

ARTIGO ORIGINAL

Análise de sentimentos em textos de redes sociais: uma comparação entre o ChatGPT e métodos tradicionais

**Maria Eduarda
Ramos Da Silva**

Universidade Federal da Paraíba,
João Pessoa, Brasil
maria.silva12@academico.ufpb.br

**Paulo Henrique Souto
Maior Serrano**

Universidade Federal da Paraíba,
João Pessoa, Brasil
paulo.serrano@academico.ufpb.br

RESUMO

As análises automatizadas na comunicação digital contribuem para uma compreensão extensiva dos fenômenos sociais. A pesquisa apresenta uma comparação entre o ChatGPT e abordagens tradicionais da análise de sentimentos de textos extraídos de redes sociais. Os métodos comparados apresentaram resultados satisfatórios na identificação de emoções e polaridade, e o ChatGPT se mostrou eficaz como ferramenta de análise de sentimentos.

PALAVRAS-CHAVE: ChatGPT; Processamento de Linguagem Natural; Análise de Sentimentos.

RECEBIDO EM 17/08/2023
ACEITO EM 20/11/2023



Este trabalho está licenciado sob uma licença [Creative Commons Attribution-NonCommercial-ShareAlike 4.0 International License](https://creativecommons.org/licenses/by-nc-sa/4.0/).

Análisis de sentimientos en textos de redes sociales: una comparación entre ChatGPT y los métodos tradicionales

RESUMEN

Las análisis automatizadas en la comunicación digital contribuyen a una comprensión amplia de los fenómenos sociales. La investigación presenta una comparación entre ChatGPT y enfoques tradicionales en el análisis de sentimientos en textos extraídos de redes sociales. Los métodos comparados arrojaron resultados satisfactorios en la identificación de emociones y polaridad, y ChatGPT demostró ser eficaz como herramienta de análisis de sentimientos.

PALABRAS CLAVE: ChatGPT; Procesamiento de Lenguaje Natural; Análisis de Sentimientos.

Sentiment analysis in social media texts: a comparison between ChatGPT and traditional methods

ABSTRACT

Automated analyses in digital communication contribute to a comprehensive understanding of social phenomena. The research presents a comparison between ChatGPT and traditional approaches to analyzing sentiments in texts extracted from social networks. The compared methods yielded satisfactory results in emotion and polarity identification, and ChatGPT proved to be effective as a sentiment analysis tool.

KEYWORDS: ChatGPT; Natural Language Processing; Sentiment Analysis.

1 INTRODUÇÃO

A análise de textos em redes sociais digitais tem sido utilizada por organizações e pesquisadores para compreender os sentimentos e emoções expressos pelos usuários das plataformas digitais de comunicação em torno de algum tópico de interesse. Diferentes métodos e tecnologias podem ser utilizados para esse tipo de finalidade.

A análise de sentimentos utilizando o processamento de linguagem natural (PLN) é uma abordagem que pode otimizar o processo de análise de dados. No ano de 2022, o ChatGPT foi apresentado ao público e tem sido utilizado em diversas áreas, como no marketing e na educação. Esse estudo busca mostrar os resultados que o ChatGPT, um grande modelo de linguagem, pode apresentar ao ser instruído a realizar análises de sentimento e emoção em textos distintos. Por não exigir um conhecimento em programação, a ferramenta pode ser muito útil para interpretar dados e informações de uma forma automatizada e classificá-los com uma emoção específica.

Outras ferramentas já existentes na análise de emoções e sentimentos, como o NLTK e o FLAIR, que são duas bibliotecas do Python e serão utilizadas juntamente com uma análise qualitativa dos textos realizadas pelos pesquisadores para comparar os resultados com o objetivo de identificar as consistências, os pontos positivos e negativos de cada uma dessas abordagens, que utilizam métodos de aprendizagem de máquina profunda.

A pesquisa está fundamentada na compreensão dos conceitos de emoção e sentimento na análise de textos, um breve panorama sobre as atuais pesquisas e ferramentas utilizadas para a análise de sentimento e emoções que fazem uso da inteligência artificial e a apresentação do ChatGPT como a nova ferramenta a ser testada.

Os resultados revelaram consistência na análise de polaridade, mas divergências na análise de emoções, especialmente com o NLTK. No entanto, o ChatGPT se destacou por sua capacidade de compreender o contexto das mensagens e apresentar resultados mais próximos dos que foram identificados por análise hermenêutica pelos pesquisadores.

2 DESENVOLVIMENTO

2.1 Fundamentação Teórica

2.1.1 *Conceito de emoções e sentimentos em textos*

O conceito de emoção, seus aspectos e sua relação com a razão são objetos de estudo de várias áreas, inclusive da filosofia (BARRETO e SILVA, 2009). Assim, ainda na Grécia Antiga, alguns filósofos como Platão, Sócrates (SCOLNICOV, 2006) e Aristóteles (FRANCISCO, 2000), tentavam compreender as emoções e como elas se relacionam com as práticas sociais. Esse é um tópico de interesse recorrente na história da humanidade.

A etimologia da palavra “emoção” vem do latim, e remete a ideia de movimento. Dessa forma, a emoção se movimenta do interior para o exterior, é por meio dela que os indivíduos se comunicam e expõem suas condições internas. A partir do interesse e estudo da comunidade científica, nos dias atuais sabe-se que, anatomicamente, os processos emocionais estão ligados a bases neurais e ao sistema límbico, e são exteriorizados por alterações fisiológicas (BARRETO e SILVA, 2009) em resposta a estímulos (PIA e FIGUÊIREDO, 2016).

É importante apontar a diferença entre emoções e sentimentos, tendo em vista que são fenômenos diferentes. Assim, enquanto a emoção é a resposta fisiológica do organismo em relação a um estímulo, o sentimento é a consciência de uma emoção, é a percepção de um pensamento e do corpo frente a alguma situação (PIA e FIGUÊIREDO, 2016). Dessa forma, “acontece o estímulo (EEC), o corpo reage (emoção) o estado de perturbação passa e então se toma uma consciência corpórea e mental do ocorrido (sentimento).” (PIA e FIGUÊIREDO, 2016, p. 29).

Essa consciência humana capaz de classificar a emoção e os sentimentos constitui uma estrutura complexa e subjetiva que pode ser apreendida através

da exteriorização desse fenômeno em textos verbais ou não verbais. Os textos que representam, ou denotam, as emoções humanas podem ser analisados com o auxílio de técnicas computacionais baseadas no processamento de linguagem natural, de forma específica a análise de sentimentos e análise de emoções.

Na computação, a análise de sentimentos pode ser o estudo da opinião, sentimentos, humor e emoções das pessoas em textos, de acordo com Liu (2020). Dentro desse campo, é possível ser feita uma análise de ânimo, que estuda se os sentimentos e/ou emoções presentes no texto são positivas, neutras ou negativas, com o processamento da linguagem natural (PLN). E dentro da análise de sentimentos, também há a detecção de emoções, que é usada para classificar dados textuais com a emoção que é evocada no texto.

Scherer e Wallbott (1994), em seus estudos, utilizaram 7 emoções principais. Essas emoções são: alegria, medo, raiva, tristeza, desgosto, culpa, e vergonha. Essas mesmas emoções foram utilizadas no presente artigo para classificar as amostras a serem analisadas.

2.1.2 O estado da arte sobre a utilização de inteligência artificial para avaliar emoções e sentimentos de textos

A Inteligência Artificial (IA) é um campo que estuda métodos para fazer as máquinas realizarem tarefas como seres humanos através de algoritmos, que são comandos computacionais (GARCIA, 2020). Uma dessas tarefas pode estar relacionada com a compreensão das linguagem, uma característica dos seres humanos que é introduzida no âmbito computacional através do Processamento de Linguagem Natural (PLN).

O PLN, uma das áreas de atuação da linguística computacional, se propõe a estudar a comunicação humana através de recursos computacionais, possibilitando que as máquinas possam entender e gerar respostas naturais baseadas no que foi aprendido (GONZALEZ e LIMA, 2003). Desse modo, com os avanços do PLN, é

possível para um ser humano estabelecer uma comunicação com a máquina com uma linguagem humana.

Liddy¹ (2003) apresenta que a origem do PLN remonta ao período histórico da Segunda Guerra Mundial em que a necessidade de criar um sistema rápido de tradução automática de idiomas era fundamental para quebrar os códigos feitos pelos inimigos. Com os avanços na área, alguns métodos e abordagens foram desenvolvidas.

As abordagens de PLN que Wankhade, Rao e Kulkarni² (2022) destacam como as mais comuns para a análise de sentimentos e emoções em textos, são: 1) a abordagem lexical; 2) a abordagem com aprendizado de máquina (do inglês *machine learning*); 3) a abordagem combinada.

A abordagem lexical, comumente usada na análise de sentimentos, é baseada em uma polaridade, classificando as palavras como positivas, neutras e negativas (WANKHADE; RAO; KULLARNI, 2022). A pontuação +1 é o nível mais alto de positividade, 0 é o valor neutro, e -1, o valor mais alto de negatividade. Essa abordagem não requer o treino de um novo *dataset* (base de dados), apesar de ser possível fazê-lo, e tem duas formas: a baseada em dicionários e a baseada em *corpus* (*Ibid.*).

Na abordagem com *machine learning*, são desenvolvidos algoritmos para um modelo de linguagem através do treinamento de dados. Nessa abordagem, Ludermir (2021) cita três tipos principais de aprendizado de máquina: o supervisionado, o não-supervisionado e o por reforço.

A pesquisadora fala que no tipo supervisionado, o *dataset* é treinado manualmente por um ser humano, apresentando ao algoritmo a resposta desejada nos dados que estão sendo rotulados, e essa classificação é aplicada nos dados ainda não rotulados que serão analisados. No entanto, na abordagem não supervisionada, as amostras recebidas pelo algoritmo não são rotuladas, e a máquina detecta padrões para interpretar os dados e estruturá-los (SAMEK et al. 2021).

¹ Link: <https://surface.syr.edu/cgi/viewcontent.cgi?article=1043&context=istpub>.

² Link: <https://link.springer.com/article/10.1007/s10462-022-10144-1#Sec15>.

Na por reforço, o algoritmo recebe uma recompensa ou punição para aperfeiçoar suas políticas. Ludermir (2021) diz que “[...] o algoritmo não recebe a resposta correta mas recebe um sinal de reforço, de recompensa ou punição. O algoritmo faz uma hipótese baseado nos exemplos e determina se essa hipótese foi boa ou ruim”.

Dentro do *machine learning*, existe um campo chamado *deep learning* (aprendizagem profunda), em que se utilizam técnicas para treinar redes neurais com diversos algoritmos diferentes. De acordo com Ludermir³ (2021), as redes neurais são inspiradas no cérebro humano, criando conexões entre neurônios artificiais. A técnica divide-se em uma fase de treinamento, onde os dados são rotulados previamente e entregues ao algoritmo, e uma fase de testes, onde esses algoritmos são avaliados e modificados de acordo com o resultado dos testes.

Esses são os métodos mais comuns da abordagem lexical e *machine learning*. Na abordagem combinada de PLN, são utilizadas as duas técnicas de aprendizado para treinar a máquina. A aplicação dessas abordagens de PLN em Python, uma linguagem de programação de alto nível, pode ser feita através do NLTK (*Natural Language Toolkit*) O NLTK é uma biblioteca do Python criada para o Processamento de Linguagem Natural (BIRD, 2006) e tem como recurso disponível a análise de sentimentos. Essa biblioteca conta com diversos *datasets* pré-prontos e é muito utilizada no contexto acadêmico.

Para a análise de sentimentos com polaridade, uma opção em Python é o *framework* Flair⁴, um modelo de linguagem simples que oferece a possibilidade de utilizar um *dataset* pré-treinado. Ele é treinado na biblioteca do PyTorch, que utiliza métodos de aprendizagem profunda em seu algoritmo.

A vantagem de se usar inteligência artificial para detectar sentimentos é a capacidade de analisar os dados com mais velocidade e de forma automatizada, tornando o processo mais simples e tendo um maior aproveitamento do tempo.

³ Link: <https://www.revistas.usp.br/eav/article/view/185035>.

⁴ Link: <https://aclanthology.org/N19-4010.pdf>.

Nesse artigo, teremos o foco nos métodos de aprendizagem máquina, utilizando NLTK, Flair e o ChatGPT, que será explicado adiante.

2.1.3 *Descrição do ChatGPT e suas possibilidades de aplicação no processamento de linguagem natural*

Chatbots são ferramentas de conversação treinadas para compreender a linguagem natural, capazes de se comunicar por texto ou por áudio com seres humanos utilizando o PLN (ADAMOPOULOU, MOUSSIADES, 2020b). Eles conseguem responder uma grande quantidade de pessoas ao mesmo tempo e são muito utilizados por empresas para automatizar processos.

De acordo com Agarwal e Wadhwa (2020), os *chatbots* podem ser divididos em dois tipos: *Rule-Based Chatbots* (*chatbots* baseados em regras), que são treinados com *scripts* prontos para as respostas, e *Neural-Based Chatbots* (*chatbots* baseados em redes neurais), que são treinados com métodos de aprendizagem profunda.

A primeira *chatbot* da história, desenvolvida por Joseph Weizenbaum aproximadamente em 1964 no *Massachusetts Institute of Technology* (MIT), foi ELIZA, que anteriormente também foi chamada de DOCTOR (ZEMČÍK, 2019). De acordo com Weizenbaum (1966), o criador desse programa computacional, ELIZA tinha a capacidade de estabelecer conversas textuais com o usuário e imitava a forma que um psicoterapeuta responderia as informações apresentadas, armazenando algumas palavras-chaves que transformassem o contexto do que estava sendo falado e fornecendo uma resposta a partir de algum *script* que se encaixasse nesse contexto.

Ela tinha uma limitação em suas falas por ser desenvolvida na abordagem de *pattern matching*, que faz parte do método *rule-based learning*, que armazena palavras-chaves para formular uma frase com os *scripts* prontos, mas esse método não compreende o contexto prévio, tornando as respostas do *chatbot* menos naturais (AGARWAL e WADHWA, 2020).

Um outro *chatbot* que surgiu na época, em 1970, foi o PARRY. Ele simulava um paciente com esquizofrenia. De acordo com Adamopoulou e Moussiades⁵ (2020b), esse *chatbot* era considerado mais evoluído que ELIZA por ter mais personalidade. Assim como ELIZA, ele não fazia uma boa compreensão da linguagem natural.

Em 1991, inspirada em ELIZA, surgiu ALICE (*Artificial Linguistic Internet Computer Entity*), ela foi desenvolvida com uma nova linguagem de marcação, a *Artificial Intelligence Markup Language* (AIML) e tinha mais de 41,000 regras e *scripts* prontos (ADAMOPOULOU e MOUSSIADES, 2020b). Apesar disso, ela ainda não era capaz de gerar respostas originais, divergentes dos *scripts* do seu *dataset*, por também ser desenvolvida em uma abordagem baseada em regras (AGARWAL e WADHWA, 2020).

Com a evolução dos *chatbots*, o desenvolvimento de novas ferramentas continuou a acontecer progressivamente, sendo usados em diversos campos. De acordo com Adamopoulou e Moussiades⁶ (2020a), as pessoas passaram a ter mais interesse no assunto a partir de 2016. Após o lançamento do ChatGPT, no período de junho de 2022 e junho de 2023, o assunto “chatgpt” ficou em segundo lugar entre os mais pesquisados mundialmente no Google, de acordo com o Google Trends (2023), seguido por “chat gpt”.

O ChatGPT foi lançado em 2022 e é desenvolvido pela OpenAI, empresa fundada por Reid Hoffman, Peter Thiel, Elon Musk, Greg Brockman, Sam Altman e outros investidores, com o objetivo de criar inteligências artificiais “amigáveis” que possam alcançar diferentes indústrias (MHLANGA, 2023).

O treinamento do ChatGPT utiliza o método *Reinforcement Learning from Human Feedback* (RLHF) (OpenAI, 2022), que é um método de aprendizagem por reforço que tem como parâmetro o uso do *deep learning*. É possível oferecer *feedbacks* para o ChatGPT durante a conversação, com os botões de *like* ou *deslike*, influenciando suas respostas.

⁵ Link: <https://www.sciencedirect.com/science/article/pii/S2666827020300062>.

⁶ Link: <https://www.sciencedirect.com/science/article/pii/S2666827020300062>.

Uma forma de medir as qualidades de uma inteligência artificial é com o teste de Turing, no qual há três participantes: Uma pessoa que fará o interrogatório, um ser humano e uma máquina que irão conversar com o interrogador, que não terá informações prévias para que possa distingui-los antes do teste. No final, o interrogador precisa identificar quem é um ser humano e quem é uma máquina (TURING e COPELAND, 2004). Dessa forma, poderá ser medido o quanto essa inteligência artificial entende a linguagem humana.

Quando perguntado se ele tem a capacidade de ser aprovado no teste de Turing, o ChatGPT deu a resposta que ele é incapaz de passar pelo teste pelo motivo de não ter sido programado para manter uma conversa fluida e imitar a linguagem natural em todos os sentidos. Sobre quais são suas outras limitações, ele respondeu que não é capaz de ter sentimentos, empatia ou consciência própria.

Um dos defeitos do ChatGPT, analisados por Borji (2023) e também mencionados no site da OpenAI (2022), é que a ferramenta eventualmente traz informações com inconsistências factuais ou inventadas, enfrentando dificuldades em diferenciá-las das informações legítimas da sua base de dados.

Sobre suas possibilidades de aplicação no processamento de linguagem natural, Hariri (2023) destaca que o ChatGPT pode fazer tradução automática, sumarizar e classificar textos, analisar sentimentos e tem como algumas vantagens o fato de compreender melhor que outros modelos a linguagem natural, responder com respostas naturais, automatizar tarefas, se adaptar a diferentes idiomas e funções de acessibilidade.

Portanto, utilizaremos o ChatGPT na análise de emoções e sentimentos, tendo em vista suas limitações e potenciais. Mostraremos como ele se diferencia de outras ferramentas de análise de sentimentos e emoções, e como se destaca nesse campo.

Compreender como os artefatos tecnológicos atuam na estrutura de funcionamento da sociedade é fundamental para que a transformação social impulsionada pela tecnologia seja realizada de forma responsável. A relação de coprodução

entre prática social e tecnologia configura uma das premissas dos Estudos de Plataforma (D'ANDRÉA, 2020), no qual esse trabalho se inclui quando considera o ChatGPT uma plataforma digital de serviços.

2.2 Metodologia

Esta pesquisa comparativa foi realizada utilizando como base o resultado da análise de textos de comentários selecionados no Twitter, Instagram e Youtube. Foram coletados 5 comentários de cada rede social, totalizando 15 conteúdos textuais.

A seleção foi realizada por critérios de conveniência, com o objetivo de identificar e selecionar conteúdos capazes de expressar sentimentos negativos, positivos e neutros, além de emoções variadas. A amostra selecionada foi considerada representativa, pois contém dados ambíguos, além dos comentários diretos e claros.

A amostra apresenta conteúdos reais, escritos por pessoas, tornando-a capaz de permitir uma avaliação rigorosa e precisa das possibilidades de análise para conteúdos em redes sociais digitais. O objetivo principal é avaliar o desempenho das tecnologias e comparar seus resultados, o que está em foco é a comparação das tecnologias computacionais de análise. A compreensão dos sentimentos ou emoções de uma determinada realidade poderá ser trabalhada em pesquisas futuras, através dos métodos aqui comparados.

Os *tweets* foram selecionados em uma pesquisa sobre “comunicação em mídias digitais”, o termo também refere-se a um curso de comunicação. Os *tweets* que foram coletados são os que estão relacionados ao curso. O foco da coleta de dados foram as opiniões dos estudantes do curso e de alunos que passaram recentemente no curso e ainda não começaram a estudar. Os comentários do YouTube foram selecionados em vídeo aulas sobre alguns *softwares* de *design*, com opiniões sobre o conteúdo do vídeo nos comentários, expressando dificuldades, dúvidas e fazendo críticas ao conteúdo do vídeo.

Para os comentários no Instagram, selecionamos publicações de universidades do nordeste, e escolhemos dentre os comentários, aqueles que possuíam alguma pergunta no texto. Algumas das perguntas realizadas nos comentários das publicações tinham características de ironia, e foram selecionadas para analisar se as ferramentas conseguem detectar o sentimento e as emoções mesmo com o conteúdo sendo utilizado para expressar o sentido oposto, caracterizando um texto mais complexo.

A análise da polaridade dos sentimentos foi feita utilizando o Flair. Como ele não tem uma base de dados em português, traduzimos os textos do português para o inglês com um algoritmo no Python automaticamente, executando o código da análise em seguida. O resultado é uma coluna com a polaridade dos textos inserida na tabela.

Para a detecção de emoções, foi utilizada a biblioteca Python NLTK, com um classificador baseado no algoritmo de Naive Bayes, que funciona como um método supervisionado de aprendizagem máquina e é usado tanto para categorização quanto para sumarização de textos em Python.

Para o treinamento do algoritmo, foi utilizado o *dataset* do ISEAR (*The International Survey On Emotion Antecedents And Reactions Dataset*), projeto que foi desenvolvido durante a década de 1990 por Klaus R. Scherer e Harald Wallbott, contendo textos rotulados com as sete emoções principais, a saber: alegria, medo, raiva, tristeza, desgosto, culpa, e vergonha, e contém aproximadamente 7000 textos rotulados.

O algoritmo em Python processa os dados do *dataset* do ISEAR e detecta padrões, relacionando palavras sumarizadas às emoções específicas. Depois, ele lê os dados da amostra que está sendo analisada e traz uma nova coluna com as emoções correspondentes para cada amostra. O *dataset* foi traduzido, sendo seu idioma original o inglês.

Os dados coletados também foram analisados com o uso do ChatGPT, em sua versão do GPT-3.5 *standard* do dia 12 de maio de 2023. O *chatbot* foi ensinado a

buscar as mesmas emoções do algoritmo em Python, aprimorando a instrução até ter um resultado satisfatório. No início da conversa, o ChatGPT foi instruído com o *prompt* “estou fazendo um artigo sobre análise de emoções em textos com o chatgpt. você poderia me ajudar fazendo a análise de alguns dados?”.

Após isso, o ChatGPT foi instruído a criar uma tabela com os dados enviados, rotulando-os com as emoções e definindo a polaridade dos sentimentos. A solicitação foi realizada ao ChatGPT em dois formatos, um agrupado e um individual, e os resultados dessas duas solicitações também foram registrados para fins comparativos. Separamos as amostras numericamente e o pedido de análise foi segmentado para apenas 3 análises por vez, com o objetivo de organizar melhor a formatação da tabela gerada.

A instrução para os dados agrupados foi: “Eu quero que você crie uma tabela com os dados que enviarei abaixo, a primeira coluna será o texto contido nos dados, rotulando eles na segunda coluna com as emoções de alegria, medo, raiva, tristeza, desgosto, culpa, e vergonha (é obrigatório que use apenas essas emoções), e na última coluna você irá definir se o sentimento do texto é positivo, negativo ou neutro”.

Para os dados enviados separadamente, o comando utilizado foi: “Eu quero que você rotule o texto abaixo com uma dessas emoções: alegria, medo, raiva, tristeza, desgosto, culpa, e vergonha, que são as emoções base da minha pesquisa científica. E também defina se a polaridade do sentimento do texto é positiva, negativa ou neutra”. Comparamos os resultados de cada tabela, buscando semelhanças e diferenças.

Quando o ChatGPT não apresentava uma resposta com essas emoções, foi utilizado o comando: “Eu quero que você rotule o texto abaixo obrigatoriamente com uma dessas emoções: alegria, medo, raiva, tristeza, desgosto, culpa, e vergonha, que são as emoções base da minha pesquisa científica. E também defina se a polaridade do sentimento do texto é positiva, negativa ou neutra”.

Os mesmos textos ainda foram analisados pelos pesquisadores, a partir de uma abordagem interpretativista com a utilização da metodologia hermenêutica,

buscando as definições de cada uma das emoções básicas e procurando identificá-las em uma proporção predominante nos textos analisados. Os resultados desse conjunto de análises foram comparados, buscando semelhanças e diferenças entre as técnicas utilizadas.

2.3 Análise dos resultados

Os resultados das análises foram estruturados em um quadro contendo a resposta obtida para a análise de emoções e para a análise de ânimo em cada uma das abordagens utilizadas: NLTK/Flair; ChatGPT Agrupado; ChatGPT Individual; Hermenêutica. O quadro 1 demonstra essa estrutura com apenas três itens da amostra.

QUADRO 1 – Extrato do quadro montado para a análise.

MENSAGEM	PYTHON NLTK/FLAIR		CHATGPT AGRUPADO		CHATGPT INDIVIDUAL		HERMENÊUTICA	
	EMOÇÃO	ÂNIMO	EMOÇÃO	ÂNIMO	EMOÇÃO	ÂNIMO	EMOÇÃO	ÂNIMO
é ótimo!! tenho aulas de editoração, fotografia, tecnologias e inovação tive só minha primeira semana mas acho que vai ser ótimo	Alegria	Positivo	Alegria	Positivo	Alegria	Positivo	Alegria	Positivo
Talvez você possa me ajudar, até agora nenhum dos youtubers especializados em Adobe Indesign não conseguiram responder ao meu problema. Tenho uma imagem e quero que o meu “texto fique sobre ela”, mas ancorada a este texto. Como devo fazer?	Desgosto	Negativo	Desgosto	Neutro	Desgosto	Negativo	Desgosto	Negativo
Afinal, terá aula ou não? Não é mais simples só postar “aulas canceladas” ou “mantidas”?	Vergonha	Negativo	Raiva	Negativo	Desgosto	Negativo	Raiva	Negativo

Fonte: Os autores.

A análise de polaridade ou ânimo demonstrou-se muito consistente entre os 4 métodos aplicados, de 15 conteúdos, 11 deram a mesma polaridade. As polaridades Positivo e Negativo foram identificadas com facilidade, e o Neutro apresentou-se de modo inconsistente entre as abordagens automatizadas, mas foi identificado da mesma forma nas respostas do ChatGPT com dados individuais e nas respostas dadas pelos pesquisadores.

Entre as respostas do ChatGPT Agrupado e a tabela ChatGPT Individual, 3 polaridades apresentaram resultados diferentes, apesar de terem sido analisadas na mesma ferramenta. Os resultados rotulados pelo Flair, em comparação com os do ChatGPT com dados agrupados, apresentaram 2 polaridades divergentes. Em comparação com a tabela com dados individuais, 3 divergiram. Apenas a tabela de dados individuais deu um resultado unânime na polaridade em comparação com a tabela dos pesquisadores. As outras duas divergiram em duas respostas diferentes, apresentando 13 resultados idênticos.

Os resultados dos métodos de detecção de emoções com as ferramentas e com a análise dos pesquisadores, quando comparados, tiveram mais respostas divergentes. Dos 15 conteúdos analisados, apenas 3 tiveram resultados consistentes nos 4 diferentes métodos de análise.

A resposta: “Trabalho a 10 anos com Corel e Photoshop, sei de cabo a rabo os dois, porem sinto necessidade de aprender illustrator por conta de conteúdo mais complexo que o corel não aguenta e facilidades em algumas ferramentas.” extraída do YouTube foi a que mais apresentou resultados distintos. NLTK/Flair classificou esse texto como Desgosto / Positivo, o GPT Agrupado classificou como Alegria / Positivo, GPT Individual desobedeceu às instruções e introduziu uma classificação não pré-determinada: Necessidade / Neutro e os pesquisadores avaliaram o trecho como Tristeza / Neutro.

A biblioteca NLTK/Flair teve pouca associação com os resultados obtidos nas outras análises do ChatGPT, tendo o mesmo resultado em 5 dos 15 casos nas 3

tabelas, e, em comparação com as respostas dos pesquisadores, 6 de 15. Essa abordagem foi a única a apresentar um resultado tão diferente dos demais. GPT Agrupado, GPT Individual e Pesquisadores apresentaram resultados semelhantes em 11 dos 15 casos analisados.

2.4 Discussão

Durante a análise pôde-se constatar que o ChatGPT leva em consideração o que já foi conversado anteriormente, então ao abrir uma nova conversa e enviando as mesmas amostras com o comando, mas sem a introdução sobre ser um projeto de pesquisa, os resultados podem ser apresentados de maneira diferente, com outras emoções.

O ChatGPT no formato de exibição web não permite a submissão de documentos, dificultando o envio de uma quantidade vasta de amostras. Apesar de criar tabelas, quando é enviado muitos dados, ele diminui o texto dentro da tabela, então houve uma necessidade de dividir a quantidade de informações enviadas para exibir o texto completo na tabela, dificultando a análise de mais de 3 ou 5 dados por vez, a depender do tamanho do texto das amostras.

O Flair se mostrou muito eficiente na análise de polaridade, assim como o ChatGPT. O NLTK como detector de emoções não apresentou resultados condizentes com os outros recursos, com exceção dos textos muito explícitos. É possível que ao utilizar uma base de treinamento menor do que a que foi utilizada no ChatGPT os resultados sejam mais precisos para textos explícitos e menos precisos para textos mais abstratos ou que trazem o sentimento imbuído em um conteúdo mais informativo ou contextualizado.

O ChatGPT, na análise de sentimentos, aparentou compreender de forma satisfatória os sentimentos das mensagens, mostrando bons resultados na classificação dos ânimos das mensagens. Em uma ocasião o ChatGPT Individual apresentou emoções diferentes do solicitado nos resultados, o que demonstra uma falha grave

na obediência às instruções e parâmetros de análise, o que implicaria no descarte do conteúdo em análise.

Nenhuma habilidade de programação é necessária para utilizar o ChatGPT, diferente das ferramentas em Python, apesar de ser desejável entender um pouco de lógica de computadores para escrever um bom comando, o que pode ser considerado um ponto positivo.

Em textos que apresentam uma contextualização a capacidade de compreensão do ChatGPT foi superior. Por exemplo, em um comentário do Youtube, o usuário da rede explica sua frustração antes de afirmar que aquele conteúdo o ajudou, o NLTK focou na explicação do problema e classificou esse conteúdo como Raiva, mas o contexto foi considerado pelos pesquisadores e pelo ChatGPT como um indicador da Alegria do usuário.

3 CONSIDERAÇÕES FINAIS

Analisamos no artigo a diferença entre ferramentas de análise de sentimentos com Python através da biblioteca NLTK / Flair, o ChatGPT, tecnologias que utilizam aprendizado profundo no campo da inteligência artificial e a análise hermenêutica que utiliza inteligência humana. Utilizando as emoções principais descritas no artigo de Schretter e Wallbot (1994) como requisitos para rotular as emoções detectadas, analisamos qual das duas tecnologias oferecem uma melhor compreensão da linguagem natural e se o ChatGPT é uma opção válida dentro dessa área.

Considerando que o ChatGPT é uma ferramenta que possui um amplo *data-set* de treinamento, treinada com uma enorme quantidade de parâmetros, seus resultados foram muito positivos. Esperava-se que o fato da rede neural não ter sido treinada especificamente para a análise de emoções e sentimentos faria com que os resultados fossem menos precisos, mas a comparação com a análise hermenêutica dos pesquisadores demonstrou o contrário.

Por se tratar de um grande modelo de linguagem ou *large language model* o ChatGPT apresenta uma maior compreensão do contexto e acaba se tornando uma ferramenta mais alinhada ao entendimento que um ser humano teria no processo de análise. Esse conjunto mais amplo de parâmetros de treinamento permitiu que o ChatGPT demonstrasse uma melhor capacidade de entender o contexto das mensagens analisadas e não apenas os *tokens* ou palavras escritas no texto.

Outros experimentos com amostras maiores podem ser realizados de forma automatizada de modo a verificar a escalabilidade dessa abordagem. O estudo constitui uma iniciativa para a compreensão de novas ferramentas de análise em mídias digitais e uma contribuição para a aplicação de novos métodos e processos de investigação.

REFERÊNCIAS

- ADAMOPOULOU, Eleni ; MOUSSIADES, Lefteris. An Overview of Chatbot Technology. **IFIP Advances in Information and Communication Technology**, v. 584, p. 373–383, 2020a. Disponível em: <<https://www.ncbi.nlm.nih.gov/pmc/articles/PMC7256567/>>. Acesso em: 13 abr. 2023.
- ADAMOPOULOU, Eleni ; MOUSSIADES, Lefteris. Chatbots: History, technology, and applications. **Machine Learning with Applications**, v. 2, 2020b. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2666827020300062>>. Acesso em: 13 abr. 2023.
- AGARWAL, Ritu ; WADHWA, Mani. Review of State-of-the-Art Design Techniques for Chatbots. **SN Computer Science**, v. 1, n. 5, 2020. Disponível em: <<https://link.springer.com/article/10.1007/s42979-020-00255-3>>. Acesso em: 30 maio 2023.
- BARRETO, J.E.F; Silva, L.P. Sistema límbico e as emoções: uma revisão anatômica. **Revista neurociências**, v. 18, n. 3, p. 386-394, 2010.
- BIRD, Steven. NLTK: the natural language toolkit. Proceedings of the COLING/ACL 2006 Interactive Presentation Sessions. Sydney, 2006.
- BORJI, Ali. A categorical archive of chatgpt failures. **arXiv:2302.03494**, 2023. Disponível em: <<https://www.sciencedirect.com/science/article/pii/S2666827020300062>>. Acesso em: 13 abr. 2023.
- BROCKMAN, G.; SUTSKEVER, I. OpenAI LP, **OpenAI**, 2019. Disponível em: <<https://openai.com/blog/openai-lp>>. Acesso em: 4 abr. 2023.

HARIRI, Walid. Unlocking the Potential of ChatGPT: A Comprehensive Exploration of its Applications. **Research Gate**. 2023. Disponível em: <https://www.researchgate.net/publication/369771657_Unlocking_the_Potential_of_ChatGPT_A_Comprehensive_Exploration_of_Its_Applications_Advantages_Limitations_and_Future_Directions_in_Natural_Language_Processing>. Acesso em: 02 jul. 2023.

TURING, A.; COPELAND, B. J. **The essential Turing: seminal writings in computing, logic, philosophy, artificial intelligence, and artificial life, plus the secrets of Enigma**. Oxford, New York: Clarendon Press ; Oxford University Press, 2004.

LUDERMIR, Teresa Bernarda. Inteligência Artificial e Aprendizado de Máquina: estado atual e tendências. **Estudos Avançados**, v. 35, n. 101, 2021.

MHLANGA, David. Open AI in education, the responsible and ethical use of ChatGPT towards lifelong learning. **Education, the Responsible and Ethical Use of ChatGPT Towards Lifelong Learning**, 2023. Disponível em: <https://papers.ssrn.com/sol3/papers.cfm?abstract_id=4354422>

KHAN, Rashid ; DAS, Anik. **Build Better Chatbots: A Complete Guide to Getting Started with Chatbots**. Berkeley, CA: Apress, 2018.

FRANCISCO, Maria de Fátima Simões. Caráter, emoção e julgamento na Retórica de Aristóteles. **Letras Clássicas**, n. 4, p. 91-108, 2000.

OPENAI. **Introducing ChatGPT**. OpenAI. Disponível em: <<https://openai.com/blog/chatgpt>>. Acesso em: 13 abr. 2023.

PIA, Jefferson da Silva; FIGUÊIREDO, João Pedro dos Anjos. **Educação emocional e prevenção à violência escolar**. 2016. Disponível em: <<https://repositorio.ufpb.br/jspui/handle/123456789/2425>>.

SCOLNICOV, Samuel. **Platão e o problema educacional**. Edições Loyola, 2006.

SCHERER, Klaus R.; WALLBOTT, Harald G. Evidence for universality and cultural variation of differential emotion response patterning. *Journal of personality and social psychology*, v. 66, n. 2, p. 310, 1994.

WANKHADE, Mayur; RAO, Annavarapu Chandra Sekhara; KULKARNI, Chaitanya. A survey on sentiment analysis methods, applications, and challenges. **Artificial Intelligence Review**, v. 55, n. 7, 2022. Disponível em: <<https://link.springer.com/article/10.1007/s10462-022-10144-1>>. Acesso em: 11 abr. 2023.

WEIZENBAUM, Joseph. ELIZA - a computer program for the study of natural language communication between man and machine. **Communications of the ACM**, v. 9, n. 1, p. 36-45, 1966. Disponível em: <<https://dl.acm.org/doi/pdf/10.1145/365153.365168>>. Acesso em: 30 maio 2023.

ZEMČÍK, Mgr. Tomáš. A Brief History of Chatbots. **DEStech Transactions on Computer Science and Engineering**, n. aicae, 2019. Disponível em: <https://www.researchgate.net/publication/336734161_A_Brief_History_of_Chatbots>. Acesso em: 13 abr. 2023.



AUTORES

Maria Eduarda Ramos Da Silva

Graduanda em Comunicação em Mídias Digitais (UFPB). Integrante do projeto de extensão Interfaces Livres. Tem interesse no campo de Processamento de Linguagem Natural (PLN) e UX/UI design.

E-mail: maria.silva12@academico.ufpb.br

iD <https://orcid.org/0009-0007-4015-1689>

Paulo Henrique Souto Maior Serrano

Professor de Comunicação em Mídias Digitais na Universidade Federal da Paraíba. Possui graduação em Comunicação Social - Jornalismo pela Universidade Federal da Paraíba (2008), mestrado em Programa de Pós-Graduação em Linguística - UFMG pela Universidade Federal de Minas Gerais (2011) e doutorado em Administração pela Universidade Federal da Paraíba (2019).

E-mail: paulo.serrano@academico.ufpb.br

iD <https://orcid.org/0000-0002-3713-5190>