acham que a IA irá substituir os Seres Humanos. Fonte: Elaborado pela autora (2023)

Toda essa variedade traz a ideia de que as preocupações e expectativas em relação à IA são variadas e não se limitam a um segmento específico da população.

Os gráficos e a análise dos dados sugerem que, independentemente de idade, gênero ou nível de educação, a "Alfabetização Tecnológica e Digital" é considerada a habilidade mais crucial para se adaptar ao futuro do trabalho. Isso reflete uma forte consciência sobre a importância da tecnologia no futuro do trabalho. Outras habilidades como "Pensamento Criativo e Inovação" e "Adaptabilidade e Resiliência" também são valorizadas, indicando uma percepção de que a adaptabilidade e a inovação são igualmente importantes no ambiente de trabalho em constante mudança.

4.2.3.1 Análise de tendências e sentimento

Para a terceira pergunta no âmbito de Futuro a IA, a pergunta foi discursiva, que possibilitou aplicar as mesmas técnicas de análise de sentimentos feita em cima dos *posts* da Plataforma X. Aplicando o código apresentado no Apêndice A.4, explicado na seção 3.5 desse trabalho.



Figura 4.13 – Nuvem de palavras do Survey Fonte: Elaborado pela autora (2023)

A nuvem de palavras destaca "tecnologia" como o termo central, sugerindo que é um tópico dominante e possivelmente visto como um facilitador no contexto discutido.

Palavras como "impacto", "social", "ética" e "neutra" indicam uma discussão sobre as consequências sociais e morais da tecnologia. Termos como "manipuladora" e "tendenciosa" contrastam com "útil" e "facilitadora", refletindo o debate sobre os benefícios e riscos associados à adoção tecnológica. "Desafios" e "futuro" sugerem uma visão prospectiva das implicações da tecnologia.

Na Figura 4.14, o gráfico exibe a frequência de diferentes naturezas extraídas das 51 frases da questão subjetiva sobre opinião sobre a IA. "Opinião" predomina, indicando uma tendência nas frases de expressar pontos de vista pessoais. "Sentimento" e "Análise" são menos frequentes, sugerindo menor expressão de emoções e de avaliações detalhadas ou técnicas nas frases analisadas.

Com base nas análises dos gráficos, é possível concluir que há uma percepção equilibrada sobre a IA, com tendências que sugerem tanto um reconhecimento de sua utilidade quanto uma cautela quanto a seus impactos sociais e éticos.

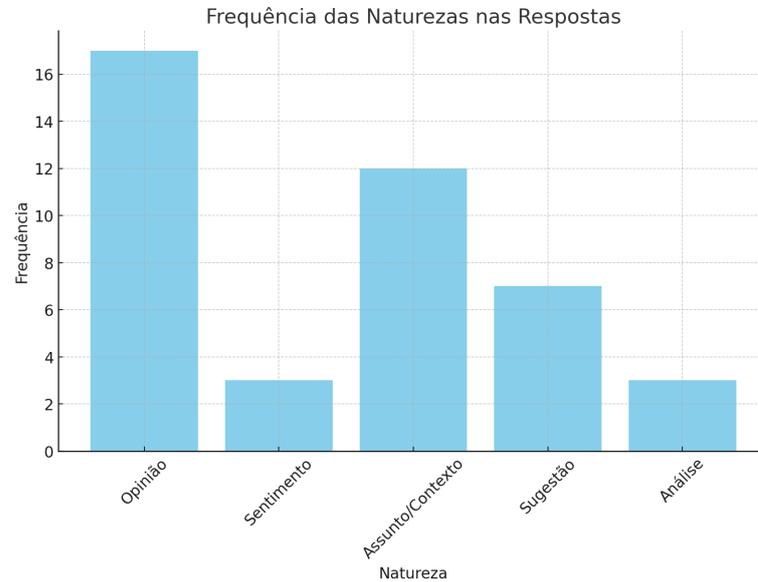


Figura 4.14 – Gráfico com frequência das Naturezas nas Respostas Fonte: Elaborado pela autora (2023)

Na Figura 4.15, é possível observar que no domínio da opinião, "Útil" e "Neutra" são frequentemente mencionadas, sugerindo que as percepções sobre a IA são equilibradas entre o pragmatismo e a imparcialidade. Em relação a "Assunto/Contexto", "Tecnologia" e "Impacto Social" dominam, indicando uma preocupação com as implicações sociais da tecnologia. "Ética" é menos citada, mas ainda relevante.

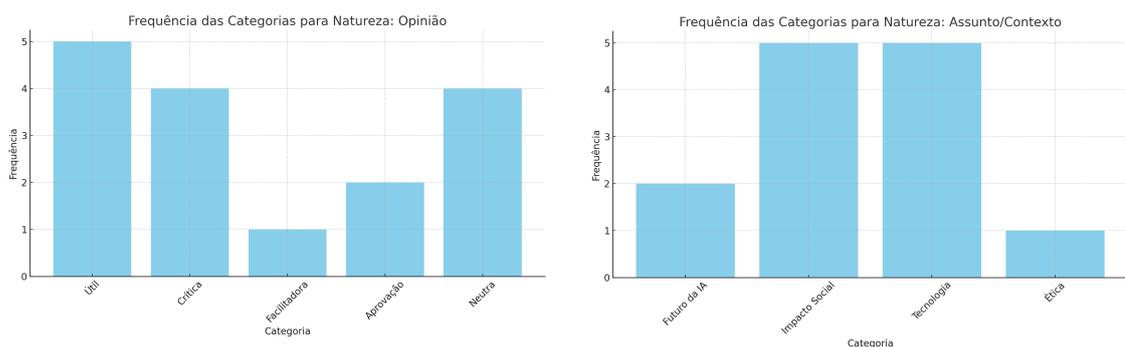


Figura 4.15 – Gráficos sobre Categorias Opinião e Assunto Fonte: Elaborado pela autora (2023)

Na Figura 4.16, as naturezas "Sentimento" e "Sugestão" possuem categorias únicas, "Preocupação" e "Prática" respectivamente, destacando preocupações específicas e orientações para ação. A análise destas frequências ressalta um foco na utilidade prática e nas consequências sociais da IA, com uma consciência ética subjacente.

Concluindo a análise do Survey, tanto de respostas objetivas quanto a subjetiva que trouxeram muita riqueza de dados, é notória a preocupação expressa nos sentimentos. As

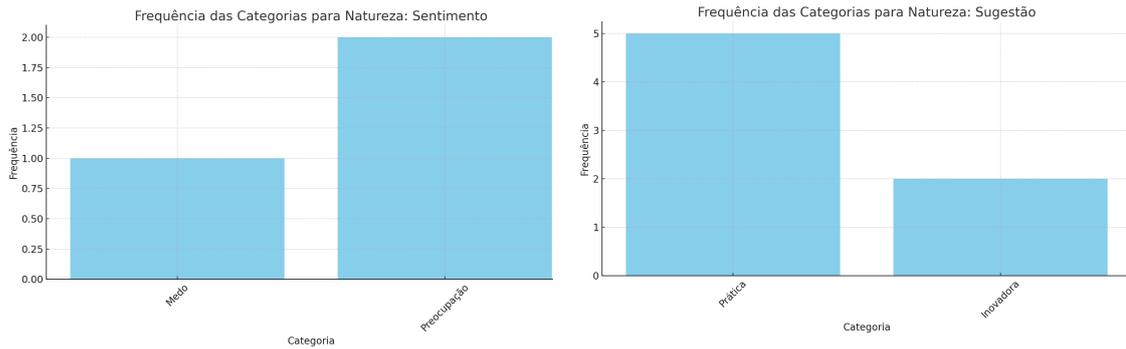


Figura 4.16 – Gráfico sobre Natureza sentimentos e sugestões

sugestões práticas podem indicar que, enquanto as pessoas reconhecem o potencial da IA, elas também estão cientes dos desafios e procuram maneiras de integrar a tecnologia de forma benéfica.

O destaque para a tecnologia e o impacto social nas categorias de assunto/contexto sugere que as implicações mais amplas da IA na sociedade são um tópico relevante de discussão e preocupação. A menor frequência de termos relacionados à ética pode indicar que, embora seja uma consideração importante, pode não ser o foco principal das discussões cotidianas comparado aos benefícios práticos e impactos sociais.

4.3 Análise de tendências sobre a IA um comparativo entre a Plataforma X e o Survey

A partir de agora será feito um comparativo entre as respostas obtidas no Survey e na Plataforma X. O gráfico da Figura 4.17 apresenta uma comparação entre sentimentos expressos nas duas fontes de dados, onde destaca-se a prevalência de respostas positivas no *survey*, consistência em sentimentos neutros entre as fontes, e uma ligeira inclinação para mais expressões negativas no *survey* do que na Plataforma X.

O aumento de sentimentos negativos pode refletir uma tendência dos participantes de surveys em compartilhar insatisfações ou preocupações que talvez não compartilhariam publicamente na Plataforma X.

No gráfico da Figura 4.18, observou-se uma prevalência de "Preocupação" no *survey*, sugerindo maior disposição dos respondentes em expressar ansiedades.

Os sentimentos "Euforia" e "Satisfação" são menos reportadas, talvez refletindo uma tendência de reservar expressões de contentamento para interações sociais diretas. O sentimento de "Medo" mostrou-se moderado, indicando uma possível cautela em compartilhar sentimentos de vulnerabilidade.

A presença de "Neutro" na Plataforma X sugere que a plataforma é bastante utilizada

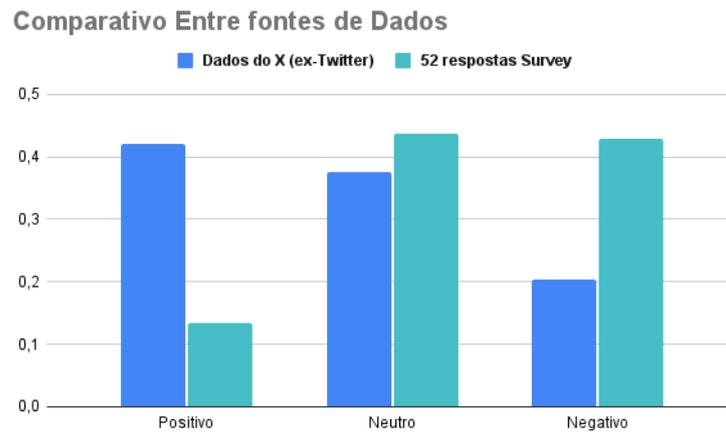


Figura 4.17 – Gráfico representando emoções positivas, negativas e neutras entre as duas fontes de dados Fonte: Elaborado pela autora (2023)

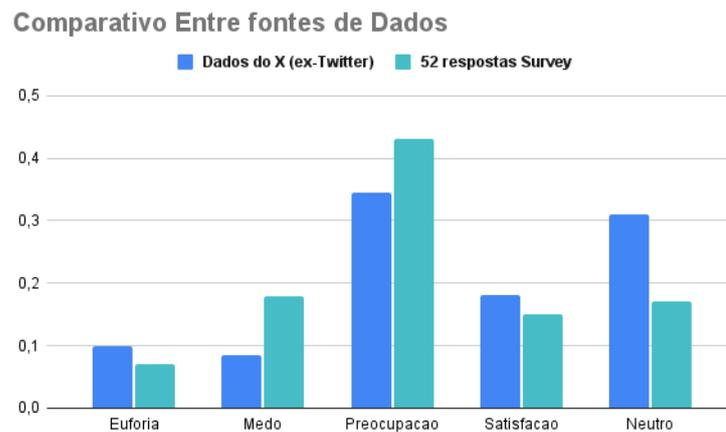


Figura 4.18 – Resultados de análises após treino do dataset expressando natureza do sentimento, como euforia, medo, preocupação e satisfação Fonte: Elaborado pela autora (2023)

para comunicações objetivas. Com isso é possível concluir-se que o *survey* pode encorajar a expressão de preocupações mais do que o ambiente público da Plataforma X.

Já para as nuvens de palavras, foram obtidas as nuvens antes de tratamento dos dados 4.13, onde ambas as nuvens destacam "IA"(Inteligência Artificial), "GPT", "ChatGPT", "coisa", "pessoa", "faz", "tempo", "trabalho" e "tecnologia" com destaque, indicando uma discussão comum sobre tecnologia.

Nas duas há variações na frequência de outras palavras, como "voz", "humano", "arte", que são mais proeminentes na segunda nuvem, possivelmente indicando discussões sobre a interação entre IA e criatividade humana.

Após a etapa de limpeza de dados, foram obtidas mais 2 nuvens de palavras, tendo mais precisão e clareza nos temas discutidos. Ambas destacam "tecnologia", "social", "impacto", "IA"(Inteligência Artificial) e "futuro", indicando uma discussão comum sobre como a tecnologia, especialmente a IA, afetará a sociedade.

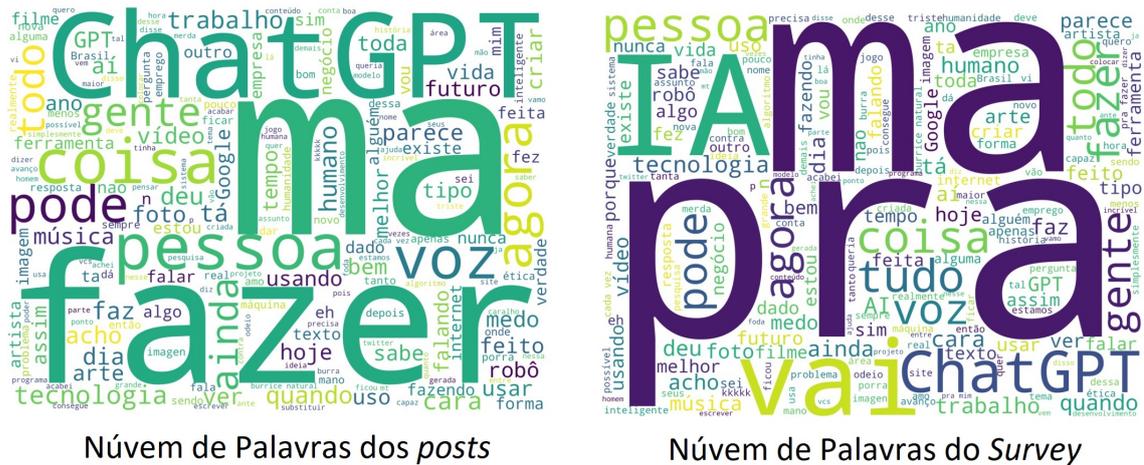


Figura 4.19 – Nuvens de palavras antes da limpeza de dados Fonte: Elaborado pela autora (2023)



Figura 4.20 – Nuvens de palavras antes da limpeza de dados

A primeira nuvem de palavras oferece uma visão mais complexa e potencialmente conflituosa da tecnologia, refletindo um espectro de opiniões e preocupações mais amplo. Já a segunda, parece refinar a discussão, talvez removendo pontos que se destoam e focando em temas mais prevalentes.

Ambas concordam que a tecnologia é um tópico central e que seu impacto na sociedade e a ética são considerações importantes. Essa comparação mostra como a limpeza de dados pode afetar a interpretação da discussão original, potencialmente suavizando extremos e destacando consensos ou temas centrais.

5 Conclusão

A Inteligência Artificial (IA) é um fenômeno transformador na sociedade contemporânea, com o potencial tanto para melhorar quanto para desafiar nossas vidas cotidianas. Este trabalho contribui para uma compreensão mais profunda de como a IA é percebida pelo público, um passo crucial para garantir seu desenvolvimento responsável e alinhado com as necessidades e preocupações humanas.

A abordagem incluiu a realização de uma revisão literária abrangente, abarcando estudos recentes sobre análise de sentimentos no contexto da IA. Utilizando técnicas avançadas de Web Scraping para extrair dados significativos da Plataforma X e implementando algoritmos de Aprendizado de Máquina, incluindo SVM (Support Vector Machines), para classificar textos e analisar sentimentos. Além disso, foi empregado um algoritmo de clustering para analisar a distribuição das objeções por categoria e conduzimos um survey detalhado para correlacionar as emoções detectadas com a experiência real dos usuários.

Este trabalho contribui significativamente para a compreensão do engajamento público com a Inteligência Artificial (IA). Através de uma análise detalhada das interações na Plataforma X e survey, insights valiosos foram obtidos sobre como o público percebe e interage com a IA.

Durante o treinamento de dados, foram enfrentados desafios, especialmente relacionados a vieses inerentes aos datasets. Estes vieses podem influenciar as conclusões e devem ser considerados como limitações. Isso ressalta a necessidade de abordagens cuidadosas na seleção e tratamento de dados.

A análise de sentimentos revelou que a maioria das respostas expressa preocupação com o desenvolvimento e a implementação da IA. Isso sugere uma conscientização pública sobre os potenciais riscos e implicações éticas associadas à IA.

O objetivo de conduzir um survey detalhado para correlacionar as emoções detectadas com a experiência real dos usuários foi alcançado com sucesso. O estudo implementou um questionário abrangente, aplicado a uma amostra significativa de usuários, permitindo uma análise profunda e relevante.

As respostas obtidas do survey forneceram dados valiosos que, quando correlacionados com as emoções detectadas por meio da análise de sentimentos, revelaram insights importantes sobre a percepção pública da Inteligência Artificial. Esta correlação entre as emoções detectadas e as experiências reais dos usuários realçou a complexidade das reações humanas à IA e enriqueceu a compreensão do impacto emocional da tecnologia no cotidiano das pessoas.

Ao comparar os dados das redes sociais com as respostas do survey, foi observada uma consistência nas preocupações expressas, mas também diferenças na profundidade e na natureza das discussões. Isso indica a diversidade de percepções e atitudes em diferentes plataformas e contextos.

As descobertas deste estudo têm aplicações práticas significativas. Elas podem orientar empresas de tecnologia e formuladores de opiniões no desenvolvimento de estratégias de comunicação mais eficazes, na criação de produtos de IA mais alinhados com as preocupações públicas e na elaboração de políticas que abordem questões éticas e sociais.

5.1 Trabalhos Futuros

Para trabalho futuros, é desejado que seja feito um desenvolvimento de um Framework avançado para análise de sentimentos. Ele será indicadores de intensidade emocional, proporcionando maiores precisão de identificação de sentimento. A análise será baseada em Processamento de Linguagem Natural (PLN) profundo, explorando nuances e contextos mais complexos na linguagem.

Além disso, o escopo do Framework se expandirá para análise em outras redes sociais com Instagram, Facebook e notícias no geral, indicando as tendências e os assuntos mais falados em tempo real.

Pretende-se utilizar para isso, análises sofisticadas como integração com API do GPT e com "Azure" para análises mais precisas pois eles já possuem base de dados bem treinada. Além de possibilitar correções sobre vieses nos resultados, assegurando uma análise mais equilibrada e representativa.

Referências

- ALLES, V. J.; GIOZZA, W. F.; OLIVEIRA ALBURQUERQUE, R. de. Natural language processing to classify named entities of the Brazilian Union Official Diary. In: IEEE. 2018 13th Iberian Conference on Information Systems and Technologies (CISTI). 2018. P. 1–6. Citado na p. 23.
- BARRETO, C. **Uso de Técnicas de Aprendizado de Máquina para Identificação de Perfis de Uso de Automóveis Baseado em Dados Automotivos**. Ago. 2018. DOI: [10.13140/RG.2.2.10105.42085](https://doi.org/10.13140/RG.2.2.10105.42085). Citado na p. 21.
- CAVNAR, W. B.; TRENKLE, J. M. et al. N-gram-based text categorization. In: LAS VEGAS, NV. PROCEEDINGS of SDAIR-94, 3rd annual symposium on document analysis and information retrieval. 1994. v. 161175, p. 14. Citado na p. 36.
- FIDDLER, T. **Fiddler Classic**. 2023. <https://www.telerik.com/support/fiddler-classic>. Accessed: [20 de Setembro]. Citado na p. 33.
- FINATTO, M. J. B.; LOPES, L.; SILVA, A. C. Processamento de linguagem natural, linguística de corpus e estudos linguísticos: uma parceria bem-sucedida. **Domínios de lingu@gem. Uberlândia, MG. Vol. 9, n. 5 (dez. 2015), p.[41]-59**, 2015. Citado na p. 22.
- GANTORI, S. **How Artificial Intelligence Will Transform Asia**. 2017. Citado na p. 15.
- GOMES, D. d. S. Inteligência Artificial: conceitos e aplicações. **Revista Olhar Científico**, v. 1, n. 2, p. 234–246, 2010. Citado na p. 15.
- KAPLAN, A. M.; HAENLEIN, M. Users of the world, unite! The challenges and opportunities of Social Media. **Business Horizons**, v. 53, n. 1, p. 59–68, 2010. ISSN 0007-6813. Citado na p. 19.
- MDN WEB DOCS. **CSP Política de Segurança de Conteúdo - HTTP | MDN**. 2023. <https://developer.mozilla.org/pt-BR/docs/Web/HTTP/CSP>. Accessed: 15 de Setembro. Citado nas pp. 32, 46.
- MEDEOT, T. ARTIFICIAL INTELLIGENCE AND SUSTAINABILITY: HOW AI CAN IMPROVE SUSTAINABLE DECISION-MAKING IN MODERN ORGANIZATIONS. **IJRD**, p. 132, 2023. Citado na p. 15.
- MICROSOFT. **Introduction to Blob (object) Storage - Azure Storage**. 2023. Acesso em: 19 de dezembro de 2023. Disponível em: <<https://learn.microsoft.com/en-us/azure/storage/blobs/storage-blobs-introduction>>. Citado nas pp. 37, 45.

- MICROSOFT AZURE BLOG. **Azure Block Blob Storage Backup**. 2018. Acesso em: 19 de dezembro de 2023. Disponível em: <<https://azure.microsoft.com/en-us/blog/azure-block-blob-storage-backup/>>. Citado na p. 37.
- PANG, B.; LEE, L. et al. Opinion mining and sentiment analysis. **Foundations and Trends® in information retrieval**, Now Publishers, Inc., v. 2, n. 1–2, p. 1–135, 2008. Citado na p. 25.
- PARVEEN, N.; CHAKRABARTI, P.; HUNG, B. T.; SHAIK, A. Twitter sentiment analysis using hybrid gated attention recurrent network. **Journal of Big Data**, SpringerOpen, v. 10, n. 1, p. 1–29, 2023. Citado na p. 34.
- PAWAR, P. Y.; GAWANDE, S. A comparative study on different types of approaches to text categorization. **International Journal of Machine Learning and Computing**, IACSIT Press, v. 2, n. 4, p. 423, 2012. Citado na p. 36.
- PRACIANO, B. J. G. Análise preditiva espaço-temporal das tendências eleitorais brasileiras com base nos dados do twitter, 2018. Citado na p. 42.
- PRUDÊNCIO, R. **Aprendizado de Máquina - Introdução**. disponível em <https://slideplayer.com.br/slide/2263120/> – acessado em 10 Dec. 2023. 2014. Citado na p. 22.
- REN, M.; YUE, C. Coverage and Secure Use Analysis of Content Security Policies via Clustering. In: 2023 IEEE 8th European Symposium on Security and Privacy (EuroSP). 2023. P. 411–428. DOI: [10.1109/EuroSP57164.2023.00032](https://doi.org/10.1109/EuroSP57164.2023.00032). Citado na p. 32.
- RODRIGUES, F. B.; GIOZZA, W. F.; OLIVEIRA ALBUQUERQUE, R. de; VILLALBA, L. J. G. Natural language processing applied to forensics information extraction with transformers and graph visualization. **IEEE Transactions on Computational Social Systems**, IEEE, 2022. Citado na p. 23.
- SAMUEL, A. L. Some studies in machine learning using the game of checkers. **IBM Journal of research and development**, IBM, v. 3, n. 3, p. 210–229, 1959. Citado na p. 20.
- SHALEV-SHWARTZ, S.; BEN-DAVID, S. **Understanding Machine Learning: From Theory to Algorithms**. Cambridge University Press, 2014. (Understanding Machine Learning: From Theory to Algorithms). ISBN 9781107057135. Disponível em: <<https://books.google.com.br/books?id=ttJkAwAAQBAJ>>. Citado na p. 20.
- SICHMAN, J. S. Inteligência Artificial e sociedade: avanços e riscos. **Estudos Avançados**, SciELO Brasil, v. 35, p. 37–50, 2021. Citado nas pp. 15, 16.
- SILVA, G. d. M.; GONÇALVES, J. J. O. Proposta de modelo de categorização de tweets para identificar o discurso de ódio contra a mulher, 2023. Citado na p. 42.
- SOUZA, E. N. P.; CLARO, D. B. Extração de relações utilizando features diferenciadas para português. **Linguamática**, v. 6, n. 2, p. 57–65, 2014. Citado na p. 22.

- SOUZA, M.; VIEIRA, R. Sentiment analysis on twitter data for portuguese language. In: SPRINGER. COMPUTATIONAL Processing of the Portuguese Language: 10th International Conference, PROPOR 2012, Coimbra, Portugal, April 17-20, 2012. Proceedings 10. 2012. P. 241–247. Citado na p. 24.
- SPINDOLA, R.; SANTOS, G. L. dos. Mídias sociais como meio para coleta de dados empesquisas de educação: Estudo de caso de uso do twitter. **ETD: Educação Temática Digital**, Faculdade de Educação, n. 25, p. 24, 2023. Citado na p. 19.
- TAUSCZIK, Y. R.; PENNEBAKER, J. W. The psychological meaning of words: LIWC and computerized text analysis methods. **Journal of language and social psychology**, Sage Publications Sage CA: Los Angeles, CA, v. 29, n. 1, p. 24–54, 2010. Citado na p. 24.
- TOOLS, W. B. **Test CSP - Web Browser Tools**. 2023. <https://webbrowsertools.com/test-csp/>. Accessed: [20 de Setembro]. Citado na p. 33.
- TWEEPY. **Tweepy Documentation**. 2023. Acessado em: [11 de Setembro]. Disponível em: <<https://docs.tweepy.org/>>. Citado nas pp. 29, 39.
- TWITTER. **Getting Started**. 2023. Acessado em: 20 de Setembro. Disponível em: <<https://developer.twitter.com/en/docs/tutorials/step-by-step-guide-to-making-your-first-request-to-the-twitter-api-v2>>. Citado na p. 29.
- TWITTER. **Academic Research - Twitter Developer**. 2023a. <https://developer.twitter.com/en/use-cases/do-research/academic-research>. Accessed: [20 de Setembro]. Citado na p. 32.
- TWITTER. **Política de Segurança - Twitter**. 2023b. <https://twitter.com/en/privacy>. Accessed: [20 de Setembro]. Citado nas pp. 32, 46.
- WE ARE SOCIAL. **Digital 2023 October Global Statshot Report**. Out. 2023. <https://wearesocial.com/blog/2023/10/informe-digital-2023-octubre/>. Acessado em 27 de novembro de 2023. Citado nas pp. 15, 19.
- YUSOF, I.; PATHAN, A.-S. K. Mitigating Cross-Site Scripting Attacks with a Content Security Policy. **Computer**, v. 49, n. 3, p. 56–63, 2016. DOI: 10.1109/MC.2016.76. Citado na p. 32.

Apêndice A – Códigos e Scripts

A.1 Script de Raspagem de Tweets

Código A.1 – Implementação do Script de Coleta e Armazenamento de Dados de Tweets

```
1 let isNewTweet = (tweet) => {
2   return !tweetsAcc.includes(tweet);
3 }
4
5
6 function createDto(tweet) {
7
8   let name = tweet.querySelector('[data-testid=User-Name]').textContent
9   let tweetText = tweet.querySelector('[data-testid="tweetText"]').textContent
10  let tweetDate = tweet.querySelector('time').getAttribute('datetime')
11  let comments =
12    tweet.querySelectorAll('[data-testid="app-text-transition-container"]')
13  let retweets =
14    tweet.querySelectorAll('[data-testid="app-text-transition-container"]')
15  let likes =
16    tweet.querySelectorAll('[data-testid="app-text-transition-container"]')
17  let views =
18    tweet.querySelectorAll('[data-testid="app-text-transition-container"]')
19  let html = tweet.outerHTML
20
21  return {
22    name,
23    tweetText,
24    tweetDate,
25    comments,
26    retweets,
27    likes,
28    views,
29    html
30  }
31 }
```

A.2 Armazenamento de Dados de Tweets em Azure Blob Storage

Código A.2 – Script para salvar informações de tweets no Azure Blob Storage.

```
1
2 \\Salvar no Blob Storage (SalvarBlob):
3 function SalvarBlob(dto) {
4     const accountName = 'tweetScrap';
5     const sasToken = 'token';
6     const containerName = 'tweets';
7     const blobName = `${dto.name}_${dto.tweetDate}.json`;
8
9     const url = 'urlBlob';
10
11
12
13     fetch(url, {
14         method: 'PUT',
15         headers: {
16             'x-ms-blob-type': 'BlockBlob',
17             'Content-Type': 'application/json',
18             'Access-Control-Allow-Origin': '*'
19         },
20         body: JSON.stringify(dto)
21     })
22     .then(response => response.json())
23     .then(data => console.log(data))
24     .catch(error => console.error('Error:', error));
25
26 }
```

A.3 Automação de Coleta e Armazenamento de Dados de Tweets

Código A.3 – Script para rolagem automática e armazenamento de tweets em lote.

```
1
2 \\ Automação de Rolagem (disposable) e Acumulação de Tweets
3 let disposable = setInterval(() => window.scrollBy(0, 100), 1000)
4
5 let tweetsAcc = [];
6
7 \\Processamento e Salvamento de Novos Tweets (storeNewTweets):
8 let storeNewTweets = () => {
9     let isNewTweet = (tweet) => {
10         return !tweetsAcc.includes(tweet);
11     }
12     let toAdd =
13         [...document.querySelectorAll('[data-testid=tweet]')].filter(isNewTweet)
14
15     toAdd.forEach(element => {
16         tweetsAcc.push(element);
17     });
18
19     if (tweetsAcc.length > 100) {
20         tweetsAcc = []
21     }
22
23     let toSave = []
24
25     toAdd.forEach(element => {
26         try {
27             toSave.push(createDto(element))
28         } catch (error) {
29             console.log(error)
30         }
31     });
32
33     toSave.forEach(async element => {
34         let eixsts = await BlobExists(element)
35         if (eixsts) {
36             return
37         }
38
39         SalvarBlob(element)
40     });
41 }
42
43 \\Evento de Rolagem
44 document.addEventListener('scroll', () => storeNewTweets())
```

A.4 Código Python para Geração de Nuvem de Palavras

Código A.4 – Código para geração de nuvem de palavras

```
1 # Importando as bibliotecas necessárias
2 from wordcloud import WordCloud, STOPWORDS
3 import matplotlib.pyplot as plt
4
5
6 stopword = [
7     'e',
8     'tu',
9     'delas',
10    'ser',
11    'está',
12    'para',
13    'vos',
14    'no',
15    'com',
16    'aos',
17    'teu',
18 ]
19
20 # Carregar o texto de um arquivo
21 file_path = 'D:/EmotionIA/allTweets.txt'
22 with open(file_path, 'r', encoding='utf-8') as file:
23     text = file.read()
24
25 custom_stopwords = set(STOPWORDS)
26
27 for i in palavras:
28     custom_stopwords.add(i)
29
30
31
32 # Criar a nuvem de palavras
33 wordcloud = WordCloud(stopwords=custom_stopwords, background_color="white",
34                       width=1600,
35                       height=1200,
36                       scale=5
37                       ).generate(text)
38
39
40 # Mostrar a imagem gerada
41 plt.imshow(wordcloud, interpolation='bilinear')
42 plt.axis("off")
43 plt.show()
44 plt.savefig('wordcloud.png')
```

A.5 Código Python para Limpeza de Dados

Código A.5 – Código Python para Limpeza de dados com Tokenização

```
1 import spacy
2 from sklearn.feature_extraction.text import CountVectorizer
3 from nltk.corpus import stopwords
4 from nltk.stem import RSLPStemmer
5
6 # Função para limpar, tokenizar e aplicar stemming
7 def preparar_texto(texto):
8     # Carrega o modelo spaCy em português
9     nlp = spacy.load('pt_core_news_sm')
10
11     # Lista de stopwords em português
12     stop_words_pt = set(stopwords.words('portuguese'))
13
14     # Inicializa o stemmer
15     stemmer = RSLPStemmer()
16
17     # Processa o texto
18     doc = nlp(texto)
19
20     # Filtra tokens, remove stopwords, pontuações e aplica stemming
21     tokens = [stemmer.stem(token.text) for token in doc if token.text not in
22               stop_words_pt and not token.is_punct]
23
24     return ' '.join(tokens)
25
26 # Função para vetorizar os textos
27 def vetorizar_textos(textos):
28     vectorizer = CountVectorizer()
29     X = vectorizer.fit_transform(textos)
30     return X, vectorizer.get_feature_names_out()
31
32 # Função principal para processar e vetorizar textos
33 def analisar_sentimentos_ai(lista_textos):
34     textos_preparados = [preparar_texto(texto) for texto in lista_textos]
35     vetores, vocabulario = vetorizar_textos(textos_preparados)
36     return vetores.toarray(), vocabulario
37
38 # Exemplo de uso
39 textos = ["A inteligência artificial vai revolucionar o mundo.", "Os robs serão
40           nossos amigos ou inimigos?"]
41 vetores, vocabulario = analisar_sentimentos_ai(textos)
42
43 print("Vocabulário:", vocabulario)
44 print("Vetores de texto:\n", vetores)
```

A.6 Código Python para Treinamento de Sentimento

Código A.6 – Código Python para Treinamento de Sentimento

```
1 import pandas as pd
2 import numpy as np
3 import nltk
4 from nltk.tokenize import word_tokenize
5 from nltk.corpus import stopwords
6 from nltk.stem import RSLPStemmer
7 import unicodedata
8 from sklearn.model_selection import train_test_split
9 from sklearn import svm
10 from sklearn.metrics import classification_report, confusion_matrix
11 from sklearn.feature_extraction.text import TfidfVectorizer
12 import matplotlib.pyplot as plt
13 import seaborn as sns
14
15 # nltk downloads
16 nltk.download('punkt')
17 nltk.download('stopwords')
18
19 #Chamada para o script de limpeza limpo.csv**
20
21 import os
22 os.system('python limpeza.py')
23
24 # Ler o arquivo limpo
25 tweets_df = pd.read_csv('limpo.csv', usecols=['Sentiment', 'TweetText'])
26
27 # Processa função de sentimento
28 def process_sentiment(sentiment):
29     sentiment = sentiment.strip() # Remove trailing spaces
30     if sentiment == 'Positive':
31         return 1
32     elif sentiment == 'Negative':
33         return -1
34     elif sentiment in ['Neutral', 'Mixed']:
35         return 0
36
37 # Aplicando a função de processamento de sentimento
38 tweets_df['processed_Sentiment'] =
39     tweets_df['Sentiment'].apply(process_sentiment)
40
41 # Divisão dos dados em conjuntos de treinamento e teste
42 X_train, X_test, y_train, y_test = train_test_split(tweets_df['TweetText'],
43     tweets_df['processed_Sentiment'], test_size=0.2)
44
45 # Vectorização com TF-IDF
46 vectorizer = TfidfVectorizer()
47 X_train_vectors = vectorizer.fit_transform(X_train)
48 X_test_vectors = vectorizer.transform(X_test)
```

```
47
48 # Treinamento do modelo SVM
49 clf = svm.SVC(kernel='linear')
50 clf.fit(X_train_vectors, y_train)
51
52 # Avaliação do modelo
53 y_pred = clf.predict(X_test_vectors)
54 print(classification_report(y_test, y_pred))
55
56 # Matriz de Confusão
57 cm = confusion_matrix(y_test, y_pred)
58 sns.heatmap(cm, annot=True, fmt="d")
59 plt.title("Confusion Matrix")
60 plt.ylabel('Actual')
61 plt.xlabel('Predicted')
62 plt.show()
```