

**INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA
CAMPUS CAJAZEIRAS
CURSO SUPERIOR DE TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE
SISTEMAS**

**UM ESTUDO SOBRE VIESES DE GÊNERO EM MODELOS DE PLN
APLICADO EM HISTÓRIAS GERADAS PELO GPT-3.5 E GEMINI**

MARIA CLARA RAMALHO MEDEIROS

**Cajazeiras
2025**

MARIA CLARA RAMALHO MEDEIROS

**UM ESTUDO SOBRE VIESES DE GÊNERO EM MODELOS DE PLN APLICADO EM
HISTÓRIAS GERADAS PELO GPT-3.5 E GEMINI**

Trabalho de Conclusão de Curso apresentado junto ao Curso Superior de Tecnologia em Análise e Desenvolvimento de Sistemas do Instituto Federal de Educação, Ciência e Tecnologia da Paraíba - Campus Cajazeiras, como requisito à obtenção do título de Tecnólogo em Análise e Desenvolvimento de Sistemas.

Orientador

Prof. Me. Francisco Paulo de Freitas Neto.

**Cajazeiras
2025**

Dados Internacionais de Catalogação na Publicação (CIP)

M488e Medeiros, Maria Clara Ramalho

Um estudo sobre vieses de gênero em modelos de PLN aplicado em histórias geradas pelo GPT-3.5 e GEMINI/Maria Clara Ramalho Medeiros. – Cajazeiras, 2025.
68f.: il.

Trabalho de Conclusão de Curso (Análise e Desenvolvimento de Sistemas) - Instituto Federal de Educação, Ciência e Tecnologia da Paraíba, Campus Cajazeiras. Cajazeiras, 2025.

Orientador(a): Prof. Me. Francisco Paulo de Freitas Neto.

1. Inteligência Artificial Generativa 2. PLN 3. Viés de gênero I. Título. II. Maria Clara Ramalho Medeiros.

CDU: 004



MINISTÉRIO DA EDUCAÇÃO
SECRETARIA DE EDUCAÇÃO PROFISSIONAL E TECNOLÓGICA
INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA

MARIA CLARA RAMALHO MEDEIROS

**UM ESTUDO SOBRE VIESES DE GÊNERO EM MODELOS DE PLN APLICADO EM
HISTÓRIAS GERADAS PELO GPT-3.5 E GEMINI**

Trabalho de Conclusão de Curso apresentado junto ao
Curso Superior de Tecnologia em Análise e
Desenvolvimento de Sistemas do Instituto Federal de
Educação, Ciência e Tecnologia da Paraíba - Campus
Cajazeiras, como requisito à obtenção do título de
Tecnólogo em Análise e Desenvolvimento de Sistemas.

Orientador

Prof. Me. Francisco Paulo de Freitas Neto

Aprovada em: **18 de Março de 2025.**

Prof. Me. Francisco Paulo de Freitas Neto - Orientador

Prof. Dr. Fabio Gomes de Andrade - Avaliador

IFPB - Campus Cajazeiras

Profa. Dra. Eva Maria Campos Pereira

IFPB - Campus Cajazeiras

Documento assinado eletronicamente por:

- **Francisco Paulo de Freitas Neto**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 19/03/2025 08:31:57.
- **Fabio Gomes de Andrade**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 19/03/2025 09:00:36.
- **Eva Maria Campos Pereira**, PROFESSOR ENS BASICO TECN TECNOLOGICO, em 25/03/2025 07:50:24.

Este documento foi emitido pelo SUAP em 19/03/2025. Para comprovar sua autenticidade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/autenticar-documento/> e forneça os dados abaixo:

Código 684119
Verificador: 9f8b34d1cb
Código de Autenticação:



Rua José Antônio da Silva, 300, Jardim Oásis, CAJAZEIRAS / PB, CEP 58.900-000
<http://ifpb.edu.br> - (83) 3532-4100

*Este trabalho dedico a todas as mulheres
na área da computação e tecnologia.*

AGRADECIMENTOS

Em primeiro lugar, a Deus e ao Universo por ter me abençoado me dando a oportunidade de desenvolver esse TCC com saúde e me presentear com as melhores pessoas do mundo que eu poderia ter do meu lado durante esse processo.

Em segunda lugar, à minha família, por todo o suporte incondicional de todas as formas que me foi dado desde o início dessa jornada e todos esses anos, com muito amor, apoio e confiança em meu potencial.

Aos meus amigos que estiveram comigo durante esse processo, me escutando, me confortando e me incentivando. Por cada momento que compartilhamos que me deram mais força e coragem para continuar o desenvolvimento desse trabalho, mesmo que indiretamente. Tenho muita gratidão pela faculdade ter me proporcionado uma rede de apoio que posso contar tanto, são as melhores pessoas que eu poderia confiar.

E por fim, mas não menos importante, a meu orientador, Paulo, que era o único que conseguia me tranquilizar completamente quando estive desanimada com minha pesquisa. Em geral, a todas as pessoas que me ouviram e me motivaram. Muito obrigada a todos que confiaram em mim.

RESUMO

Este trabalho aborda a importância de estudar os vieses de gênero em modelos de Processamento de Linguagem Natural (PLN), especialmente em relação às inteligências artificiais gerativas. A pesquisa buscou entender como esses vieses são reproduzidos em textos gerados por modelos como GPT e Gemini. Para isso, modelos de PLN como XLNet, BERT e DistilBERT foram treinados para inferir o gênero e avaliar a tendência dos textos em relação a estereótipos. O estudo utilizou bases de dados específicas, md_gender_bias e Stereoset, para investigar esses vieses, destacando a relevância de analisar o impacto social das IAs, especialmente quando usadas sem considerar esses vieses. A md_gender_bias foi usada para treinar um modelo capaz de inferir o gênero o qual se refere e Stereoset para classificar se o texto tende ao antiestereótipo ou estereótipo de gênero. A partir da análise dos resultados obtidos, foi possível confirmar a presença de vieses nesses modelos.

Palavras-chave: PLN. Viés de gênero. GPT. Gemini. Inteligência Artificial Generativa.

ABSTRACT

This work addresses the importance of studying gender biases in Natural Language Processing (NLP) models, particularly in relation to generative artificial intelligence. The research aims to understand how these biases are reproduced in texts generated by models like GPT and Gemini. To achieve this, NLP models such as XLNet, BERT, and DistilBERT were trained to infer gender and evaluate the tendency of texts towards stereotypes. The study utilized specific datasets to investigate these biases, highlighting the importance of analyzing the social impact of AI, especially when used without considering these biases. `md_gender_bias` was used to train a model capable of inferring the gender it refers to, and Stereoset was used to classify whether the text leans towards anti-stereotype or gender stereotype. Based on the analysis of the obtained results, the presence of biases in these models was confirmed.

Keywords: NLP. Gender bias. GPT. Gemini.

LISTA DE FIGURAS

Figura 1 – Exemplo de tokenização	18
Figura 2 – Gênero dos anotadores da <i>MGB</i>	25
Figura 3 – Metodologia utilizada	41
Figura 4 – Gráficos de dispersão dos dados obtidos pela aplicação dos modelos treinados no Stereoset	48
Figura 5 – Gráficos de barra do percentil de rotulação do label_0 de acordo com o BERT no Stereoset	49
Figura 6 – Gráficos de heatmap dos percentis de rotulação dos labels de acordo com o BERT no MGB	50
Figura 7 – Amostragem em português	51
Figura 8 – Gráficos de barras obtidos pela aplicação dos modelos treinados na MGB	53

LISTA DE CÓDIGOS

Algoritmo 1 – Como fazer uma requisição para a API do GPT	24
Algoritmo 2 – Como fazer uma requisição para a API do Gemini	24
Algoritmo 3 – Estrutura da configuração da base de dados no formato JSON .	26
Algoritmo 4 – Estrutura dos dados utilizados na base de dados StereoSet no formato JSON	27
Algoritmo 5 – Como foi feito o treinamento dos modelos e seus hiper parâmetros	43
Algoritmo 6 – Estrutura de dados do resultado dos modelos treinados no Stere- oset	46

LISTA DE ABREVIATURAS E SIGLAS

API	Application Programming Interface
BERT	Bidirectional Encoder Representations from Transformers
CLN	Compreensão de Linguagem Natural
GLN	Geração de Linguagem Natural
GPT	Generative Pre-trained Transformers
IA	Inteligência Artificial
JSON	JavaScript Object Notation
MGB	md_gender_bias
NLU	Natural Language Understanding
PLN	Processamento de Linguagem Natural
TCC	Trabalho de Conclusão de Curso
XLNet	Generalized Autoregressive Pretraining for Language Understanding

SUMÁRIO

1	INTRODUÇÃO	11
1.1	PROBLEMÁTICA	13
1.2	OBJETIVOS	14
1.2.1	Objetivo geral	14
1.2.2	Objetivos específicos	15
1.3	ORGANIZAÇÃO DO DOCUMENTO	15
2	PLN E VIESES DE GÊNERO	17
2.1	PLN em termos técnicos	17
2.1.1	Entendendo como funcionam modelos de PLN	17
2.1.2	BERT, DistilBERT e XLNet	20
2.1.3	GPT e Gemini	22
2.1.4	Conhecendo as bases de dados	24
2.2	Entendendo vieses e quais suas fontes	28
2.3	Gênero no PLN	31
2.3.1	Butler, concepções de gênero e implicações da binaridade no PLN	31
2.3.2	Ideologias de gênero heteronormativas nos dados de treinamento	34
2.3.3	Gênero linguístico	36
2.3.4	Métricas para avaliação de viés de gênero	37
3	METODOLOGIA	41
4	RESULTADO E DISCUSSÕES	46
5	CONSIDERAÇÕES FINAIS	56
	REFERÊNCIAS	58
	APÊNDICE A – LISTA COM TODOS OS <i>PROMPTS</i> UTILIZADOS PARA GERAR A BASE DE DADOS	63
	APÊNDICE B – HISTÓRIA DE EXEMPLO GERADA PELO GEMINI NA TEMÁTICA DE FRONT-END	64

APÊNDICE C – HISTÓRIA DE EXEMPLO GERADA PELO GPT NA TEMÁTICA DE FRONT-END 65

1 INTRODUÇÃO

O campo da Inteligência Artificial está se expandindo todos os dias, tanto que deixou de ser algo distante, conhecido apenas por pessoas da área da tecnologia, e se tornou algo popular a partir de sua evolução que se tornou possível realizar atividades normalmente feitas por humanos e outras que superam a capacidade humana (KAUFMAN, 2020).

Entre as Inteligências Artificiais com as quais se está mais acostumado diariamente, é possível mencionar as que trabalham com textos e linguagem, as de Processamento de Linguagem Natural ou PLN (RUSSELL; NORVIG, 2019).

Esses modelos têm o propósito de lidar diretamente com tudo que é voltado à linguagem. Seja Análise de Sentimento ou Reconhecimento de Emoções, a qual é uma versão mais complexa e expansiva da primeira, que tem a finalidade de identificar o sentimento/emoção de um texto, como, por exemplo, uma avaliação de um produto em um site de compras.

Também existem as de Resolução de Correferência, comumente utilizadas para sistemas de tradução de linguagens, como o Google Tradutor, que calcula o grau de correlação entre as palavras. Outra opção é a de Reconhecimento de Entidades Nomeadas, com a finalidade de categorizar entidades em textos, como, por exemplo, identificar substantivos como indivíduos, lugares, comidas, etc.

Além das citadas, há as de Geração de Texto, seja gerando em si novos textos a partir de outros, como resumos ou a geração de novos a partir de instruções. Essa finalidade é utilizada popularmente para perguntas e respostas, podendo citar o *ChatGPT* e Gemini entre as inteligências artificiais mais populares que utilizam dessa dinâmica (OPENAI, 2022; DEEPMIND, 2023). Dessa forma, modelos de PLN, no geral, estão ligados ao entendimento da linguagem, tal como os seres humanos entendem e compreendem uns aos outros.

É nesse seu processo de compreensão e aprendizado, de identificar padrões e tentar reproduzir o que para o ser humano é naturalmente cognitivo, que os vieses surgem como produto da ação humana. Como por exemplo, seja influenciando o seu resultado na escolha da base de dados para o seu aprendizado. O próprio Google reforça, num vídeo feito em 2017 publicado na plataforma *Youtube*¹: “mesmo que

¹ <https://youtu.be/59bMh59JQDo?si=T3cM35l8MdrnTjRp>

algo seja baseado em dados, isso não o torna automaticamente neutro [...]. Nossos vieses como humanos passam a fazer parte das tecnologias que criamos” (Online). Sustentando esse mesmo argumento, segundo (O’NEIL, 2016, p.35), “modelos são opiniões embutidas em matemática”.

Essas opiniões que O’Neil se refere são os vieses, e eles estão ligados intrinsecamente com a forma como o indivíduo julga as pessoas e o mundo ao seu entorno, atribuindo concepções e opiniões sobre eles, seja de forma favorável ou em seu detrimento. De forma mais específica, refere-se à “presença de um tratamento injusto ou preconceituoso direcionado a certos grupos ou indivíduos baseados em características como raça, gênero, religião ou etnicidade” (SILBERG; MANYIKA, 2019, Tradução nossa), como também pessoas com deficiências, orientação sexual e idade. Qualquer grupo pode estar passível a sofrer das consequências desses vieses, mas uns em maior frequência e prejuízo.

Consequentemente, os vieses de gênero em modelos de Processamento de Linguagem Natural (PLN) têm sido amplamente documentados e analisados em diversas aplicações, incluindo análise de sentimentos, tradução automática e modelos generativos de pergunta e resposta, que são o foco desta pesquisa.

Um exemplo que estampou os noticiários foi o da *Amazon*, empresa multinacional de tecnologia norte-americana, que se envolveu com polêmicas quando utilizou, no ano de 2014, um algoritmo para avaliar currículos e escolher quais pessoas seriam contratadas, o que resultou na rejeição de todas as pessoas do gênero feminino candidatas. “Uma simples menção ao termo ‘de mulheres’ no currículo era penalizada pela ferramenta, e reduzia as chances das postulantes às vagas, mesmo que estivesse se referindo a instituições de ensino só para mulheres” (AUTRAN, 2018), afirma a reportagem.

Outro exemplo claro de viés pode ser observado na tradução automática, que frequentemente perpetua estereótipos de gênero. Um caso amplamente conhecido envolve o Google Tradutor, que ao traduzir a frase "The doctor asked the nurse to help her in the procedure" do inglês para o espanhol, gerou uma tradução errônea ao alterar o pronome feminino "her", que se referia ao "doctor", para o pronome masculino "el". Ao mesmo tempo, "nurse" foi traduzido como "la enfermera", reforçando o estereótipo de gênero feminino. Esse exemplo ilustra como modelos de tradução automática podem introduzir inferências de gênero indesejadas, refletindo vieses presentes nos dados de treinamento (STANOVSKY et al., 2019).

Estudos recentes, como o realizado na pesquisa "Evaluating Gender Bias

in Machine Translation", mostraram que todos os sistemas testados, incluindo os mais avançados, tendem a traduzir com base em estereótipos de gênero, especialmente quando aplicados a papéis tradicionalmente associados a um gênero, como "nurse"(enfermeira) ou "receptionist"(repcionista) (STANOVSKY et al., 2019).

Em relação às IAs gerativas, o GPT tem sido alvo de vários estudos sobre vieses de gênero. Na área da saúde, por exemplo, foi constatado que o GPT-4 tende a reforçar estereótipos relacionados à raça e ao gênero ao gerar diagnósticos clínicos, afetando negativamente a precisão e a diversidade nas vinhetas clínicas (ZACK et al., 2023). Além disso, pesquisas sobre as histórias geradas pelo GPT indicam que, ao gerar narrativas, há uma predominância de personagens masculinos, refletindo estereótipos sociais de gênero (LUCY; BAMMAN, 2021).

Embora haja estudos extensivos sobre os vieses no GPT, observou-se uma lacuna em relação ao modelo Gemini. Em fevereiro de 2024, Sundar Pichai, CEO do Google, fez uma declaração sobre a problemática dos vieses na geração de imagens pelo Gemini, prometendo melhorias, mas até maio de 2024, nenhuma atualização significativa havia sido divulgada (GOOGLE. . . , 2024). A presença de vieses no Gemini também se reflete em sua configuração de segurança, que, em alguns casos, interrompe a geração de conteúdo devido à detecção de possíveis vieses ou conteúdo prejudicial, como ocorreu durante o teste de prompts relacionados à tecnologia, que resultaram em um erro de conteúdo sexualmente explícito sem qualquer instrução para tal.

Esses exemplos demonstram a capacidade dos modelos de IA, como o GPT e o Gemini, de gerar conteúdos enviesados e prejudiciais. Esse cenário reforça a necessidade de estudos mais aprofundados sobre como esses modelos, amplamente utilizados, podem afetar a geração de conteúdo, especialmente em áreas sensíveis, como a representação de gênero. Neste trabalho, investigaremos, na prática, como o GPT 3.5 e o Gemini geram histórias na temática da tecnologia, com foco na possível manifestação de vieses de gênero.

1.1 PROBLEMÁTICA

Como visto, o caso da *Amazon* é um exemplo explícito dos possíveis resultados alarmantes que os vieses de gênero podem causar por inteligência artificial. Conforme (COSTA-JUSSA, 2019) menciona, “viés de gênero pode ser definido como a dominância, em contextos específicos como profissões ou acima de papéis sociais primários, de um gênero sobre o outro. Como consequência, o gênero menos dominante é mal representado e estereótipos aparecem” [p.2, Tradução nossa]. Pensando nesse caso,

é isso que aconteceu ao treinar o modelo com uma base de dados majoritariamente masculina, já que pelo histórico de empregados, os contratados em sua maior parte sempre eram homens. Com isso, o modelo aprendeu, a partir dos dados fornecidos, um viés de gênero, penalizando indivíduos cuja identificação ou características estavam associadas ao feminino, resultando em menor chance de aprovação.

O viés de gênero, por sua vez, é prejudicial por reproduzir ações preconceituosas, atingindo principalmente pessoas cisgêneros (que se identificam com seu gênero biológico) e pessoas trans do gênero feminino ou pessoas não binárias, justamente pela falta de representação dos dados ou pela esteriotipação. Essa problemática não é tão recente quanto se pensa (começando por volta da década de 1990), mas se tornou um tópico ainda maior de pesquisa em 2012, com o aumento de Inteligências Artificiais de PLN baseadas em Aprendizado Profundo (*Deep Learning*) (COSTA-JUSSA, 2019). Existindo até o ano de 2022, aproximadamente 200 pesquisas sobre esse tema (DEVINNEY et al., 2022). Por isso, tendo em conta sua recência, há muitos pontos que ainda não foram abordados ou abordagens que ainda não foram utilizadas. Ainda mais quando se fala de Inteligências Artificiais Gerativas.

Diante desses desafios, é a partir da seguinte problemática que o trabalho a seguir irá abordar: **Como vieses de gênero se relacionam com modelos de PLN? Especificamente, como eles se relacionam com o GPT-3.5 e Gemini, modelos de PLN Gerativos.** Para servir como auxílio, foram desenvolvidos seis modelos de PLN, organizados em dois trios com finalidades específicas: três modelos para inferir o gênero ao qual um texto se refere e três modelos para classificar se um texto tende mais ao estereótipo ou ao anti-estereótipo de gênero, variando apenas na arquitetura utilizada como base (BERT, DistilBERT ou XLNet). Ambos foram aplicados em textos gerados por IAs Gerativas de texto, o GPT-3.5 e o Gemini, em histórias temáticas sobre desenvolvimento de tecnologia. Uma análise dessas histórias permite identificar padrões e compreender de que essas formações de IA refletem ou reforçam desigualdades de gênero presentes nos dados em que foram treinadas.

1.2 OBJETIVOS

1.2.1 Objetivo geral

Sob essa perspectiva, o trabalho tem como objetivo estudar como os vieses de gênero se manifestam no GPT-3.5 e Gemini, especificamente em histórias geradas na temática da tecnologia.

1.2.2 Objetivos específicos

- Entender características gerais de modelos de PLN, termos e técnicas mais importantes, conhecendo mais sobre os modelos utilizados na pesquisa, sobre os próprios modelos alvos de estudo e também sobre as bases de dados utilizadas para treinamento.
- Estudar os tipos de vieses e como eles podem se manifestar em modelos de PLN e também ser identificados, focando principalmente em vieses de gênero, em que é realizada uma contextualização sobre a concepção de gênero e suas consequências no PLN.
- Gerar e analisar um conjunto de histórias produzidas pelos modelos GPT-3.5 e Gemini, utilizando prompts padronizados dentro do tema da tecnologia.
- Treinar modelos de PLN pré-treinados, como XLNet, BERT e DistilBERT, para inferir o gênero referido no texto e analisar a tendência estereotípica ou anti-estereotípica, utilizando bases de dados específicas. Esses modelos foram empregados como ferramenta para a investigação de vieses.
- Analisar os resultados obtidos e as implicações de vieses de gênero em cima disso.

1.3 ORGANIZAÇÃO DO DOCUMENTO

A fundamentação bibliográfica é dividida em duas seções principais que se dividem em seções menores quando é necessário para facilitar o entendimento do tema. Primeiro, é discutido em termos técnicos sobre o funcionamento de modelos de PLN, apresentando conceitos e técnicas muito utilizados nesse processo. Dentro desse tema, ainda são apresentados os modelos pré-treinados utilizados para essa pesquisa, como também o GPT e Gemini que fazem parte do alvo de estudo. Após essa contextualização mais técnica, são apresentadas as bases de dados utilizadas para treinamento dos modelos pré-apresentados, fazendo uma breve contextualização de sua estrutura e origem de desenvolvimento.

Por fim, nessa seção de revisão bibliográfica, é discutido sobre a intersecção de vieses de gênero com PLN de uma forma ampla, primeiramente contextualizando as fontes de vieses e como eles podem se manifestar. Depois é discutida a concepção de gênero a partir de Butler e as implicações de binaridade no PLN, apresentado como ideologias de gênero influenciam os dados usados no treinamento de modelos, contextualizado como o gênero é entendido pela linguagem, as métricas definidas para

medir vieses de gênero no PLN e, concluindo o tópico como também a fundamentação bibliográfica, exemplos de modelos enviesados.

Após a revisão literária, é explicada a metodologia, na qual descrevem os processos realizados para cumprir os objetivos específicos. Isso inclui a geração das bases de dados de estudos, o treinamento dos modelos e a aplicação dos modelos em cima desses dados. Após a aplicação, são levantadas a apresentação e discussão desses resultados.

Concluindo, tem-se as considerações finais abordando a conclusão desta pesquisa e sugestões para trabalhos futuros.

2 PLN E VIESES DE GÊNERO

2.1 PLN EM TERMOS TÉCNICOS

2.1.1 Entendendo como funcionam modelos de PLN

Modelos de PLN lidam com tudo que está relacionado com linguagem. O termo PLN em si é um termo guarda-chuva que abriga todas as possibilidades relacionadas à capacidade da máquina reconhecer, interpretar e gerar linguagem. Para isso, é preciso antes compreender a linguagem em toda sua complexidade em semântica, sintaxe, regras gramaticais e variações.

O campo específico responsável por isso dentro da PLN é Compreensão de Linguagem Natural (CLN), que é mais conhecido pelo termo em inglês *NLU*, que se refere a *Natural Language Understanding* (MANNING; SCHÜTZE, 1999). Esse campo é essencial para que o modelo consiga compreender as linguagens em sua totalidade, num processo que para o ser humano é muito fluído, mas que deve ser convertido para o que é compreensível para máquinas. Outro campo paralelo ao CLN é o de Geração de Linguagem Natural (GLN), que esse é o responsável por atribuir sua capacidade de gerar respostas (CUSTÓDIO, 2024).


As duas andam lado a lado para compôr um modelo completo capaz de compreender a linguagem como também de criar por conta própria artefatos linguísticos de forma que mais se assemelhe a um ser humano. Não é por tanto que esse é o objetivo de IAs (Inteligências Artificiais) como propôs Alan Turing no Teste de Turing, conhecido também por Jogo da Imitação (1950) ¹, o qual verificaria se a máquina é capaz de se assemelhar ao pensamento humano e ser confundida com um. Para atingir tal propósito, o PLN utiliza a Aprendizagem Profunda (Deep Learning), uma subárea da Aprendizagem de Máquina (Machine Learning), o campo das IAs, para suprir as necessidades e dificuldades provindas da sua complexidade. A Aprendizagem Profunda se baseia no uso de redes neurais que simulam a função dos neurônios no sistema nervoso central humano (LECUN et al., 2015).

Entre as técnicas mais conhecidas de PLN, é importante discutir sobre tokenização (*tokenization*) e normalização (*normalization*), ambas técnicas realizadas no pré-processamento dos dados. A tokenização é o processo de quebrar o texto em sequências menores, demarcadas por delimitadores como espaços em branco, vírgula e pontos, conforme apresentado na Figura 1. Assim, através desse processo, é

¹ <https://courses.cs.umbc.edu/471/papers/turing.pdf>

possível descartar delimitadores desnecessários, separando a sentença em fragmentos menores. Ao mesmo tempo que os delimitadores são importantes para o contexto, como para denunciar que a sentença acabou ou em números decimais (ARANHA, 2007). No geral, é um processo indispensável no PLN para auxiliar a compreensão do modelo.

Figura 1 – Exemplo de tokenização



Fonte: Elaborada pela autora (2024)

Após a fragmentação, tem-se a normalização (ARANHA, 2007). A normalização é um processo de agrupar vários conceitos e representações num só que represente um todo, ou melhor, é o processo de padronizar as palavras, como o próprio nome já induz a interpretação. Ao agrupar as palavras para representar um todo, não se está atribuindo o mesmo significado a cada variação, mas sim lidando com um alto grau de redundância. Isso significa que, ao criar grupos de palavras para representar um conceito ou um conjunto de informações, reconhece-se que há muitas palavras diferentes que transmitem a mesma ideia, resultando em uma repetição significativa (ou redundância) nas variações das palavras. Essa é a técnica que torna possível que o *sensitive case* não seja um problema já que uma palavra que tenha sua primeira letra maiúscula não seria diferenciada da que é totalmente minúscula.

O processo de normalização pode ser de vários tipos, as principais sendo: lematização (*lemmatization*) e radicalização (*stemming*) (ARANHA, 2007). Essas duas vão reduzir as palavras para uma versão simplificada, mas a principal diferença é que enquanto a lematização resulta numa palavra existente no dicionário, a radicalização não (ALVES, 2021).

A lematização é centrada na derivação das palavras para uma versão mais simplificada, como foi apresentado anteriormente, retirando todas as inflexões e variações. As palavras "correndo" e "correria" resultariam, no final da lematização, a mesma palavra: "correr". Esse processo facilita a compreensão simplificando as palavras para um contexto mais simples. Já a radicalização é o processo de derivar a palavra até o seu radical. As palavras usadas como exemplo nesse parágrafo se transformariam no radical "corr". Por outro lado, essa simplificação excessiva pode levar a perda de significado, por exemplo, quando duas palavras com significados diferentes resultam no mesmo radical (ALVES, 2021).

Essas etapas presentes no pré-processamento dos dados são essenciais para compreensão da linguagem humana para modelos de PLN, o que leva ao treinamento do modelo numa base de dados para assim obter o resultado esperado. Em resumo: considerem que para um modelo aprender a extrair nomes de um texto, ele antes teria que entender a linguagem, para só depois ser capaz de realizar essa atividade específica que envolve o entendimento de linguagem. Por isso, o desenvolvimento de um modelo de PLN envolve esse preparo antes de lhe atribuir conhecimento para realizar a atividade requisitada. Essa passagem de conhecimento é feita a partir do treinamento em um conjunto de dados que lhe dê direcionamento do que se espera de resultado.

Pensando no escopo dessa pesquisa, é feito uso de modelos pré-treinados, ou seja, eles já possuem uma base sólida de conhecimentos sobre a linguagem humana, e é necessário apenas treinar esses modelos nas bases selecionadas para que realize o objetivo delimitado. Isso é uma forma de dispensar a etapa de aprendizagem inicial, na qual o modelo ainda estaria aprendendo a linguagem, e focar apenas na finalidade esperada. Isso é possível por sua capacidade de Aprendizado por Transferência (*Transfer learning*), que é reutilizar o conhecimento aprendido para aumentar o desempenho em uma tarefa correlacionada (PAN; YANG, 2010).

Esse Aprendizado por Transferência é resultado do *finetuning*, ou ajuste fino, já que é a partir desse ajuste de parâmetros que o modelo é adaptado para outros usos. Essa é uma das características que tornaram os modelos de PLN lançados nos últimos anos mais poderosos que os anteriores (BERGMANN, 2024).

Entre os diversos modelos pré-treinados disponíveis na internet atualmente, os escolhidos para serem usados nessa pesquisa são: BERT (DEVLIN et al., 2019), DistilBERT (SANH et al., 2020) e XLNet (YANG et al., 2020). Esses modelos são baseados em Transformadores ², os quais são uma arquitetura de Aprendizagem Profunda avan-

² <https://arxiv.org/abs/1706.03762>

çada, modificando uma sequência de entrada em uma de saída, analisando o contexto e as relações entre cada elemento da sequência. É esse potencial de prever a próxima sequência de uma palavra num texto que faz com que os modelos compreendam o contexto como um todo.

2.1.2 BERT, DistilBERT e XLNet

O BERT (*Bidirectional Encoder Representations from Transformers*), proposto por (DEVLIN et al., 2019) (pesquisadores do Google), é projetado para pré-treinar representações linguísticas de forma bidirecional e profunda. Ou seja, ele considera o contexto de uma palavra olhando tanto para as palavras que vêm antes quanto para as que vêm depois dela, em todas as camadas da rede neural .

Uma analogia que ajuda a entender a diferença entre modelos unidirecionais e bidirecionais é considerando a montagem de um quebra-cabeça. Quando se pensa na abordagem de um modelo unidirecional, a montagem do quebra-cabeça é feita olhando apenas para as peças que já foram encaixadas, sem poder ver as peças que ainda faltam. Dessa forma, pode acabar demorando mais para encontrar as conexões certas porque só tem uma visão parcial do que está fazendo. Por outro lado, considerando a abordagem de um modelo bidirecional, o resultado é completamente diferente. Pode-se olhar todas as peças que estão na mesa, tanto as que já estão encaixadas quanto as que ainda estão soltas. Com essa visão completa, é possível identificar as conexões muito mais rapidamente e montar o quebra-cabeça de forma mais eficiente.

Essa abordagem bidirecional utilizada pelo BERT permite que o modelo compreenda melhor o significado das palavras em diferentes contextos. Isso ocorre porque considera não somente o contexto prévio, mas também o contexto posterior.

Ao ser lançado, em 2018, BERT era o primeiro modelo de representação baseado em *finetuning* que alcançava desempenho mais avançado e eficaz em uma grande variedade de tarefas (DEVLIN et al., 2019).

Em comparação ao BERT, o DistilBERT é apresentado como uma alternativa mais rápida, leve, pequena e melhor em relação ao BERT. Essa versão destilada mostrou que é possível reduzir o tamanho de um modelo BERT em até 40% enquanto mantém 97% da sua acurácia e é 60% mais rápido. Além disso, ele possui um método combativo contra vieses indutivos que são enraizados em modelos de PLN. Por isso, ele reduz o tempo de treinamento para aprendizagem do modelo, removendo algumas camadas (que fazem parte da estrutura das redes neurais responsáveis por processar os dados e fazer as correlações e identificações de padrões) que não afetam o

desempenho (SANH et al., 2020).

Isso é feito a partir de um processo chamado de destilação, na qual se tem um modelo professor (que nesse caso é o BERT) e se tem um modelo aluno (o DistilBERT), enquanto, nesse caso, utiliza uma técnica de perda na taxa de aprendizagem. Vale lembrar que, por ser uma versão destilada de um modelo, é consequente que ele não somente reproduza os vieses do modelo do qual se origina, mas também se misture com seus próprios vieses. Mas no geral, é uma boa alternativa caso se deseje um tempo menor de treinamento de um modelo, enquanto é equivalente ao BERT em termos de resultados, por exemplo (SANH et al., 2020).

Por fim, tem-se o XLNet (*Generalized Autoregressive Pretraining for Language Understanding*), proposto por (YANG et al., 2020). Esse modelo é mais complexo quando comparado aos modelos anteriores, pois é necessário apresentar mais alguns conceitos para compreender seu funcionamento.

Em termos técnicos, XLNet é um método de pré-treinamento autorregressivo generalizado que utiliza um objetivo de modelagem de linguagem permutada. Esse método combina as vantagens dos modelos autorregressivos e autocodificadores.

Quebrando esse contexto em partes menores, um modelo autorregressivo é aquele que usa técnicas matemáticas da estatística para prever, em uma série temporal (ou seja, um conjunto de variáveis que, nesse caso, seriam os dados de treinamento), qual seria o próximo valor. Assim, são utilizados métodos de correlações probabilísticas.

Quando se fala de um modelo autocodificador, refere-se a uma abordagem de aprendizagem não supervisionada. Nesse caso, o modelo aprende a partir dos dados informados no treinamento sem uma amostra do que é esperado como saída. Na prática, essa abordagem funciona mais como uma técnica auto-supervisionada, contendo em sua rede neural dois mecanismos: uma parte codificadora, que codifica a entrada, e uma parte decodificadora, que reconstrói a representação do espaço que ficou faltando na entrada (ESTEVES, 2020).

Assim, ele aprende e extrai representações (que são as codificações) para a correlação e formação de padrões. Esses modelos autocodificadores foram inovadores para o campo da Aprendizagem não supervisionada para a aprendizagem de representações sem a necessidade de rótulos bem definidos. Quando se soma esses dois métodos, obtém-se uma arquitetura neural projetada para funcionar com o objetivo autorregressivo, incluindo a integração do *Transformer-XL* e como também o mecanismo de atenção bidirecional.

Portanto, o modelo autocodificador alcança uma melhoria significativa em relação aos objetivos de pré-treinamento anteriores em várias tarefas. Ele foi escolhido inicialmente como o modelo que seria utilizado justamente por essa melhora, tendo um melhor desempenho e acurácia comparados a outros modelos baseados em transformadores, com resultados melhores em 20 tarefas comparadas ao BERT (YANG et al., 2020).

Quando comparados os três na tarefa de Reconhecimento de emoções, por exemplo, o XLNet, BERT e DistilBERT obtiveram as acurácias 0,7299, 0,7009 e 0,6693 respectivamente. Nesse caso de estudo, o XLNet teve a maior taxa de acurácia em comparação aos dois, ao contrário do DistilBERT que possuiu a menor acurácia (ACHEAMPONG et al., 2020). Para essa pesquisa, foram escolhidos esses modelos pensando nos recursos computacionais disponíveis (que no caso é um notebook com 20GB de RAM e um processador Intel 7 da última geração) como também pela acurácia dos modelos em si, parecendo uma ideia bastante promissora.

2.1.3 GPT e Gemini

Como visto anteriormente, enquanto o BERT, DistilBERT e XLNet são os modelos treinados como ferramenta de auxílio, o GPT e Gemini são os modelos que foram investigados com sua ajuda. Ambos são modelos generativos, capazes de gerar novos dados como também de aprender e validar esses dados. São IAs poderosas. Habilidade para gerar textos, imagens, vídeos e áudios. No escopo dessa pesquisa, foram avaliadas essas IAs no âmbito do PLN, ou seja, o que estiver relacionado à sua capacidade de compreensão e geração de linguagem. Por isso, é necessário entender primeiro o que faz esses modelos serem tão famosos atualmente, até mesmo fora da área da tecnologia, alcançando um público leigo sobre esse assunto.

O GPT (*Generative Pre-trained Transformers*) (OPENAI, 2022) é um termo guarda-chuva que se refere à família de produtos da *OpenAI*, surgido em 2018, que já é revolucionário por si só ao usar a arquitetura de transformadores em suas redes neurais, o que aumenta deliberadamente seu desempenho, além de utilizar métodos autodecodificadores e ser unidirecional (RADFORD et al., 2018). O *ChatGPT* é um desses produtos, sendo um *ChatBot* de IA, que se tornou muito popular ao proporcionar às pessoas geração de textos coerentes e bem escritos, como compreensão elevada do texto para interpretação, podendo criar resumos, sintetizar temas e respostas. E principalmente: gerar ideias e histórias. Tarefas que tomariam tempo e criatividade do ser humano se tornaram mais fáceis por esse acesso fácil ao *ChatGPT*, tornando-se uma ferramenta de verdadeira ajuda para várias atividades e finalidades.

O Gemini (PICHAI, 2023), por outro lado, conhecido também pelo seu nome antigo "Bard", é produto dos próprios pesquisadores do Google. O Gemini também é um modelo baseado em transformadores e autodecodificadores, funcionando similarmente ao GPT. Em dezembro de 2023, o Gemini (Ultra) prometia ser aproximadamente 4% melhor que o GPT-4 em interpretação e geração de respostas de 57 combinações de assuntos diferentes, superando em aproximadamente 93% outros modelos de PLN em testes padrões de referência. O Gemini Pro, em comparação ao GPT-4, é muito mais rápido em tradução de línguas, por exemplo, mas a qualidade da tradução é inferior. Em média, ele tende a ser mais rápido.

Quando se fala de interpretação e compreensão, para tarefas de perguntas e respostas e resumos, Gemini Pro também tem um desempenho melhor comparado ao GPT-3.5. Sobre geração de conteúdo, o Gemini Pro pode gerar conteúdo tendencioso aos interesses do Google (II, 2023). Quando se fala dessas variações de GPT e Gemini, refere-se a versões diferentes do próprio modelo que variam em desempenho, tempo de resposta e conjunto de atividades proporcionadas. Nessa pesquisa, por exemplo, será avaliada a versão 3.5 do GPT, a mesma do *ChatBot*, e o Gemini Pro.

Os modelos do GPT e do Gemini podem ser acessados via interface de aplicativo, em formato de *ChatBot*, ou pelas próprias APIs. Enquanto o modelo Gemini Pro via API é gratuito, para ter acesso à API do GPT-3.5 é necessário pagar uma taxa a partir do uso de *tokens*. Esse termo deve ser familiar nesse contexto, já que o conceito de tokenização foi apresentado nessa seção. Assim, para 1000 *tokens* de *input* (entrada), a taxa é de 0.00150 dólares, já para 1000 *tokens* de *output* (saída), o valor é de 0.00300 dólares. No caso dessa pesquisa, foi pago o valor de 5 dólares.

O acesso a essas APIs é bastante simples, com poucas linhas de código, precisando apenas da chave obtida na hora de cadastrar sua aplicação na interface e do modelo desejado, o resto é padronizado. A seguir no Algoritmo 1, tem uma amostra de uma requisição feita para a API do GPT-3.5 utilizando a linguagem *python*. Nele, especifica-se o modelo utilizado, como também se especifica o papel que o modelo deve interpretar. É utilizada a abordagem de *chat*.

Por sua vez, o Algoritmo 2 tem uma amostra de uma requisição para a API do Gemini utilizando *python*. Nela, começa-se um *chat* com histórico vazio, enviando o *prompt* desejado.

Algoritmo 1 – Como fazer uma requisição para a API do GPT

```

1  completion = client.chat.completions.create(
2      model="gpt-3.5-turbo",
3      messages=[
4          {"role": "system", "content": "Você é um escritor criativo
           e inteligente, tendo muito conhecimento sobre a área de
           tecnologia."},
5          {"role": "user", "content": string}
6      ]
7  )

```

Fonte: Elaborada pela autora (2024)

Algoritmo 2 – Como fazer uma requisição para a API do Gemini

```

1  chat = model.start_chat(history=[])
2  response = chat.send_message(prompt)

```

Fonte: Elaborada pela autora (2024)

2.1.4 Conhecendo as bases de dados

Conhecendo os modelos que foram utilizados, agora se pode falar das bases de dados que foram usadas para seu treinamento a fim de obter modelos capazes de desempenhar os papéis esperados. Para isso, foram utilizadas as seguintes bases de dados: a *md_gender_bias* e *StereoSet*. Por isso, nessa seção, será estudado um pouco sobre elas.

A base de dados MGB é um produto da pesquisa “Multi-Dimensional Gender Bias Classification” (NEMANI et al., 2024). Essa base de dados tem várias configurações, que variam entre dados que foram obtidos por inferência de anotadores e os outros dados que foram obtidos a partir de outros modelos de PLN, esses que rotulam o gênero temático do texto. Dentre as configurações disponíveis, ou seja, a forma como os dados são dispostos e estruturados, a escolhida para essa pesquisa foi a *open-subtitles_inferred*, que é baseada numa base de dados disponível de várias legendas de filmes e TV (LISON; TIEDEMANN, 2016), selecionando apenas as legendas que continham o nome ou identidade de um personagem. Além do mais, essa configuração contém 442 mil tuplas (sendo 351 mil tuplas para treino, 49 mil tuplas para teste e 42 mil tuplas para validação). A anotação desses dados foi feita da seguinte forma:

Eles anotaram o gênero do personagem usando termos de parentesco de gênero, como filha, e distribuição de probabilidade de gênero calculada pela contagem de nomes femininos e masculinos de bebês nos

Estados Unidos. Usando o gênero do personagem, eles produziram rótulos para a dimensão *AS* (como). Eles produziram os rótulos para a dimensão *TO* (para) pegando o gênero do próximo personagem a falar, se tiver outra fala na conversa; senão, eles pegam o gênero do último personagem a falar. Eles atribuem o rótulo *ABOUT* (sobre) nessa base de dados usando um classificador treinado nos datasets 1-4. (DINAN et al., 2020, p.328, Tradução Nossa)

Esses anotadores são todos trabalhadores da *Amazon Mechanical Turk*, falantes da língua inglesa e estão localizados nos Estados Unidos. O gênero desses anotadores pode ser observado de acordo com a Figura 2.

Figura 2 – Gênero dos anotadores da MGB

Reported Gender	Percent of Total
Man	67.38
Woman	18.34
Non-binary	0.21
Prefer not to say	14.07

Fonte: (DINAN et al., 2020)

Como pôde ser visto, a discrepância entre o percentual de anotadores do gênero masculino para o restante é uma questão importante a ser destacada. Essa majoritária presença masculina é um fator que pode ter contribuído para gerar uma base de dados enviesada, o que levaria à geração de um classificador de vieses enviesado, o que por si só é contraditório. Outra questão preocupante é a escolha de utilizar os nomes como indicadores de gênero, já que o nome de alguém não está diretamente relacionado ao seu gênero, como ainda é considerado popularmente entre os conservadores, ainda mais usando uma abordagem de contagem binária. Mas é uma forma considerável pensando nas limitações em todo esse processo de classificação de gênero. Por sua complexidade, é até mesmo difícil considerar qual abordagem é mais prejudicial que a outra.

Outra característica muito relevante dessa configuração é a existência de uma categorização que foge da binaridade, incluindo a classificação “gender-neutral”. Essa classificação permite que os rótulos ternários fujam da classificação binária de gênero. Por mais que essa terceira categoria possa ser considerada como contraproducente e percebida como prejudicial (DEV et al., 2021), dentre as configurações disponíveis

dessa base de dados, e outras bases de dados conferidas, essa configuração é considerada a melhor para a realização da pesquisa justamente porque outras pesquisas nem mesmo consideram algo que fuja da binaridade.

A sua configuração inclui um campo para rotulação binária, classificando entre 1 e 0, e uma rotulação que envolve o gênero neutro, como foi explicado mais acima. Os rótulos para cada gênero são: 0 para o gênero feminino, 1 para o masculino e 2 para o neutro. Além da rotulação, a estrutura inclui o percentual atribuído a essa rotulação e a frase que foi analisada conforme apresentado no Algoritmo 3.

Algoritmo 3 – Estrutura da configuração da base de dados no formato JSON

```
1 {'binary_label': 1,
2 'binary_score': 0.6521999835968018,
3 'ternary_label': 2,
4 'ternary_score': 0.4496000111103058,
5 'text': "hi , how are you doing ? i'm getting ready to do some
   cheetah chasing to stay in shape ."}

```

Fonte: (DINAN et al., 2020)

Partindo para a base de dados *StereoSet* (NADEEM et al., 2020), ela é um produto da pesquisa “StereoSet: Measuring stereotypical bias in pretrained language models”, contendo um conjunto de dados para estereótipos de raça, profissão, religião e gênero, para avaliar estereótipos em duas modalidades: intra-sentença (dentro de uma única frase) e inter-sentença (que ocorre entre uma ou mais frases). Na sua configuração, cada tupla contém um contexto, o alvo a qual se refere aquele contexto, o âmbito de estereótipo e um trio de frases contendo uma frase estereotipada (label 0), anti-estereotipada (label 1) e uma sem contexto algum relacionado (label 2), como pode ser visto no código 4.

Algoritmo 4 – Estrutura dos dados utilizados na base de dados StereoSet no formato JSON

```

1  {
2    "id": "15af6c4499094469461b56ca10a397e4",
3    "target": "schoolgirl",
4    "bias_type": "gender",
5    "context": "The BLANK schoolgirl gave a recital at her school.",
6    "sentences": {
7      "sentence": [
8        "The green schoolgirl gave a recital at her school.",
9        "The innocent schoolgirl gave a recital at her school.",
10       "The angry schoolgirl gave a recital at her school."
11     ],
12     "id": [
13       "1ae10f8f1b2224156b610a39fcbbc97c",
14       "6b56153532fa360d37c25e918546f571",
15       "554f95f82b71a6865716fec6e60e5992"
16     ],
17     "labels": [
18       {
19         "label": [2, 2, 0, 2, 2],
20         "human_id": [
21           "231ce49f72fb13ff85b9d972cd3b3e4d",
22           "7c0a857e663fecc227a98a190f53be96",
23           "5a017dd813fd6ffd6fbcaf2273ea5ff6",
24           "1e28d436b6661f962052aae87b7d55a7",
25           "1fa6ad7b622d0c7b5d0c5c44f4386bd7"
26         ]
27       },
28       {
29         "label": [1, 1, 2, 1, 3],
30         "human_id": [
31           "231ce49f72fb13ff85b9d972cd3b3e4d",
32           "7c0a857e663fecc227a98a190f53be96",
33           "5a017dd813fd6ffd6fbcaf2273ea5ff6",
34           "1e28d436b6661f962052aae87b7d55a7",
35           "1fa6ad7b622d0c7b5d0c5c44f4386bd7"
36         ]
37       },
38       {
39         "label": [0, 0, 3, 0, 0],
40         "human_id": [
41           "231ce49f72fb13ff85b9d972cd3b3e4d",
42           "7c0a857e663fecc227a98a190f53be96",
43           "5a017dd813fd6ffd6fbcaf2273ea5ff6",
44           "1e28d436b6661f962052aae87b7d55a7",
45           "1fa6ad7b622d0c7b5d0c5c44f4386bd7"
46         ]
47       }
48     ],
49     "gold_label": [2, 1, 0]
50   }
51 }

```

Sobre os vieses contidos nesta base de dados, foram 803 anotadores no processo de inferência na modalidade “inter-sentença” e, mais uma vez, os anotadores eram trabalhadores da *Amazon Mechanical Turk* na qual “cada exemplo era escrito por um anotador e validado por outros 4 anotadores”, totalizando então cinco pessoas para anotação de cada frase (NADEEM et al., 2020). A partir do rotulamento dos anotadores, era selecionado o rótulo mais inferido entre eles para determinar qual rótulo seria o determinante. Importante frisar que os anotadores são todos dos Estados Unidos, por isso os vieses estão relacionados diretamente com a cultura e vivências dessas pessoas nesse país. Da mesma forma que se os anotadores fossem de outros países, os vieses provavelmente seriam completamente diferentes e, assim, o rótulo inferido e os próprios exemplos iriam variar.

Essa base de dados, na verdade, não foi desenvolvida com esse intuito de servir como dados para treinar um modelo classificador e sim mais como dados para testar e validar o estereótipo. Pensando, porém, na estrutura dos dados, ela foi utilizada para essa abordagem de classificador. Por isso, por fugir de sua proposta, possa ser que o resultado obtido não seja completamente coerente.

2.2 ENTENDENDO VIESES E QUAIS SUAS FONTES

Após debater sobre termos mais técnicos em volta do PLN, é necessário voltar para a segunda parte que compõe a problemática: os vieses. De acordo com Friedman e Nissenbaum (1996), o viés pode ser classificado de três formas: Pré-existente, Técnico e Emergente.

O Pré-existente é aquele que está enraizado na sociedade, isto é, nas instituições, crenças e atitudes. Esse tipo de viés pode surgir inconscientemente ou conscientemente, refletindo a visão da sociedade ou do indivíduo (FRIEDMAN; NISSENBAUM, 1996). Por exemplo, considere que um banco decide desenvolver um *software* de aprovação de empréstimos. O gerente do projeto, responsável por definir os critérios para aprovação, tem preconceitos inconscientes contra minorias étnicas. Ele acredita que membros de certas minorias são mais propensos a serem inadimplentes.

Apesar de não expressar esse preconceito abertamente, ele define critérios que, na prática, desfavorecem essas minorias, como exigir uma pontuação de crédito excessivamente alta ou uma história de emprego mais estável, sabendo que essas minorias geralmente enfrentam mais dificuldades socioeconômicas que impactam esses fatores. Como resultado, o *software*, mesmo sem intenção explícita, incorpora o viés do gerente e nega empréstimos desproporcionalmente a membros dessas minorias.

Já o Técnico está relacionado diretamente às restrições técnicas. Ele pode ser produto de uma limitação de hardware ou *software*, de um algoritmo injusto ou da tentativa de tornar construções humanas, como discursos, mais legíveis aos computadores (FRIEDMAN; NISSENBAUM, 1996). Por exemplo, considere que uma universidade desenvolve um algoritmo para alocar vagas de estacionamento para estudantes e funcionários. Esse algoritmo prioriza a alocação de acordo com a ordem alfabética dos sobrenomes dos solicitantes.

Como resultado, pessoas com sobrenomes que começam com letras do início do alfabeto (A-M) têm uma probabilidade significativamente maior de conseguir uma vaga de estacionamento próxima e conveniente, enquanto aqueles com sobrenomes que começam com letras do final do alfabeto (N-Z) têm muito menos chances. Esse viés técnico, decorrente do uso de um critério descontextualizado e aparentemente neutro como a ordem alfabética, cria uma desigualdade sistemática que favorece certos grupos de pessoas com base em um fator arbitrário.

Por fim, enquanto o Pré-existente e o Técnico são possíveis perceber em ambiente de desenvolvimento, o Emergente só surge em ambiente de produção, quando se há o contato do sistema com o usuário. Esse viés surge por mudanças no conhecimento social, na população ou nos valores culturais (FRIEDMAN; NISSENBAUM, 1996). Por exemplo, considere que um portal de serviços públicos online é desenvolvido inicialmente para ser utilizado por uma população urbana com alto nível de alfabetização digital. O *design* do portal incluía uma navegação complexa e instruções detalhadas por escrito, assumindo que os usuários teriam facilidade em seguir textos extensos e realizar várias etapas para completar um processo.

Considerando, porém, que esse portal fosse posteriormente estendido para atender também a populações rurais e de áreas com menor acesso à educação e tecnologia, esses novos usuários, muitas vezes com pouca experiência em informática e baixos níveis de alfabetização, encontrariam grandes dificuldades para utilizar o portal. Isto é, esse grupo que não era compatível com o público alvo proposto inicialmente para o portal foi prejudicado por mais que não tenha sido proposital.

Contextualizando para o PLN, algumas fontes de viés em modelos de acordo com Nemani et al. são: Viés de Dado, Viés de Rotularização e Viés de Modelo (NEMANI et al., 2024). Viés de Dado se refere ao viés que é fruto dos dados usados para treinar o modelo. Os dados selecionados podem carregar vieses tendenciosos a partir do viés do desenvolvedor, apresentando padrões e associações distorcidas, representações limitadas de grupos minoritários e dados desatualizados.

Esses vieses de dados são gerados a partir de vieses cognitivos, dito isso eles se classificam como: Viés de confirmação (aquele que está relacionado a informações que sustentam nossas crenças e atitudes, por exemplo, um chefe achar que mulheres não são aptas para um cargo maior de liderança e assim só oferecer oportunidades do tipo para homens); Viés Histórico (se manifesta quando crenças e preconceitos sistematicamente culturais influenciam decisões, ou seja, manifesta-se nos dados quando é incorreto e não representa a realidade); Viés de Seleção (ocorre quando a amostra da população não representa o grupo alvo completamente ou representa a partir de conceitos distorcidos, destacando-se dois tipos principais: Viés de Amostragem, quando o conjunto de dados não é aleatorizado; Viés de Convergência, quando o conjunto de dados não é coletado de forma que represente corretamente o grupo alvo) (MEHRABI et al., 2022).

Trazendo novamente o exemplo citado anteriormente sobre o ocorrido polêmico da *Amazon*, o enviesamento do modelo é produto fundamentalmente dos dados utilizados para seu treinamento, que apenas vão reproduzir o ambiente majoritário masculino da sociedade. Ou seja, se predomina o Viés Histórico, no qual homens têm mais oportunidades de trabalho na área de tecnologia, e viés de Seleção, no qual não representa o público apto para o trabalho, já que não era um critério a pessoa ser do gênero masculino para ser apto ao trabalho, mas acabou se tornando um critério a partir da amostragem insuficiente. Assim, dependendo da qualidade do conjunto de dados selecionado, pode haver insuficiência de ocorrências para os grupos representados, levando a associações incoerentes por não ter representações insuficientes e a estereotipação. Por isso, essa é a fonte de vieses mais comum e perceptível entre os modelos.

Já o Viés de Rotularização se refere ao processo de anotação de rótulos em cima de um conjunto de dados, realizado por pessoas selecionadas para essa finalidade, as quais injetam seus vieses nos dados de treinamento e validação dos modelos de PLN. No caso, o viés vem da pessoa que realiza o processo de anotação, agravando-se se o conjunto de dados a ser rotulado já é enviesado por si só. Esse é o Viés que foi introduzido nas bases de dados selecionadas para essa pesquisa, por exemplo, já que ambas passaram por esse processo de rotularização.

Viés de Modelo é quando o próprio modelo amplifica e reforça os vieses, sendo conhecido também como superamplificação de viés. Segundo Nemani et al.:

Um fator que contribui para a superamplificação do viés em modelos de linguagem é a escolha do objetivo de perda usado durante o treinamento. Frequentemente, esses objetivos priorizam melhorar a precisão da previsão do modelo, o que pode incentivar o modelo a explorar cor-

relações espúrias ou irregularidades nos dados de treinamento. Como resultado, o modelo pode depender de certas características discriminatórias, como gênero ou raça, para alcançar maior precisão, mesmo que essas características sejam irrelevantes para a tarefa. (NEMANI et al., 2024, p.6, tradução nossa)

Outro fator também que pode introduzir viés é o processo de pré-processamento, no qual é feita a preparação dos dados, como a tokenização, normalização e derivação. O processo de simplificar os dados textuais pode remover características da diversidade linguística, o que levaria ao ato de normalizar todas as formas de uma palavra para uma única forma base, resultando na eliminação de distinções importantes entre dialetos ou variações culturais, alimentando a estigmatização desses grupos e uma representação desproporcionalmente baixa.

No geral, independente da sua fonte, todo o desenvolvimento de um modelo vai estar ligado intrinsecamente aos vieses que o rodeiam: na escolha dos dados, na origem dos dados, no pré-processamento e na finalidade do modelo. Afinal, a partir do momento em que se lida com o que é produto do ser humano, está-se lidando com uma amostragem de suas representações, com os seus vieses, que variam entre vivências e culturas diferentes. Por isso que, para entender como os vieses de gênero surgem e como eles influenciam nos modelos, é necessário entender gênero, já que é a partir disso, de como gênero é interpretado na lente dos vieses que nascem os resultados enviesados.

2.3 GÊNERO NO PLN

Nesta pesquisa, o gênero será analisado em duas dimensões distintas no contexto do *PLN*: como o gênero é compreendido na sociedade e como essa compreensão impacta os modelos de *PLN*, além de como os vieses de gênero se manifestam nesses modelos. Para isso, é essencial definir o conceito de gênero, a fim de entender como uma definição incorreta e imprecisa pode ser um produto da reprodução de vieses, resultando em modelos enviesados.

2.3.1 Butler, concepções de gênero e implicações da binaridade no PLN

Na obra de Judith Butler, “Problemas de gênero: feminismo e subversão da identidade” (BUTLER, 2018), a filósofa pretende discutir sobre a concepção de gênero e da identidade da mulher, partindo do ponto em que ela se refere que o gênero é uma construção social tanto quanto o sexo e a sexualidade, sendo assim eles são produtos de práticas e ações performativas que resultam em significados culturais. Dessa forma, a filósofa conclui que há uma dicotomia entre sexo e gênero, apontando

que o gênero não pode ser simplesmente resumido como uma reflexão cultural de significados de um sexo previamente dado. Nesse contexto, o ponto mais importante que deve ser destacado nesse momento é o seguinte: “as identidades e os sujeitos são fundamentalmente performativos, ou seja, não basta dar-lhes nomes, mas há que atentar também para os atos concretos que lhes dizem respeito, não somente sexuais, mas corporais de modo geral” (FREITAS, 2018, p.232).

A concepção de gênero, como destaca Butler, não pode ser restringida a essa visão que está entrelaçada diretamente com a concepção do sexo biológico, a qual faria com que a construção da sua identidade partisse de uma análise restrita unicamente ao sexo, o que, conseqüentemente, restringiria a construção de sua identidade social. No momento em que se limita o sexo biológico como intrínseco à sua identidade social, está também limitando os próprios conceitos de comportamentos e expressão corporal. A pessoa, dessa forma, estaria limitada a representar somente os conceitos que a concepção do seu sexo na sociedade lhe permitisse. Por isso, “buscar definir uma identidade [...] acaba por ‘aprisionar’ os indivíduos em categorias ontológicas engessadas ao invés de os libertar” (FREITAS, 2018, p.229).

Com o conceito de performatividade, Butler está afirmando que a cultura é capaz de impor práticas entendidas como femininas ou masculinas (HADDAD; HADDAD, 2017, p.8) e isso acaba excluindo as outras formas de expressões corporais que fogem desse conceito heteronormativo e comportamentos impostos. Ao afirmar que gênero é performativo, isso quer dizer que o “gênero não é algo que nós somos, mas que continuamente fazemos, através da repetição das normas de gênero, que se cristalizam, imposto por práticas regulatórias” (HADDAD; HADDAD, 2017, p.3). Sendo assim, a concepção de identidade e de gênero não pode ser restringida e limitada aos conceitos que rodeiam as práticas normalizadas de expressão e comportamentos corporais que a cultura impõe como “feminino” e “masculino”.

Butler argumenta ainda que o próprio sujeito generificado não possui a liberdade voluntarista de escolher suas performances de gênero sem antes passar por um filtro que seria a regulação; essa regulação é a heteronormatividade (heterossexualidade compulsória) que delimita quais são suas escolhas e possibilidades de performance de gênero (BORBA, 2014). Ao trazer isso, a autora está afirmando que os padrões heteronormativos são como uma norma que apresenta como rótulos tudo que se enquadra neles, e que fugir dessa norma, ou seja, conseguir se expressar livremente fora dos padrões em questão de gênero e identidade, é no mínimo complicado. Com isso, “as múltiplas categorizações de gênero projetadas sobre seu corpo são um produto da instabilidade dos significados de nossos signos corporais que, também instavelmente, limitam nossa existência linguística e, por consequência, corpórea”

(BORBA, 2014, p.451).

Esse modelo binário de gênero é apontado como "folk" em pesquisas como a de Keyes, "The Misgendering Machines: Trans/HCI Implications of Automatic Gender Recognition", que seria justamente essa visão imutável, binária e fisiológica de gênero (DEVINNEY et al., 2022), associando gênero com o sexo biológico. Como aponta Devinney et al:

O modelo "folk" apaga a existência de pessoas trans e não binárias. Essa exclusão do que é "aceitável" ou "normal" tem consequências concretas e muitas vezes violentas para pessoas trans, as quais não são vistas tendo um gênero "compreensível" por pessoas e sistemas que elas encontram" (DEVINNEY et al., 2022, p.2, tradução nossa).

As consequências principais do uso de uma IA que segue o modelo "folk" são: "misgendering" e a exclusão. A prática de mau reconhecimento do gênero, termo referido no inglês como "misgendering", é o ato de inferir um gênero que não corresponde ao verdadeiro, ou seja, que não corresponde à identidade de gênero de quem está sendo inferido. E a exclusão se refere a invalidar ou não levar em consideração qualquer outra manifestação que fuja da binaridade (DEV et al., 2021). Essas são as consequências quando se fala em identidades que fogem da binaridade de gênero.

Essas implicações de conceitos de não binaridade de gênero no campo de PLN são frutos tanto das limitações de anotação dos dados, em que as pessoas anotadoras não reconhecem ou valorizam as identidades não binárias, como também da disparidade nas amostras de dados, em que dados de identidades não binárias podem ser descartados ou não representados por não ver necessidade em tais representações, o que alimenta a exclusão e a disseminação de estereótipos (DEV et al., 2021).

É como se as identidades não binárias fossem invisíveis para esses sistemas, incapazes de reconhecer de fato suas identidades e reproduzindo estereótipos. Além de que, muitas vezes, os dados neutros em termos de gênero apresentam um viés semelhante aos dados identificados como masculinos, enquanto os dados identificados como femininos mostram um viés mais acentuado. Isso sugere que os modelos de NLP podem ter dificuldades em compreender e gerar linguagem neutra em termos de gênero, possivelmente devido à sua raridade nos dados de treinamento (SOBHANI et al., 2023).

Um exemplo claro dos danos causados por esses vieses é observado em siste-

mas de tradução automática, especialmente no uso de pronomes. Na pesquisa "What about em? How Commercial Machine Translation Fails to Handle (Neo-)Pronouns", é investigado como sistemas de tradução automática (Machine Translation) lidam com pronomes de terceira pessoa, especialmente neopronomes, que são os pronomes que fogem do binário de gênero, analisando três sistemas comerciais (*Bing*, *DeepL*, *Google Translate*) em seis idiomas. Resultados mostram que pronomes neutros frequentemente resultam em erros gramaticais e semânticos. Modelos como BERT têm melhor desempenho ao identificar "they" como pronome singular neutro, em contraste com modelos mais antigos, que frequentemente interpretam "they" como plural (BAUMLER; RUDINGER, 2022).

Essa problemática não se limita à resolução de correferência. De acordo com (HOSSAIN et al., 2023), ao avaliar modelos de PLN quanto ao uso correto de pronomes neutros e neopronomes, foi observado que os modelos apresentaram baixa precisão para ambos, alcançando apenas 7,6% para neopronomes e 31% para pronomes neutros.

A seguir, será discutido como uma visão heteronormativa de gênero, conforme indicado por Butler, influencia os dados de treinamento em PLN.

2.3.2 Ideologias de gênero heteronormativas nos dados de treinamento

Susan Leavy (LEAVY, 2018), em seu trabalho "Viés de gênero em Inteligências Artificiais: A necessidade por diversidade e teoria de gênero em aprendizagem de máquina", aponta como as ideologias de gênero impostas e refletidas pela norma heteronormativa ainda estão presentes e enraizadas nos dados e assim resultando em modelos que aprendem conceitos estereotipados de gênero. É analisado viés de gênero em cinco circunstâncias diferentes — *Naming*, *Ordering*, *Biased Descriptions*, *Metaphor* e *Presence of Women in Text* —, ressaltando os problemas de ideologia de gênero em cada um, ocasionados por vieses controversos, focando nos rótulos "feminino" e "masculino".

Na categoria *Naming*, Leavy (LEAVY, 2018) analisou como os termos são utilizados para se referir e descrever grupos de homens e mulheres, apontando como os pais são normalmente descritos como "homem de família", ao contrário das mães que são descritas como "mãe solteira", "mãe trabalhadora", "mulher de carreira" ou somente "mãe", mostrando a visão retrógrada da sociedade em torno da mulher que vê o seu papel social como ser mãe e cuidar de seus filhos. Outra manifestação de viés de gênero é como mulheres são mais normalmente descritas como "garotas" do que homens são descritos como "garotos", apontando que 52% das vezes que usaram o

termo “garota” eram para descrever mulheres, ao contrário dos homens que apenas 28% das vezes usadas “garoto” se referiam aos homens (LEAVY, 2018). Além disso:

O termo "garota" também foi usado em contextos mais depreciativos e sexuais. Isso demonstra como técnicas para analisar não apenas a frequência de menções, mas o contexto mais amplo do uso de termos para homens e mulheres em textos, podem detectar viés de gênero em dados de treinamento para aprendizado de máquina. (LEAVY, 2018, p.15, tradução nossa).

Já na categoria *Ordering*, a autora analisa o viés de gênero no ordenamento de itens de uma lista. Ela destaca que “embora tenha havido variações na ordem de nomeação dos pares, o gênero foi o fator de influência mais importante em relação a qual dos pares de termos foi nomeado primeiro” (LEAVY, 2018, p.15, tradução nossa). Na categoria *Biased Descriptions*, foram analisados os adjetivos usados para descrever homens e mulheres nos jornais britânicos, trazendo como resultado que os homens são geralmente mais descritos em torno do seu comportamento, enquanto as mulheres eram mais descritas em torno de sua aparência e sexualidade. Além de que, quando era investigado o contexto em que eram inseridos termos como “garotas”, eram seguidos por adjetivos que as objetificavam, retratando-as em situações negativas (LEAVY, 2018). Do mesmo modo, ao analisar *British national Corpus* e selecionar e comparar qual adjetivo estava se referindo aos homens e mulheres, o resultado revelou uma gama de estereótipos de gênero, principalmente voltados às mulheres, entre esses, os adjetivos listados para elas foram: mandona, fofoqueira, submissa, histérica, chorosa, tagarela e mal-intencionada. Ao contrário dos homens, em que a lista de adjetivos era bem maior e com uma carga mais positiva (LEAVY, 2018).

Por isso, é reforçada mais uma vez a necessidade de uma seleção criteriosa para evitar que, a partir desse treinamento, seja gerado um modelo tendencioso a reproduzir vieses de gênero.

Dito isso, pode-se ver nos casos que Leavy (LEAVY, 2018) apontou amostras de dados que são usados para treinamento dos modelos é produto da visão heteronormativa à qual Butler se refere. Esta mesma visão heteronormativa que conclui como padrão de gênero os rótulos “feminino” e “masculino”, ou ainda mais problemático, que ignora a questão de gênero e foca unicamente no sexo biológico do indivíduo, exclui qualquer outra forma de manifestação de gênero, além de expressar estereótipos e especulações em torno desses próprios rótulos, prejudicando principalmente as pessoas trans. Há uma expectativa da sociedade de que haja uma performatividade de gênero ou do sexo previamente dado, tudo o que parece fugir dessa expectativa não parece

ser reconhecido por esses sistemas, levando à exclusão e ao mal reconhecimento do gênero, agindo por meio de estereótipos do que é esperado para tal.

Ainda mais, os dados disponíveis para desenvolver modelos de PLN são mais como grandes conjuntos misturados de textos que não refletem performances e experiências individuais de gênero, mas assim se tornam apenas a produção de categorias de gênero (DEVINNEY et al., 2022), o que leva a uma insuficiente e opaca representação de gênero comparada a nossa realidade. Além de que, é necessário lembrar o contexto no qual os modelos são desenvolvidos em sua maioria, no qual se inserem homens brancos concentrados nos Estados Unidos. De fato, com um ambiente como esse, prevalecendo apenas uma ideologia desse tipo, não será possível representar minorias nem diversidade.

2.3.3 Gênero linguístico

Após discutir sobre a relação entre gênero e PLN, no sentido de fonte de vieses em dados, é necessário discutir sobre como o gênero é entendido pela linguagem: o gênero linguístico. Se enquadram em gênero linguístico conceitos como: gênero gramatical, gênero referencial, gênero lexical e gênero (bio)-social (CAO; III, 2020; STANCZAK; AUGENSTEIN, 2021).

Gênero gramatical se refere ao conceito de conjuntos de substantivos que estão relacionados a um gênero, tipicamente utilizado para se referir a idiomas. Um exemplo fácil é a língua Portuguesa e Inglesa. Quando se compara como é falado no português, em que se tem muitas referências ao gênero em orações, e como é falado no inglês, é fácil perceber que no português há muito mais indicações e flexões de gênero do que no inglês. A frase "Ela é uma boa aluna" é cheia de referências à gênero (o pronome "ela" vai concordar com todos os adjetivos, substantivos e artigos que se referem a ele), quando no inglês a mesma frase ficaria "She is a good student", no qual a única referência de gênero é indicada pelo pronome, o restante da frase não se modifica para se referenciar a ele. Correlacionado ao gênero gramatical, tem-se o gênero referencial e o gênero lexical.

O gênero referencial (CAO; III, 2020) é justamente essa parte de identificar referências de gênero, que é bastante semelhante a outros termos que eles apresentam em sua obra, sendo gênero conceitual, que é como um gênero é referido, reconhecido e inferido para classificar o gênero do qual se refere. E já o gênero lexical é sobre os conjuntos lexicais que carregam propriedade de gênero, como a dicotomia entre "aluna" e "aluno" para indicar o gênero feminino e masculino respectivamente.

É perceptível que lidar com gênero a partir da vista gramatical será diferente entre linguagens que têm mais flexões de gênero (Português, Espanhol, Francês) do que linguagens que possuem menos flexões de gênero. Isso porque, em linguagens com mais flexões de gênero, abrem-se mais margens para inferência de gênero, já que há mais anotações e indicadores.

2.3.4 Métricas para avaliação de viés de gênero

Já para medir viés de gênero diretamente em modelos de PLN, pode-se ver duas definições usadas para detecção de vieses: seja influenciando a performance em aplicativos ou visivelmente estereotipado. Pensando na performance de aplicativos, são realizados testes de acurácia, F1 score e falsos positivos relacionados a entidades de gênero para que fosse possível perceber a manifestação de vieses justamente por esses resultados exatos: que, quando relacionados a certas entidades de gênero, o desempenho daquele modelo era menor comparado ao desempenho de outras entidades (STANCZAK; AUGENSTEIN, 2021).

Mas não somente analisar o desempenho, e sim, observar como o modelo se relaciona com diferentes entidades de gênero para podermos analisar a reprodução de estereótipos. Pensando nisso, foram desenvolvidos alguns testes que são utilizados em contextos e finalidades distintos que podem ser aplicados em modelos baseados em transformadores. Entre esses, pode-se citar: *WEAT score*, *Equalized Odds*, *Counterfactual evaluation* e *BLEU Score* (NEMANI et al., 2024).

O *WEAT score* (SILVA et al., 2021) funciona a partir do cálculo do grau de associação entre conjuntos de palavras. Em termos mais técnicos, é a diferença entre as médias das semelhanças de cosseno das palavras nos conjuntos. No contexto de viés de gênero, o *WEAT score* pode ser utilizado para verificar se um modelo está reproduzindo vieses de gênero quando o grau de associação entre palavras generificadas e certos atributos é alto, o que indica que há uma grande associação enviesada entre esses termos.

Nesse trabalho (SILVA et al., 2021), os autores apontam que o processo de tokenização tem uma grande influência na equitatividade dos resultados em modelos PLN. Por exemplo, os modelos de PLN treinados em bases *uncased* (no qual não importa se os caracteres das palavras estão em maiúsculo ou não) possuem menos vieses e mais diversidade de palavras e pronomes. Ainda mais, os modelos destilados costumam ter efeitos dos vieses ainda mais fortes comparados aos modelos dos quais foram extraídos, como é o caso do DistilBERT.

As suas principais limitações são que um conjunto limitado de palavras não é o suficiente para abranger todas as gamas de associações "generificadas" e também há uma falta de informação contextual e subjetividade das definições de atributos (NEMANI et al., 2024).

O próximo é o *Equalized Odds*, o qual é uma métrica que avalia se as previsões de um modelo são consistentes entre diferentes grupos demográficos. Isso é feito a partir da comparação entre previsões verdadeiras positivas (em inglês, *TPRs*) e previsões falsas positivas (em inglês, *FPRs*). Como no caso da investigação de vieses de gênero, a comparação é realizada entre os resultados das previsões referindo-se a inputs de dados distintos de gênero.

Assim, é calculada a diferença absoluta entre os casos de *TPRs* entre dados do gênero masculino e feminino, a mesma coisa para os casos de *FPRs*. Uma previsão é considerada verdadeira positiva, como indica seu nome, quando o resultado previsto é rotulado como positivo de forma correta, já quando é falsa positiva, o resultado é rotulado como positivo de forma incorreta, ou seja, incongruente. Quando um modelo indica valores menores obtidos por esses cálculos, quer dizer que o modelo está prevendo igualmente entre os casos generificados, independente do gênero. Sua principal limitação é por sua binaridade: os testes são feitos apenas em conjuntos de dados classificados binariamente em relação a gênero, excluindo todas as outras manifestações de identidades de gênero (SILVA et al., 2021).

Em seguida, tem-se *Counterfactual evaluation* (PEARL, 2009), o qual é uma técnica que utiliza a troca de gênero para avaliar qual a performance que é obtida em consequência dessa troca. Para avaliar essa performance com as palavras substituídas por outro gênero, são calculados novos testes de acurácia para só assim fazer a comparação entre os resultados obtidos. O cálculo do grau dessa métrica é feito a partir da diferença entre a acurácia dos dados com o gênero original e a acurácia dos dados com o gênero substituto. Dessa forma, é possível perceber se há vieses de gênero influenciando na performance do modelo relacionado a algum gênero ou identidade de gênero; assim, um valor positivo indica que o modelo é enviesado ao gênero original, um valor negativo é enviesado ao gênero oposto. Sua limitação já foi vista anteriormente, que é a questão da binaridade de gênero: essa técnica apenas avalia na visão dos rótulos masculinos e femininos (SILVA et al., 2021).

Por fim, entre os métodos utilizados para investigar vieses de gênero em modelos baseados em transformadores, tem-se o *BLEU score*, que se baseia em usar versões de frases com os gêneros trocados como dados de entrada e comparar o quão parecidos são os resultados do modelo com as frases originais. Assim, para se

investigar viés de gênero usando essa métrica, é calculada e comparada a média das pontuações para frases com gêneros trocados, masculino e feminino. Se o modelo consistentemente gerar pontuações *BLEU* mais altas para frases com gênero masculino trocado do que para frases com gênero feminino trocado, isso indica um viés em favor da linguagem masculina.

Por outro lado, se o modelo consistentemente gerar pontuações *BLEU* mais altas para frases com gênero feminino trocado do que para frases com gênero masculino trocado, isso indica um viés em favor da linguagem feminina. A sua principal desvantagem é por medir a sobreposição lexical entre as traduções geradas e as traduções de referência, ou seja, ele não captura aspectos contextuais ou semânticos, tratando todas as palavras e frases igualmente. Essa desvantagem é consequência do seu uso para investigação de vieses de gênero, já que ela é inicialmente pensada para avaliar a performance de modelos de tradução de linguagens (SILVA et al., 2021).

Agora em modelos neurais, outro método que foi utilizado para detecção de vieses de gênero é a medição causal. Nela, é investigado como a informação é transmitida dos dados de entrada para a saída através dos diversos componentes do modelo (VIG et al., 2020b). É um método bastante eficaz para entender como o modelo utiliza as informações para realizar as previsões, já que é possível ir isolando as variáveis contidas entre esse caminho em que os dados são recebidos e é retornado o resultado. O escopo completo desse método não interessa a essa pesquisa por sua complexidade envolvendo as redes neurais, mas além de ter confirmado o que já se entendia anteriormente (por exemplo, no processo de treinamento que os vieses de gênero surgem e que em modelos maiores os efeitos de vieses de gênero são aumentados), também foi observada outra questão em relação ao gênero neutro.

Investigamos adicionalmente o efeito de uma intervenção neutra em termos de gênero, na qual escolhemos "person" como alvo da mudança de gênero estabelecida e medimos a probabilidade de continuidade com "they". Note que, infelizmente, todos os exemplos podem ser vistos como tendenciosos contra a neutralidade de gênero, já que os modelos tiveram exposição limitada ao "they" singular. Além disso, esse caso sofre com o fator de confusão adicional de que o modelo poderia atribuir probabilidade ao "they" plural se não se referir à profissão. (VIG et al., 2020a, p.4, Tradução Nossa)

Pode-se concluir, mais uma vez, como há uma dificuldade nesses modelos em lidar com gênero neutro, o que reflete a carência no processo de treinamento e falta de representatividade, já que se um modelo não reconhece "they" no singular, como é utilizado em inflexões de gênero neutros no Inglês, é apenas a reprodução da invalidação e exclusão do uso do gênero neutro na linguagem. Além de não somente


isso, mas foi possível observar um padrão entre esses métodos que é por sua limitação em trabalhar com a binaridade de rótulos de gênero, o que contribui para agravar os efeitos de invalidação das identidades de gênero que não se enquadram nesse rótulo.

Por fim, nessa seção foi possível ser discutidas abordagens para verificar a presença de vieses de gênero em modelos de PLN, mas em sua maior parte, ao que se refere a *Word Embeddings*, que é uma técnica de representação de palavras em forma vetorial. Quando se fala de modelos gerativos, como é o caso dessa pesquisa, essas abordagens se tornam mais complexas de serem aplicadas por seu contexto ser muito simples comparado a modelos completos treinados para finalidades específicas. É pensando nisso que essa pesquisa irá partir de um ponto mais abstrato e substantivo, usando de minha análise para concluir a reprodução de vieses enquanto são utilizados os modelos de PLN como ferramenta de auxílio. Na próxima seção, foram apresentados exemplos concretos de reprodução de vieses de gênero em modelos de PLN que serviram de inspiração para o desenvolvimento da metodologia dessa pesquisa.

3 METODOLOGIA

Esse trabalho é composto por uma revisão bibliográfica, tendo como método o levantamento de registros de pesquisas desenvolvidas anteriormente por outros autores e pesquisadores, e uma pesquisa exploratória de levantamento para estudo dos dados, ver Figura 3.

Figura 3 – Metodologia utilizada



Fonte: Elaborada pela autora (2024)

Inicialmente, o instrumento para coleta de dados tratou-se de um levantamento bibliográfico. Foi utilizado o método de pesquisa descritiva de tipo básica, através da leitura e fichamento de textos em revistas, artigos, periódicos, meios eletrônicos, dentre outros que oferecem subsídios para o enriquecimento desta pesquisa. Isso com a finalidade de entender como funciona um algoritmo de PLN, termos e técnicas mais importantes, e estudar quais os tipos de fontes de vieses e como eles podem se manifestar em modelos de PLN, focando principalmente em vieses de gênero, em que é realizada a contextualização sobre a concepção de gênero.

Os procedimentos metodológicos adotados para a pesquisa bibliográfica foram: a elaboração do tema, pesquisa de literatura e análise crítica dos materiais pesquisados. Os artigos e materiais em geral selecionados seguiram critérios disponíveis na íntegra e de forma gratuita, trabalhos nacionais e estrangeiros e pesquisas publicadas nas últimas duas décadas, sendo assim, conteúdos recentes que possuem a necessidade de serem discutidos.

Já para estudar a reprodução de vieses de forma prática em modelos de PLN, como as IAs de geração de texto, GPT e Gemini, realizou-se uma pesquisa de levantamento de caráter qualitativa e quantitativa, de natureza exploratória. Foram desenvolvidos modelos de PLN capazes de inferir qual o gênero o texto está se referindo para identificar possíveis vieses de gênero nos modelos que o geraram e no próprio modelo que está fazendo a inferência. Foram treinados três modelos pré-treinados disponíveis para uso: BERT, DistilBERT e XLNet. Para treinar esses modelos, foram utilizadas a base de dados MGB e *StereoSet*.

Inicialmente, para as bases de dados geradas para estudo, foi necessário elaborar os 12 *prompts* (instruções) que seriam utilizados para gerar histórias com temática voltada para desenvolvimento de tecnologia, como “desenvolvimento de front-end”, e depois foram realizadas as solicitações para as APIs do GPT-3.5 e Gemini. A ausência de indicações de gênero no prompt deixa a definição a cargo da IA, permitindo analisar os vieses de gênero associados às suas interpretações em cada contexto. A lista de instruções utilizadas está listada no Apêndice A. As áreas tecnológicas foram selecionadas com base em sua repercussão social e domínio teórico-prático recorrentes no debate público.

Para testar a viabilidade da ideia, inicialmente foram geradas duas bases de dados em inglês, cada uma contendo 10 tuplas por instrução. Após a confirmação da viabilidade, foram criadas as bases de dados definitivas, com 100 tuplas por instrução. As histórias variam de um a dois parágrafos, ver Apêndices B e C que representam exemplos de histórias geradas pelo GPT-3.5 e Gemini, respectivamente.

Posterior a isso, foram inicializados os processos de treinamento na base de dados MGB. Após a primeira fase de treinamento do XLNet, foi obtida uma acurácia de 85% com os dados de validação, que levou um total de 262 horas para finalizar sua execução. Para isso, foi usada uma taxa de aprendizado de $2e-5$, um tamanho de lote de 16, época de treinamento de 2 e o decaimento de peso de 0.01. Já para o treinamento do DistilBERT, utilizando a mesma configuração, foi obtida uma acurácia de 87% em 98 horas de execução. Por fim, concluindo os treinamentos, o modelo treinado no BERT durou 64 horas, tendo a maior acurácia entre eles: 89%. O modelo específico

usado do XINet é o "xlnet-base-cased", o do DistilBERT é "distilbert-base-uncased" e o do BERT é o "bert-base-uncased". Esses valores de hiperparâmetros foram usados baseados na própria documentação da *HuggingFace* no contexto de treinamento dos modelos na tarefa de *Text Classification*¹, como pode ser visto no Algoritmo 5.

Algoritmo 5 – Como foi feito o treinamento dos modelos e seus hiper parâmetros

```

1  training_args = TrainingArguments(
2      output_dir="mdgenderbias_bert",
3      learning_rate=2e-5,
4      per_device_train_batch_size=16,
5      per_device_eval_batch_size=16,
6      num_train_epochs=2,
7      weight_decay=0.01,
8      evaluation_strategy="epoch",
9      save_strategy="epoch",
10     load_best_model_at_end=True
11 )
12
13 trainer = Trainer(
14     model=model,
15     args=training_args,
16     train_dataset=tokenized_datasetTrain,
17     eval_dataset=tokenized_datasetTest,
18     tokenizer=tokenizer,
19     data_collator=data_collator,
20     compute_metrics=compute_metrics,
21 )
22
23 trainer.train()
```

Fonte: Elaborada pela autora (2024)

Para treinamento na base de dados *StereoSet*, foi feito um processamento na base de dados para que melhor cumprisse a funcionalidade proposta, utilizando apenas a amostra de dados na modalidade inter-sentença e no âmbito de gênero. As duas colunas mais importantes da base de dados são: *bias_type*, que se refere ao tipo do viés, e *sentences*, que é o trio de frases relacionadas a um determinado contexto, contendo o rótulo indicado por cada um dos anotadores a cada frase. Depois de selecionar a fragmentação da base que se referiam unicamente a intra-sentença, foram selecionadas as que se referiam aos estereótipos de gênero. Só aí que foi feito um tratamento no trio de frases fragmentando cada frase em uma nova tupla com seu rótulo correspondente. Após a fragmentação, foram descartadas todas as frases nas quais o rótulo se referia à ausência de relação com o contexto. Os rótulos binários correspondem, respectivamente: 0 e 1 a estereótipos e anti-estereótipos.

¹ <https://huggingface.co/docs/transformers/tasks/sequence_classification>

Um problema encontrado na utilização dessa base de dados, principalmente para essa finalidade e depois que a fase de processamento e preparação dos dados foi finalizada, é o tamanho da amostra obtida para treinamento e teste desse modelo. A amostra no final dessa fase contém apenas 437 tuplas, dividindo 70% para treinamento e 30% para teste. É por esse motivo que os dados sobre sua acurácia e o tempo de treinamento foram omitidos.

O problema de ser uma amostra reduzida é que leva ainda mais a um resultado enviesado e ineficaz. Enviesado pois uma amostra enxuta não é o suficiente para explorar profundamente todos os âmbitos possíveis, contendo apenas alguns exemplos propensos a generalizações e/ou exceções por parte deles. E ineficaz pois uma quantidade pequena de dados não é o suficiente para um modelo ser treinado visando a melhor acurácia de suas previsões, já que ele não tem material o suficiente para aprender, tendendo a um resultado enviesado. No fim, os dois estão relacionados. Como apontado anteriormente, o tamanho da amostra de dados está correlacionado com a sua acurácia e desempenho como também aos seus vieses.

É relevante destacar que os modelos treinados funcionam tanto como ferramenta de apoio para a análise de vieses de gênero nos textos quanto como objeto de estudo, uma vez que sua própria construção está sujeita a vieses. Além disso, a pesquisa em si é influenciada por escolhas metodológicas, como a seleção das bases de dados utilizadas no treinamento dos modelos e a abordagem adotada para sua aplicação e análise. A inferência de rótulos de gênero, propósito central do modelo, também carrega um viés inerente, pois o gênero não é uma característica fixa e absoluta que possa ser determinada com total precisão. Dessa forma, o modelo deve ser compreendido exclusivamente como um instrumento para a investigação de vieses de gênero nos textos.

Na aplicação do modelo nessas histórias, foi usada a seguinte abordagem: primeiro, foi dividido cada parágrafo em frases menores. Assim, a acurácia do modelo seria mais precisa em conseguir classificar por ser uma amostra menor, além de que a própria amostra de dados utilizada para seu treinamento era composta de apenas uma frase por tupla, de poucos caracteres. Por isso, é sugerido que a previsão seria mais imprecisa se fosse aplicada aos dois parágrafos de uma vez. Esse processo se repetiu tanto para os modelos treinados na base de dados MGB e na *Stereoset*.

Para a base de dados MGB, depois de inferir o rótulo para cada frase menor, foi calculado qual o rótulo mais inferido no total de frases, para descobrir qual rótulo seria considerado o prevalecente. Inicialmente, foi pensado que se dois rótulos tivessem a mesma quantidade de inferências, o rótulo inferido seria o de gênero neutro. Mas

por mais que essa abordagem tenha sido utilizada, todas as histórias que tiveram incongruência em mais de um rótulo foram descartadas no final do processo. Ademais, é calculada a porcentagem de cada rótulo inferido a cada fragmentação do texto. Esse processo foi repetido para cada modelo treinado, visando verificar diferenças entre os resultados obtidos por modelos diferentes.

Os procedimentos metodológicos adotados para a pesquisa de levantamento foram: A definição da problemática a ser estudada com a pesquisa, delimitação da base de dados (e configuração) que seriam utilizadas, elaboração das instruções, requisições para as APIs do GPT e Gemini para coleta dos dados, treinamento dos modelos com as bases de dados delimitadas inicialmente (com a preparação dos dados quando necessário) e, depois dos testes de validação do modelo treinado, a aplicação desses modelos nas bases de dados geradas pelas IAs gerativas de texto, assim finalizando com a análise dos dados obtidos.

4 RESULTADO E DISCUSSÕES

Os resultados obtidos consistem em 12 *datasets* a serem analisados, além dos dois *datasets* das histórias geradas pelo GPT e Gemini. Esses 12 *datasets* estão divididos em dois grupos: seis correspondem aos resultados das aplicações dos modelos XLNet, DistilBERT e BERT treinados na base de dados *Stereoset* sobre as histórias do GPT e Gemini, enquanto os outros seis representam os resultados das aplicações desses modelos treinados na base de dados MGB.

A estrutura desses dados é composta por um primeiro argumento, que indica a porcentagem atribuída a cada rótulo, e um segundo argumento, que representa o rótulo dominante. Um exemplo de um dos dados obtidos na aplicação dos modelos treinados no *Stereoset* pode ser visto a seguir no Algoritmo 6. Em outras palavras, tem-se um objeto com a porcentagem atribuída ao rótulo 0 (anti-estereótipo) e 1 (estereótipo) e qual o rótulo dominante (que teve a maior atribuição). Já no caso do MGB, os rótulos são 0 (gênero feminino), 1 (gênero masculino) e 2 (gênero neutro), além do gênero dominante.

Algoritmo 6 – Estrutura de dados do resultado dos modelos treinados no Stereoset

```
1 ({'label_0': 42.857142857142854, 'label_1': 57.14285714285714},
  1)
```

Fonte: Elaborada pela autora (2024)

Primeiramente, a discrepância entre os resultados obtidos pelos modelos, mesmo quando treinados com as mesmas bases de dados e hiperparâmetros, é não apenas perceptível, mas também crucial para a análise. No caso específico da base de dados do *Stereoset*, essa diferença se destaca de forma ainda mais evidente nos gráficos referentes ao DistilBERT, especialmente quando comparados aos demais modelos. Um aspecto particularmente intrigante é que todas as histórias rotuladas por ele receberam exclusivamente o "*label_0*", sem exceção.


Esse fato, por si só, já levanta questionamentos, pois, diante da diversidade das 12.000 histórias geradas tanto pelo GPT quanto pelo Gemini, seria esperado que houvesse alguma variação nos rótulos atribuídos. No entanto, o comportamento do DistilBERT destoa completamente, sugerindo um possível viés ou limitação específica do modelo. Quando analisamos esse fenômeno em conjunto com os resultados dos outros modelos, a discrepância torna-se ainda mais evidente, tornando o DistilBERT um ponto fora da curva em relação às demais arquiteturas testadas.

O que pode ter levado a esse comportamento? Não há uma resposta definitiva, uma vez que todos os modelos foram treinados sob as mesmas condições. Entretanto, é possível que a arquitetura do DistilBERT exija ajustes específicos nos hiperparâmetros para alcançar uma acurácia satisfatória nesse tipo de tarefa. Além disso, como não foi possível calcular sua acurácia devido a fatores previamente mencionados, é provável que as mesmas razões que impediram essa métrica tenham influenciado diretamente nesse resultado inesperado.


Diante disso, é inviável continuar incluindo o DistilBERT nas análises relacionadas ao Stereoset, pois sua inconsistência compromete a validade dos resultados. Assim, para evitar distorções, as avaliações futuras irão desconsiderá-lo, reconhecendo que, nesse contexto, sua performance pode ser considerada um fracasso.

Ao analisarmos os gráficos de dispersão de dados (*scatter plot*) com a biblioteca em python SeaBorn que comparam os resultados do GPT e do Gemini, a diferença entre os modelos não se mostra tão extrema. No entanto, algumas tendências relevantes podem ser observadas na Figura 4.


Figura 4 – Gráficos de dispersão dos dados obtidos pela aplicação dos modelos treinados no Stereoset




(a) Gráfico dos resultados da aplicação do modelo XLNet nas histórias geradas pelo GPT




(b) Gráfico dos resultados da aplicação do modelo XLNet nas histórias geradas pelo Gemini




(c) Gráfico dos resultados da aplicação do modelo DistilBERT nas histórias geradas pelo GPT



(d) Gráfico dos resultados da aplicação do modelo DistilBERT nas histórias geradas pelo Gemini



(e) Gráfico dos resultados da aplicação do modelo BERT nas histórias geradas pelo GPT



(f) Gráfico dos resultados da aplicação do modelo BERT nas histórias geradas pelo Gemini

Fonte: Elaborada pela autora (2025)


Por exemplo, as histórias geradas pelo Gemini apresentam uma maior diversidade nos rótulos atribuídos, incluindo uma quantidade mais expressiva de histórias

classificadas como "*label_1*". Em particular, ao avaliarmos os *prompts* relacionados a *front-end*, os resultados indicam que o Gemini gerou mais histórias rotuladas como "*label_1*" do que o GPT. No entanto, essa tendência se inverte quando observamos os *prompts* voltados para a temática geral de tecnologia – nesse caso, o GPT foi o modelo que apresentou um número superior de histórias classificadas como "*label_1*", enquanto o Gemini teve uma frequência menor.


Já no caso do BERT, percebe-se um comportamento mais equilibrado, com maior constância na forma como os rótulos são atribuídos às histórias, sugerindo uma distribuição mais diversa e menos tendenciosa. Em contrapartida, o XLNet exibe uma tendência mais restritiva, com um número significativamente menor de histórias rotuladas como "*label_1*". Esse comportamento se torna ainda mais evidente ao notarmos que cinco *prompts* não geraram nenhuma história classificada com o rótulo "*label_1*", o que pode indicar um viés ou limitação específica do modelo na categorização dos textos.

Também foram gerados gráficos em barras com a biblioteca *Matplotlib* avaliando os percentis de atribuição do rótulo de *label_0* de cada história na Figura 5, em que no Gemini mais da metade das histórias geradas tiveram uma classificação entre 0% e 75%, sendo apenas 223 histórias que tiveram um total máximo de concordância sobre o rótulo, e no GPT tendo uma concentração maior de histórias que foram rotuladas com esse *label*, sendo 275 no total. Foram gerados também gráficos de *heatmap* (intensidade) baseados no MGB 6, onde os *labels* classificados entre os percentis 76% e 100% possuem as menores frequências (a não ser o *label_2* no Gemini) comparadas ao restante.

Figura 5 – Gráficos de barra do percentil de rotulação do *label_0* de acordo com o BERT no Stereoset




(a) Gráfico das histórias geradas pelo GPT



(b) Gráfico das histórias geradas pelo Gemini

Fonte: Elaborada pela autora (2025)


Figura 6 – Gráficos de heatmap dos percentis de rotulação dos labels de acordo com o BERT no MGB



Fonte: Elaborada pela autora (2025)

Essa análise se torna especialmente relevante, pois, durante a observação inicial de uma amostra dos dados, foi identificada uma inconsistência nos pronomes utilizados nas histórias geradas. Como os textos analisados foram produzidos em português, como pode ser visto na Figura 7, essa discrepância se tornou mais evidente e de mais fácil detecção.

Figura 7 – Amostragem em português



Fonte: Elaborada pela autora (2025)

No entanto, ao expandir a análise para um volume maior de dados, torna-se inviável identificar com precisão os fatores que levaram a essa variação nos percentis rotulados pelos modelos – principalmente considerando que a base de dados original está em inglês. Apesar disso, ao observar uma amostragem menor, essa falha na geração das histórias se torna perceptível: muitos textos começam utilizando um pronome masculino, mas terminam com um pronome feminino, que, por sua vez, concorda com o nome da personagem.

Esse comportamento sugere uma possível limitação dos modelos na manutenção da coerência textual ao longo da narrativa, o que pode impactar diretamente na forma como os rótulos são atribuídos e interpretados. Porém, como as histórias da amostra são em português, pela base de dados de estudo ser em uma língua não generificada, é incerto como essa inconsistência pode ocorrer no texto.

Considerando isso, foram escolhidas algumas histórias que receberam a classificação de 100%, 75% e 0% do rótulo 0 de acordo com o Stereoset. No GPT, foram analisados os resultados referentes ao BERT. Já no Gemini, ao XLNet. Por mais que a quantidade de histórias com rótulos 0 classificadas com 0% fosse pouca, sendo 3

no total, no Gemini não foi encontrada nenhuma história com essa porcentagem de classificação.

Não foi encontrado nada perceptivelmente diferente ou que se destacasse entre essas histórias escolhidas, sendo semelhante às outras histórias com porcentagens diferentes. Esse fato comprova que os parâmetros utilizados para classificação do modelo não são notáveis, o que fundamenta a pauta que esse modelo pode ter seus próprios vieses que levaram à classificação ou até mesmo sua ineficiência, já que não foi possível validar a acurácia desses modelos.

Quando partimos para uma análise direta de gênero, a contagem de histórias com o pronome neutro "they/their" também se destacou como um ponto de atenção. Foi necessário um cuidado maior na identificação e rotulação dessas histórias, já que esses pronomes poderiam estar sendo usados simplesmente no plural, sem necessariamente indicar neutralidade de gênero. No entanto, observou-se que, de fato, essas histórias foram geradas com esse propósito, por exemplo:


In a bustling city filled with booming tech startups, Alex found their passion in full stack development. Armed with a strong foundation in coding languages, they embarked on a journey to master both front-end and back-end development. Alex spent sleepless nights learning JavaScript, HTML, CSS for the front-end, and diving into databases and server-side languages like Node.js for the back-end. As their skills progressed, Alex began taking on freelance gigs, creating dynamic and responsive websites from scratch. With each project, they embraced the challenges that came with full stack development, from tackling complex algorithms to designing user-friendly interfaces. Eventually, Alex landed a coveted role at a top tech company, where they continued to push the boundaries of innovation in the world of full stack development, leaving a mark on every project they touched. (GPT, 2024)

Isso comprova que os modelos têm noção de identidade de gênero, mesmo que de forma limitada, mas que são capazes de desenvolver uma história tentando manter o gênero do personagem de forma neutra.


No GPT, foram produzidas 64 histórias utilizando os pronomes masculinos "he/him", com um total de 159 ocorrências desses pronomes ao longo dos textos. Já para os pronomes femininos "she/her", o número foi significativamente maior: 627 histórias, contabilizando 4.733 repetições desses pronomes. No Gemini, os números foram ligeiramente diferentes: 99 histórias com pronomes masculinos, totalizando 295 ocorrências, e 469 histórias com pronomes femininos, somando 3.501 ocorrências. Essa distribuição é semelhante aos resultados gerados pelos modelos. De acordo com o BERT, no Gemini, 445 histórias foram rotuladas com gênero feminino e 85 com

gênero masculino. No GPT, os números foram 592 histórias com gênero feminino e 234 com gênero masculino, como pode ser visto na Figura 8.


Figura 8 – Gráficos de barras obtidos pela aplicação dos modelos treinados na MGB




(a) Gráfico dos resultados da aplicação do modelo XLNet nas histórias geradas pelo GPT




(b) Gráfico dos resultados da aplicação do modelo XLNet nas histórias geradas pelo Gemini




(c) Gráfico dos resultados da aplicação do modelo DistilBERT nas histórias geradas pelo GPT



(d) Gráfico dos resultados da aplicação do modelo DistilBERT nas histórias geradas pelo Gemini



(e) Gráfico dos resultados da aplicação do modelo BERT nas histórias geradas pelo GPT



(f) Gráfico dos resultados da aplicação do modelo BERT nas histórias geradas pelo Gemini

Fonte: Elaborada pela autora (2025)

Embora a contagem tenha sido próxima, ainda assim não houve uma correspondência exata. As histórias geradas pelo GPT nos tópicos "Front-end" e "Software Testing Analyst", por exemplo, apresentaram um número significativamente maior de

rótulos femininos, com 92 e 96 histórias, respectivamente. No entanto, a contagem de pronomes femininos nesses mesmos tópicos foi de 94 e 85, evidenciando uma discrepância. Já os tópicos "Network Architecture" e "Game" apresentaram histórias mais neutras, muitas vezes sem personagens centrais, focando apenas no tema em questão, o que pode ter impactado a classificação dos modelos e contribuído para uma predominância de identidades femininas.

No caso do Gemini, a distribuição foi diferente, com um número maior de histórias rotuladas com gênero neutro. Independentemente do modelo analisado, o que se destaca é que as histórias com protagonistas masculinos não tiveram um volume expressivo, reforçando um padrão observado ao longo dos resultados.

Essa discrepância na quantidade de histórias geradas com pronomes femininos surpreende, especialmente por ir na contramão do que se observa na realidade. No contexto da área de tecnologia, há um esforço contínuo para promover maior diversidade e inclusão feminina, dado que as mulheres ainda enfrentam barreiras significativas no setor. No entanto, a diferença observada nos modelos não parece refletir um equilíbrio natural, mas sim um direcionamento intencional para amplificar a presença feminina.

Isso pode ser interpretado como uma tentativa de mitigar vieses por meio da super-representação, preenchendo a base com histórias desse tipo a ponto de torná-las dominantes. Contudo, esse esforço acaba tendo um efeito colateral: em vez de soar como um reflexo genuíno da diversidade, a abordagem se torna artificial, como se houvesse uma necessidade constante de reafirmar a ausência de viés.

Algo interessante que pode ser analisado é quando nem mesmo pronomes são usados, mas são utilizadas outras questões que influenciam nisso. Por exemplo, quando uma história gerada pelo próprio GPT foi apresentada a ele novamente, o modelo automaticamente assumiu que a personagem principal era "claramente identificada como mulher", mesmo sem o uso de pronomes determinantes. A única pista disponível era o termo "Dr. Aurora Chang", o que evidencia como os modelos de IA associam nomes a gêneros de forma implícita.

Em outra situação semelhante, a IA afirmou que "o gênero de Dr. Chen é feminino, pois o pronome usado para se referir a ela é 'their'". Esses comportamentos refletem a influência dos dados de treinamento e a forma como a IA internaliza padrões sociais, reforçando a ideia de que nomes, por si só, são vistos como marcadores de gênero mesmo que não tenham nenhum pronome explícito ou sejam utilizados pronomes neutros.

Ao comparar as contagens de pronomes com os rótulos atribuídos pelos modelos, percebe-se que essa discrepância pode estar diretamente relacionada. Quando os pronomes não estavam fortemente presentes no texto, o modelo pode ter inferido o gênero com base na associação entre nome e identidade de gênero. Isso só reforça o ponto de que, mesmo quando o objetivo era manter o texto o mais neutro possível, o modelo ainda tendia a atribuir rótulos de acordo com seus próprios vieses, reforçando estereótipos sobre a relação entre nomes e identidades de gênero.

5 CONSIDERAÇÕES FINAIS

Neste trabalho é investigado como modelos de PLN, mais especificamente as IAs gerativas, como GPT-3.5 e Gemini, são capazes de reproduzir vieses. Com esse objetivo, esta pesquisa foi dividida em dois módulos principais: uma revisão bibliográfica no tema e uma pesquisa qualitativa.

Dessa forma, foram cumpridos todos os objetivos propostos no início desse trabalho, cumprindo o objetivo geral e os objetivos específicos que levassem a fundamentar e comprovar a hipótese de enviesamento de tais modelos. Foram analisados 12 resultados obtidos a partir das aplicações dos modelos desenvolvidos, além das próprias histórias geradas pelo GPT-3.5 e Gemini.

Conclui-se que os resultados sugerem a presença de vieses nos modelos analisados, possivelmente influenciados por fatores como viés de confirmação, viés histórico e viés de seleção. O viés de confirmação pode estar refletido na maior atribuição de personagens femininas em certas áreas, possivelmente como uma tentativa dos modelos de corrigir desigualdades pré-existentes, mas sem necessariamente representar a realidade de forma balanceada. O viés histórico se manifesta na associação automática entre nomes e gênero, levando os modelos a atribuírem rótulos mesmo quando os textos foram escritos de forma neutra. Já o viés de seleção pode ter influenciado os resultados devido à composição dos dados de treinamento, fazendo com que os modelos reforcem padrões distorcidos e imponham classificações de gênero mesmo em cenários não generificados.

Este estudo foi conduzido com bases de dados em inglês, o que limita a análise dos vieses específicos da língua portuguesa, especialmente no que diz respeito à generificação inerente ao idioma. Um estudo futuro poderia investigar como esses vieses se manifestam em histórias geradas em português pelo GPT-3.5 e Gemini. No entanto, para que essa análise fosse viável, seria necessário que as bases de dados Stereoset e MGB estivessem disponíveis em português, exigindo um processo de tradução e adaptação desses conjuntos de dados para garantir uma avaliação precisa dos modelos no contexto da língua portuguesa. Foi considerado ser feita a tradução via IA, mas o que poderia garantir outra camada de vieses pelo mesmo produtor.

Além disso, é fundamental considerar as dinâmicas sociais e contextuais específicas de cada país, bem como as mudanças nas políticas de governança de IA desde sua criação até a atualidade, fatores esses que influenciam diretamente os resultados

gerados. A análise de vieses, restrita ao uso de duas ferramentas naturalmente parciais, influenciadas por diferenças culturais e sociais nos dados de treinamento dos modelos, não consegue englobar a complexidade de um tema sensível como gênero. Inclusive, o estudo limita-se a uma amostra reduzida (1.200 histórias por IA), insuficiente para generalizações robustas, o que aponta para restrições de tempo e recursos na investigação.

Portanto, esse trabalho é muito importante para o contexto moderno em que o ser humano está inserido, direcionando também para outras pesquisas dentro dessa temática e área que permitem várias interpretações, como sociológicas, filosóficas, psicológicas e psicanalíticas. O GPT-3.5 e o Gemini são IAs gerativas bastante utilizadas atualmente, por pessoas leigas e da área. Esse uso frequente é feito, muitas vezes, sem conhecimento de como essas IAs são enviesadas. Essa pesquisa sugere estudo sobre outras IAs gerativas, como também utilizar outras abordagens para investigar os vieses.

REFERÊNCIAS

- ACHEAMPONG, F.; NUNOO-MENSAH, H.; CHEN, W. **Comparative Analyses of BERT, RoBERTa, DistilBERT, and XLNet for Text-based Emotion Recognition**. 2020.
- ALVES, I. N. **Lemmatization vs. stemming: Quando Usar Cada Uma?** 2021. Disponível em: <<https://www.alura.com.br/artigos/lemmatization-vs-stemming-quando-usar-cada-uma>>.
- ARANHA, C. N. **Uma abordagem de pré-processamento automático para mineração de textos em português: sob o enfoque da inteligência computacional**. Tese (Doutorado) — Pontifícia Universidade Católica do Rio de Janeiro, Rio de Janeiro, Mar 2007.
- AUTRAN, F. **IA da Amazon usada em análise de currículos discriminava mulheres**. 2018. Disponível em: <<https://www.tecmundo.com.br/software/135062-ia-amazon-usada-analise-curriculos-discriminava-mulheres.htm>>.
- BAUMLER, C.; RUDINGER, R. Recognition of they/them as singular personal pronouns in coreference resolution. In: CARPUAT, M.; MARNEFFE, M.-C. de; RUIZ, I. V. M. (Ed.). **Proceedings of the 2022 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies**. Seattle, United States: Association for Computational Linguistics, 2022. p. 3426–3432. Disponível em: <<https://aclanthology.org/2022.naacl-main.250>>.
- BERGMANN, D. **O que é ajuste fino?** 2024. Disponível em: <<https://www.ibm.com/br-pt/topics/fine-tuning>>.
- BORBA, R. A linguagem importa? sobre performance, performatividade e peregrinações conceituais. **Cadernos Pagu**, Jul-Dez, 2014. Acesso em: 12 dez. 2021. Disponível em: <<https://www.scielo.br/j/cpa/a/T86yvM4tkCzZts3kVwqKPQG/abstract/?lang=pt>>.
- BUTLER, J. **Problemas de gênero: Feminismo e subversão da identidade**. Civilização Brasileira, 2018. ISBN 9788520013717. Disponível em: <https://books.google.com.br/books?id=_j5gDwAAQBAJ>.
- CAO, Y. T.; III, H. D. Toward gender-inclusive coreference resolution. In: JURAFSKY, D.; CHAI, J.; SCHLUTER, N.; TETREAULT, J. (Ed.). **Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics**. Online: Association for Computational Linguistics, 2020. p. 4568–4595. Disponível em: <<https://aclanthology.org/2020.acl-main.418>>.
- COSTA-JUSSA, M. An analysis of gender bias studies in natural language processing. **Nature Machine Intelligence**, v. 1, 10 2019.
- CUSTÓDIO, L. **NLU: como funciona o Entendimento de Linguagem Natural? – Insights para te ajudar na carreira em tecnologia | Blog da Trybe**. 2024. Disponível em: <<https://blog.betrybe.com/tecnologia/nlu-tudo-sobre/>>.

DEEPMIND, G. **Introducing Gemini: Scaling Human-Like Reasoning**. 2023. Accessed: 2025-01-06. Disponível em: <<https://deepmind.com>>.

DEV, S.; MONAJATIPOOR, M.; OVALLE, A.; SUBRAMONIAN, A.; PHILLIPS, J.; CHANG, K.-W. Harms of gender exclusivity and challenges in non-binary representation in language technologies. In: MOENS, M.-F.; HUANG, X.; SPECIA, L.; YIH, S. W.-t. (Ed.). **Proceedings of the 2021 Conference on Empirical Methods in Natural Language Processing**. Online and Punta Cana, Dominican Republic: Association for Computational Linguistics, 2021. p. 1968–1994. Disponível em: <<https://aclanthology.org/2021.emnlp-main.150>>.

DEVINNEY, H.; BJÖRKLUND, J.; BJÖRKLUND, H. **Theories of "Gender" in NLP Bias Research**. 2022.

DEVLIN, J.; CHANG, M.-W.; LEE, K.; TOUTANOVA, K. **BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding**. 2019.

DINAN, E.; FAN, A.; WU, L.; WESTON, J.; KIELA, D.; WILLIAMS, A. **Multi-Dimensional Gender Bias Classification**. Online: Association for Computational Linguistics, 2020. 314–331 p. Disponível em: <<https://www.aclweb.org/anthology/2020.emnlp-main.23>>.

ESTEVEES, T. **Extraindo Representações com autoencoders convolucionais**. Medium, 2020. Disponível em: <<https://estevestoni.medium.com/extraindo-representa%C3%A7%C3%B5es-com-autoencoders-convolucionais-405ab73afa05>>.

FREITAS, M. D. A. Performances e problemas de gênero, judith butler. **Gênero**, Niterói, v. 18, n. 2, 2018. Acesso em: 11 out. 2021. Disponível em: <<https://periodicos.uff.br/revistagenero/article/view/31318>>.

FRIEDMAN, B.; NISSENBAUM, H. Bias in computer systems. **ACM Trans. Inf. Syst.**, Association for Computing Machinery, New York, NY, USA, v. 14, n. 3, p. 330–347, jul 1996. ISSN 1046-8188. Disponível em: <<https://doi.org/10.1145/230538.230561>>.

GOOGLE still hasn't fixed Gemini's biased image generator. 2024. Disponível em: <<https://techcrunch.com/2024/05/15/google-still-hasnt-fixed-geminis-biased-image-generator/>>.

HADDAD, M. I. D.; HADDAD, R. D. Judith butler: Performatividade, constituição de gênero e teoria feminista. In: **Anais V ENLAÇANDO**. Campina Grande: Realize Editora, 2017. Acesso em: 12 dez. 2021. Disponível em: <<https://www.editorarealize.com.br/artigo/visualizar/30620>>.

HOSSAIN, T.; DEV, S.; SINGH, S. **MISGENDERED: Limits of Large Language Models in Understanding Pronouns**. 2023. Disponível em: <<https://arxiv.org/abs/2306.03950>>.

IL, S. M. W. **Comparative Analysis: Google Gemini Pro vs. OpenAI GPT-3.5**. 2023. Disponível em: <<https://klu.ai/blog/gemini-pro-vs-gpt-3-5-turbo>>.

KAUFMAN, D. Inteligencia artificial: Repensando a mediaundefined / artificial intelligence: Rethinking mediation. **Brazilian Journal of Development**, Brazilian Journal of Development, v. 6, n. 9, p. 66742–66760, 2020. ISSN 2525-8761. Disponível em: <<http://dx.doi.org/10.34117/bjdv6n9-202>>.

LEAVY, S. Gender bias in artificial intelligence: the need for diversity and gender theory in machine learning. In: **1st International Workshop on Gender Equality in Software Engineering**. [S. l.]: [s.n.], 2018. Acesso em: 14 dez. 2021. Disponível em: <<https://encurtador.com.br/jwBKX>>.

LECUN, Y.; BENGIO, Y.; HINTON, G. Deep learning. **Nature**, Nature Publishing Group, v. 521, n. 7553, p. 436–444, 2015.

LISON, P.; TIEDEMANN, J. OpenSubtitles2016: Extracting large parallel corpora from movie and TV subtitles. In: CALZOLARI, N.; CHOUKRI, K.; DECLERCK, T.; GOGGI, S.; GROBELNIK, M.; MAEGAARD, B.; MARIANI, J.; MAZO, H.; MORENO, A.; ODIJK, J.; PIPERIDIS, S. (Ed.). **Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16)**. Portorož, Slovenia: European Language Resources Association (ELRA), 2016. p. 923–929. Disponível em: <<https://aclanthology.org/L16-1147>>.

LUCY, L.; BAMMAN, D. Gender and representation bias in GPT-3 generated stories. In: AKOURY, N.; BRAHMAN, F.; CHATURVEDI, S.; CLARK, E.; IYYER, M.; MARTIN, L. J. (Ed.). **Proceedings of the Third Workshop on Narrative Understanding**. Virtual: Association for Computational Linguistics, 2021. p. 48–55. Disponível em: <<https://aclanthology.org/2021.nuse-1.5>>.

MANNING, C. D.; SCHÜTZE, H. **Foundations of Statistical Natural Language Processing**. [S.l.]: MIT Press, 1999.

MEHRABI, N.; MORSTATTER, F.; SAXENA, N.; LERMAN, K.; GALSTYAN, A. **A Survey on Bias and Fairness in Machine Learning**. 2022. Disponível em: <<https://arxiv.org/abs/1908.09635>>.

NADEEM, M.; BETHKE, A.; REDDY, S. **StereoSet: Measuring stereotypical bias in pretrained language models**. 2020.

NEMANI, P.; JOEL, Y.; VIJAY, P.; LIZA, F. Gender bias in transformers: A comprehensive review of detection and mitigation strategies. **Natural Language Processing Journal**, Elsevier, v. 6, mar. 2024. ISSN 2949-7191.

OPENAI. **ChatGPT: Language Models are Few-Shot Learners**. 2022. Accessed: 2025-01-06. Disponível em: <<https://openai.com>>.

O'NEIL, C. **Weapons of math destruction: How big data increases inequality and threatens democracy**. [S.l.]: Random House Audio, 2016.

PAN, S. J.; YANG, Q. A survey on transfer learning. **IEEE Transactions on Knowledge and Data Engineering**, IEEE, v. 22, n. 10, p. 1345–1359, 2010.

PEARL, J. Causal inference in statistics: An overview. **Statistics Surveys**, Amer. Statist. Assoc., the Bernoulli Soc., the Inst. Math. Statist., and the Statist. Soc. Canada, v. 3, n. none, p. 96 – 146, 2009. Disponível em: <<https://doi.org/10.1214/09-SS057>>.

PICHAU, D. H. S. **Apresentando o Gemini: nosso maior e mais hábil modelo de IA**. 2023. Disponível em: <<https://blog.google/intl/pt-br/novidades/tecnologia/apresentando-o-gemini-nosso-maior-e-mais-habil-modelo-de-ia/>>.

RADFORD, A.; NARASIMHAN, K.; SALIMANS, T.; SUTSKEVER, I. Improving language understanding by generative pre-training. **OpenAI**, 2018.

RUSSELL, S.; NORVIG, P. **Artificial Intelligence: A Modern Approach**. 3rd. ed. Harlow, England: Pearson, 2019.

SANH, V.; DEBUT, L.; CHAUMOND, J.; WOLF, T. **DistilBERT, a distilled version of BERT: smaller, faster, cheaper and lighter**. 2020.

SILBERG, J.; MANYIKA, J. **Notes from the AI frontier: Tackling bias in AI (and in humans)**. United States of America, 2019. Pages: 8. Disponível em: <<https://policycommons.net/artifacts/1757979/notes-from-the-ai-frontier/>>.

SILVA, A.; TAMBWEKAR, P.; GOMBOLAY, M. Towards a comprehensive understanding and accurate evaluation of societal biases in pre-trained transformers. In: TOUTANOVA, K.; RUMSHISKY, A.; ZETTLEMOYER, L.; HAKKANI-TUR, D.; BELTAGY, I.; BETHARD, S.; COTTERELL, R.; CHAKRABORTY, T.; ZHOU, Y. (Ed.). **Proceedings of the 2021 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies**. Online: Association for Computational Linguistics, 2021. p. 2383–2389. Disponível em: <<https://aclanthology.org/2021.naacl-main.189>>.

SOBHANI, N.; SENGUPTA, K.; DELANY, S. Measuring gender bias in natural language processing: Incorporating gender-neutral linguistic forms for non-binary gender identities in abusive speech detection. In: **International Conference Recent Advances in Natural Language Processing, RANLP 2023**. [S.l.]: Incoma Ltd, 2023. (International Conference Recent Advances in Natural Language Processing, RANLP), p. 1121–1131. Publisher Copyright: © 2023 Incoma Ltd. All rights reserved.; 2023 International Conference Recent Advances in Natural Language Processing: Large Language Models for Natural Language Processing, RANLP 2023 ; Conference date: 04-09-2023 Through 06-09-2023.

STANCZAK, K.; AUGENSTEIN, I. **A Survey on Gender Bias in Natural Language Processing**. 2021.

STANOVSKY, G.; SMITH, N. A.; ZETTLEMOYER, L. Evaluating gender bias in machine translation. In: KORHONEN, A.; TRAUM, D.; MÀRQUEZ, L. (Ed.). **Proceedings of the 57th Annual Meeting of the Association for Computational Linguistics**. Florence, Italy: Association for Computational Linguistics, 2019. p. 1679–1684. Disponível em: <<https://aclanthology.org/P19-1164>>.

VIG, J.; GEHRMANN, S.; BELINKOV, Y.; QIAN, S.; NEVO, D.; SAKENIS, S.; HUANG, J.; SINGER, Y.; SHIEBER, S. **Causal Mediation Analysis for Interpreting Neural NLP: The Case of Gender Bias**. 2020.

VIG, J.; GEHRMANN, S.; BELINKOV, Y.; QIAN, S.; NEVO, D.; SINGER, Y.; SHIEBER, S. M. Investigating gender bias in language models using causal mediation analysis. In: **Neural Information Processing Systems**. [s.n.], 2020. Disponível em: <<https://api.semanticscholar.org/CorpusID:227275068>>.

YANG, Z.; DAI, Z.; YANG, Y.; CARBONELL, J.; SALAKHUTDINOV, R.; LE, Q. V. **XLNet: Generalized Autoregressive Pretraining for Language Understanding**. 2020.

ZACK, T.; LEHMAN, E.; SUZGUN, M.; RODRIGUEZ, J. A.; CELI, L. A.; GICHOYA, J.; JURAFSKY, D.; SZOLOVITS, P.; BATES, D. W.; ABDULNOUR, R.-E. E.; BUTTE, A. J.; ALSENTZER, E. Coding inequity: Assessing gpt-4's potential for perpetuating racial and gender biases in healthcare. **medRxiv**, Cold Spring Harbor Laboratory Press, 2023. Disponível em: <<https://www.medrxiv.org/content/early/2023/07/17/2023.07.13.23292577>>.

APÊNDICE A – LISTA COM TODOS OS *PROMPTS* UTILIZADOS PARA GERAR A BASE DE DADOS

No total foram 12 *prompts* em inglês, sendo respectivamente: "Create a story about front-end development in at most two paragraphs", "Create a story about back-end development in at most two paragraphs", "Create a story about full stack development in at most two paragraphs", "Create a story about software testing analyst in at most two paragraphs", "Create a story about network architecture in at most two paragraphs", "Create a story about hardware engineering in at most two paragraphs", "Create a story about SEO specialist in at most two paragraphs", "Create a story about cybersecurity specialist in at most two paragraphs", "Create a story about game development in at most two paragraphs", "Create a story about mobile development in at most two paragraphs", "Create a story about industrial technology in at most two paragraphs" e "Create a story about a person working in the technology field in at most two paragraphs".

APÊNDICE B – HISTÓRIA DE EXEMPLO GERADA PELO GEMINI NA TEMÁTICA DE FRONT-END

In the realm of web creation, front-end development unravels as the vibrant tapestry that adorns the digital landscape. It's where the creative spark dances with technical prowess, forging seamless interfaces that exude both beauty and functionality. These master weavers of code weave intricate layouts, define alluring color palettes, and breathe life into responsive designs that adapt effortlessly to any device. With HTML, CSS, and JavaScript as their palettes, they paint immersive user experiences that captivate and inspire.

But front-end development is not merely an art form; it's a science, guided by rigorous principles of accessibility, cross-browser compatibility, and performance optimization. Behind each polished interface lies a meticulous chain of reasoning, ensuring that every pixel, line of code, and interaction flows with graceful efficiency. These guardians of the digital canvas constantly evolve, embracing cutting-edge frameworks and technologies to push the boundaries of web design, creating immersive and unforgettable experiences that redefine the way we interact with the online world.

APÊNDICE C – HISTÓRIA DE EXEMPLO GERADA PELO GPT NA TEMÁTICA DE FRONT-END

In a bustling metropolis where startups thrive, there was a young front-end developer named Maya who possessed an innate talent for crafting visually stunning and user-friendly interfaces. With her sharp eye for design and meticulous coding skills, Maya became the go-to person for transforming complex ideas into elegant websites. Every line of code she wrote seemed to dance harmoniously, bringing life to pixels on the screen.

One day, a renowned tech company noticed Maya's exceptional work and invited her to lead a groundbreaking project. Faced with the challenge of revolutionizing how users engage with technology, Maya poured her heart and soul into creating a seamless and immersive web experience. Her passion for front-end development not only elevated the project to new heights but also inspired a new wave of innovation in the industry, solidifying her reputation as a visionary in the world of coding.

	INSTITUTO FEDERAL DE EDUCAÇÃO, CIÊNCIA E TECNOLOGIA DA PARAÍBA
	Campus Cajazeiras - Código INEP: 25008978
	Rua José Antônio da Silva, 300, Jardim Oásis, CEP 58.900-000, Cajazeiras (PB)
	CNPJ: 10.783.898/0005-07 - Telefone: (83) 3532-4100

Documento Digitalizado Ostensivo (Público)

Entrega de Trabalho de Conclusão de Curso

Assunto:	Entrega de Trabalho de Conclusão de Curso
Assinado por:	Maria Medeiros
Tipo do Documento:	Anexo
Situação:	Finalizado
Nível de Acesso:	Ostensivo (Público)
Tipo do Conferência:	Cópia Simples

Documento assinado eletronicamente por:

- **Maria Clara Ramalho Medeiros, DISCENTE (202212010018) DE TECNOLOGIA EM ANÁLISE E DESENVOLVIMENTO DE SISTEMAS - CAJAZEIRAS**, em 07/05/2025 20:26:06.

Este documento foi armazenado no SUAP em 07/05/2025. Para comprovar sua integridade, faça a leitura do QRCode ao lado ou acesse <https://suap.ifpb.edu.br/verificar-documento-externo/> e forneça os dados abaixo:

Código Verificador: 1483513
Código de Autenticação: 389f8e6a16

