

# **Uma avaliação da capacidade de Modelos de Linguagem para análise de sentimentos em um contexto de saúde mental**

**Miguel D. Henz<sup>1</sup>, Wesllei F. Heckler<sup>1</sup>, Jorge L. V. Barbosa<sup>1</sup>**

<sup>1</sup> Programa de Pós-Graduação em Computação Aplicada (PPGCA)

Universidade do Vale do Rio dos Sinos (UNISINOS)

Av. Unisinos, 950, Cristo Rei, 93022-750, São Leopoldo, RS, Brasil

{henzmiguel, weslleiheckler}@edu.unisinos.br, jbarbosa@unisinos.br

**Abstract.** Mental disorders negatively impact peoples' quality of life. These conditions manifest through sentiments such as sadness, loneliness, apathy, and fear. Thus, sentiment analysis can enhance the early identification of mental symptoms. Therefore, this article evaluates the capacity of language models based on Artificial Intelligence concerning the sentiment analysis of texts in Brazilian Portuguese. The evaluation process occurred based on a dataset of 5,000 text posts from Twitter. The caramelo-smile-2 model obtained the best performance in the experiment, reaching approximately 0.8 of precision, recall, and f1-score. The results highlight the potential of using pre-trained language models for sentiment analysis of Brazilian Portuguese texts, which can allow the utilization of these models in applications to analyze text messages of patients diagnosed with mental disorders.

**Resumo.** Transtornos mentais impactam negativamente a qualidade de vida das pessoas. A manifestação dessas condições ocorre através de sentimentos, tais como tristeza, solidão, apatia ou medo. Desta forma, a análise de sentimentos pode auxiliar na identificação prévia de sintomas mentais. Portanto, este trabalho apresenta uma avaliação sobre a capacidade de modelos de linguagem baseados em Inteligência Artificial em relação à análise de sentimentos de textos em português brasileiro. Os modelos foram avaliados através de um conjunto de dados com 5.000 postagens de texto da rede social Twitter. O modelo caramelo-smile-2 obteve o melhor desempenho no experimento, atingindo aproximadamente 0,8 nas métricas precision, recall e f1-score. Os resultados destacam o potencial de uso de modelos de linguagem pré-treinados para análise de sentimentos de textos em português brasileiro, o que pode viabilizar a utilização em aplicações para análise de mensagens de texto de pacientes diagnosticados com transtornos mentais.

## **1. Introdução**

Os transtornos mentais afetam milhões de pessoas ao redor do mundo, impactando negativamente a qualidade de vida, a produtividade e a recuperação de estresses diários [Heckler et al. 2025]. No Brasil, ansiedade e depressão são as condições mais prevalentes, atingindo em torno de 9.000 casos de ansiedade e 4.800 de depressão a cada 100.000 pessoas em 2021 [Statista 2024]. Em casos mais severos, esses transtornos podem levar

ao suicídio, que é a principal causa de morte no mundo. Dessa forma, a identificação antecipada de sinais dessas condições contribui para estratégias de prevenção de transtornos mentais [World Health Organization 2021, Heckler et al. 2022, Heckler et al. 2023].

A depressão é caracterizada por alterações no humor, expressadas através de tristeza, solidão e apatia [Beck and Alford 2008]. A ansiedade, por sua vez, consiste em experiências excessivas de medo e ansiedade, que são reações naturais dos seres humanos para situações de risco. Uma desregulação duradoura nessas reações caracteriza o transtorno de ansiedade [American Psychiatric Association 2022]. Considerando que a manifestação de transtornos mentais pode ocorrer por meio de emoções e sentimentos, a identificação desses comportamentos pode auxiliar na identificação prévia de sintomas desses transtornos.

A análise de sentimentos pode ocorrer através de Processamento de Linguagem Natural (PLN), uma área da Inteligência Artificial (IA) que compreende técnicas para processamento e análise de textos e outros tipos de dados relacionados à linguagem natural do ser humano. Essas técnicas possibilitam a criação de sistemas capazes de responder perguntas, realizar traduções entre idiomas e analisar textos [Radford et al. 2019]. Sistemas de análise de sentimentos avaliam texto ou fala, a fim de classificar o conteúdo como “positivo”, “negativo” ou “neutro” em relação aos sentimentos e emoções expressados no conteúdo [Birjali et al. 2021].

Psicólogos, terapeutas e profissionais da área de saúde mental frequentemente lidam com a interpretação de sentimentos e emoções, tarefa que, por ser subjetiva, pode ser desafiadora e passível de imprecisões. Um estudo destacou as imprecisões e subjetividade dos seres humanos em classificar sentimentos em textos [Moreira et al. 2016]. Nesse estudo, a precisão humana na classificação de sentimentos foi inferior a 50%. Técnicas computacionais baseadas em dicionários léxicos, tais como *Sentistrength*, *Sentinet* e *LIWC*, também obtiveram desempenho abaixo de 50%. Considerando esse cenário e tendo em vista as possíveis aplicações de análise de sentimentos na área de Psicologia, a pesquisa voltada à análise de sentimentos em textos mostra-se estratégica.

Com o surgimento da arquitetura *Transformers*, pesquisas relacionadas a PLN passaram a considerar modelos baseados nessa arquitetura, especialmente modelos de linguagem [Bengio et al. 2021]. Mesmo que a tradução de idiomas entre inglês e português com o Google Translator se mostre efetiva [Lopes et al. 2024], a existência de técnicas mais específicas para o português brasileiro pode potencializar a efetividade da análise de sentimentos. Portanto, este trabalho apresenta uma experimentação de análise de sentimentos em textos por meio de modelos de linguagem baseados em IA com suporte para o português brasileiro.

O artigo está dividido em cinco seções. A Seção 2 descreve os trabalhos relacionados. A Seção 3 apresenta os resultados de experimentos realizados com seis modelos de linguagem. Em seguida, a Seção 4 apresenta uma discussão sobre os resultados. Por fim, a Seção 5 aborda as considerações finais e direcionamentos para trabalhos futuros.

## 2. Trabalhos Relacionados

A identificação de trabalhos relacionados ocorreu através de uma revisão bibliográfica nas bases de artigos *IEEE Xplore*<sup>1</sup> e *Web of Science*<sup>2</sup>. Essas bases de dados indexam publicações relacionadas à computação e saúde, que são os principais temas desta pesquisa. Para a busca de trabalhos relacionados, utilizou-se uma expressão de busca de artigos gerada com base nos tópicos principais deste trabalho. A partir dos tópicos principais, foram derivados termos alternativos, os quais compõem a expressão final utilizada nas bases de artigos. A Tabela 1 apresenta os tópicos principais, os termos alternativos e a expressão final de busca.

**Tabela 1. Principais tópicos e termos alternativos da expressão de busca**

Tópicos principais	Termos alternativos
Análise de Sentimentos	(“sentiment analysis” OR “emotion analysis” OR “emotional analysis”)
	AND
Processamento de Linguagem Natural	(“natural language processing” OR “artificial intelligence” OR “large language model”)
	AND
Língua Portuguesa	“portuguese”
	AND
Conjuntos de Dados	(“dataset” OR “data” OR “corpus”)

A pesquisa de trabalhos relacionados foi realizada em fases, onde a primeira ocorreu diretamente nos motores de busca das bases de dados, utilizando a expressão de busca. Foram incluídos no conjunto inicial de artigos aqueles que contêm os termos da expressão de busca, publicados em periódicos ou conferências e escritos na língua inglesa. A filtragem inicial retornou 94 artigos da base *Web of Science* e 17 artigos da *IEEE Xplore*. As fases seguintes envolveram a filtragem dos artigos com base em quatro critérios de exclusão, que são: (i) O estudo não pode ser uma revisão da literatura ou mapeamento sistemático; (ii) O estudo não está relacionado aos temas de pesquisa, que são análise de sentimentos e processamento de linguagem natural; (iii) O estudo não está disponível como texto completo; e (iv) Artigo duplicado entre as bases de dados. Além disso, um trabalho [Moreira et al. 2016] foi adicionado por conveniência e aderência à pesquisa. Esse trabalho foi encontrado por meio de uma busca no Google Scholar.

Na segunda fase, realizou-se a leitura do título, palavras-chave e resumo dos trabalhos, removendo os artigos enquadrados em, pelo menos, um dos critérios de exclusão. Nessa fase, 12 artigos da *IEEE Xplore* e 61 da *Web of Science* foram aceitos para a fase seguinte. O foco da terceira fase foi a leitura da introdução e conclusão dos trabalhos selecionados, a fim de aprofundar o entendimento sobre as pesquisas. Nessa etapa, 8 artigos da *IEEE Xplore* e 33 da *Web of Science* foram aceitos. A última etapa consistiu na remoção de duplicados e na leitura completa dos trabalhos selecionados. A Tabela 2

<sup>1</sup><https://ieeexplore.ieee.org/Xplore/home.jsp>

<sup>2</sup><https://login.webofknowledge.com/>

apresenta a lista final dos 16 trabalhos aceitos na fase final, apresentando a referência, o título e o local de publicação desses trabalhos.

**Tabela 2. Trabalhos Relacionados**

ID	Referência
1	[Moreira et al. 2016] Análise de Sentimentos: Comparando o uso de ferramentas e a análise humana (Simpósio Brasileiro de Sistemas de Informação (SBSI))
2	[Corrêa et al. 2017] PELESent: Cross-Domain Polarity Classification Using Distant Supervision (Brazilian Conference on Intelligent Systems (BRACIS))
3	[Sakiyama et al. 2019] Twitter breaking news detector in the 2018 Brazilian presidential election using word embeddings and convolutional neural networks (International Joint Conference on Neural Networks (IJCNN))
4	[Carosia et al. 2020] Analyzing the Brazilian Financial Market through Portuguese Sentiment Analysis in Social Media (Applied Artificial Intelligence)
5	[da Silva et al. 2020] Sentiment Parser based on X-Bar Theory to Brazilian Portuguese (International Conference on Computing, Electronics & Communications Engineering (iCCECE))
6	[Cardoso et al. 2021] Comparison between Different Approaches to Sentiment Analysis in the Context of the Portuguese Language (Iberian Conference on Information Systems and Technologies (CISTI))
7	[Martins et al. 2021] A sentiment analysis approach to increase authorship identification (Expert Systems)
8	[Souza and Baptista de Oliveira e Souza Filho 2021] Sentiment Analysis on Brazilian Portuguese User Reviews (IEEE Latin American Conference on Computational Intelligence (LA-CCI))
9	[Chaves et al. 2022] BPA: A Multilingual Sentiment Analysis Approach based on BiLSTM (International Conference on Enterprise Information Systems (ICEIS))
10	[Marques et al. 2022] Sentiment Analysis in Understanding the Potential of Online News in the Public Health Crisis Response (International Journal of Environmental Research and Public Health)
11	[Carvalho et al. 2023] The Importance of Context for Sentiment Analysis in Dialogues (IEEE Access)
12	[da Silva et al. 2023] Sentiment Gradient-Improving Sentiment Analysis with Entropy Increase (Iberoamericana Journal of Artificial Intelligence)
13	[Almeida et al. 2024] Optimizing Sentiment Analysis Models for Customer Support: Methodology and Case Study in the Portuguese Retail Sector (Journal of Theoretical and Applied Electronic Commerce Research)
14	[Branco et al. 2024] Sentiment Analysis in Portuguese Restaurant Reviews: Application of Transformer Models in Edge Computing (Electronics)
15	[Lopes et al. 2024] Analysis of the hikikomori phenomenon - an international infodemiology study of Twitter data in Portuguese (BMC Public Health)
16	[Raychowdhury et al. 2024] Optimizing Multilingual Sentiment Analysis in Low-Resource Languages with Adaptive Pretraining and Strategic Language Selection (International Conference on Computing and Machine Intelligence (ICMI))

Em relação aos trabalhos relacionados, apenas dois utilizaram modelos de linguagem para análise de sentimentos. Essas pesquisas exploraram o modelo BERTimbau [Branco et al. 2024, Chaves et al. 2022]. O restante dos trabalhos explorou técnicas tradicionais de Aprendizado de Máquina, tais como *Naïve Bayes*, *Support Vector Machines*, *Random Forest* e *k-nearest neighbor* [da Silva et al. 2020, Cardoso et al. 2021, Carosia et al. 2020, Sakiyama et al. 2019]. Considerando esta lacuna de pesquisa, o presente artigo difere dos demais publicados na literatura ao validar a viabilidade de utilizar diferentes modelos de linguagem pré-treinados, incluindo um *Large Language Model*, para a tarefa de análise de sentimentos em textos.

### 3. Avaliação e Resultados

Esta seção aborda os métodos de avaliação e os resultados obtidos nesta pesquisa. Inicialmente, esta seção apresenta a metodologia utilizada para selecionar os modelos de linguagem, tratar os dados e mapear os resultados, bem como o conjunto de dados usado para a experimentação. Por fim, os resultados obtidos são apresentados, a fim de demonstrar a capacidade dos modelos de linguagem explorados.

### 3.1. Metodologia de avaliação dos modelos de linguagem

O método de avaliação envolveu quatro fases. Primeiramente, houve a seleção dos modelos para os experimentos através da plataforma *Hugging Face*<sup>3</sup>, sendo selecionados modelos de linguagem capazes de gerar ou classificar textos (*text-2-text generation* ou *text classification*). Essa plataforma disponibiliza um repositório de modelos de linguagem, no qual membros da comunidade podem registrar modelos proprietários. Em relação aos modelos com habilidades de classificação de textos, foram considerados aqueles que possuíam suporte para classificar textos entre “positivo”, “negativo” ou “neutro”. Os modelos selecionados foram: *caramelo-smile-2* [Adilmar Coelho Dantas 2025], *clf-sentimentos-cmts* [Bluhm 2025], *distilbert-base-multilingual-cased-sentiments-student* [Yuan 2025], *multilingual-sentiment-analysis* [TabularisAI 2025] e *distilbert-base-uncased-finetuned-sst2-pt* [Wang 2025]. Além disso, também foi considerado por conveniência o modelo *GPT-4o-mini* [OpenAI 2024]. Esta pesquisa utilizou versões pré-treinadas dos modelos mencionados, não realizando nenhum treinamento ou ajuste fino adicional nesses modelos.

Na segunda fase, realizou-se uma pesquisa sobre conjuntos de dados rotulados com pares de textos e classificações, considerando as 3 classes esperadas. Nessa pesquisa, foi identificado um conjunto de dados de postagens de texto da rede social Twitter (agora conhecida como X) [Kaggle 2025]. Apesar de não ser recente, esse conjunto foi o mais atual encontrado que apresentava as três classes desejadas. O conjunto de dados contém 5.000 postagens de texto coletadas da rede social no período entre 01/08/2018 e 20/10/2018. Além dos textos, o conjunto de dados também contém data e hora da publicação e uma classificação para cada texto, considerando as classes “positivo”, “negativo” e “neutro”. Assim, este conjunto foi utilizado pela sua conveniência e versatilidade dos textos.

A elaboração desse conjunto de dados considerou o método de supervisão distante [Go et al. 2009]. Esse método consiste na coleta de textos de redes sociais, como o Twitter, utilizando *emoticons* positivos e negativos como rótulos automáticos de sentimento. Assim, postagens contendo *emoticons* que indicam felicidade, como “:)”, foram consideradas positivas (Classe 1), enquanto aquelas que indicam tristeza, como “:(”, foram consideradas negativas (Classe 0). Para a classe neutra (Classe 2), foi utilizada a abordagem que emprega textos de contas populares de notícias e *hashtags* específicas associadas a conteúdos objetivos e não opinativos [Kouloumpis et al. 2021]. A Tabela 3 apresenta um exemplo de cada classe retirado do conjunto de dados explorado.

**Tabela 3. Exemplos de textos retirados do conjunto de dados explorado**

<b>Texto</b>	<b>Classe</b>
tudo se acertando aqui em casa :)	1
Odeio quando mesmo cheia de vontade de fazer algo o desânimo me vence :(	0
Do ‘tijolão’ ao smartphone: a evolução dos celulares nos últimos 20 anos. <a href="https://t...">https://t...</a>	2

A terceira fase consistiu em verificar as respostas fornecidas (*outputs*) pelos modelos de linguagem selecionados, a fim de criar uma interpretação lógica para elas, mape-

<sup>3</sup><https://huggingface.co/>

ando os retornos para as classes “positivo”, “negativo” ou “neutro”. Para isso, analisou-se se essas palavras estavam presentes na resposta ou se havia uma forma específica de nomear esses sentimentos. Após essa verificação, as respostas foram convertidas para o formato utilizado pelo conjunto de dados inicial, onde a classe “0” representa “negativo”, “1” representa “positivo” e “2” representa “neutro”. As classificações foram organizadas em uma lista para cada modelo de linguagem.

```
template =[  
    "Classifique o texto entre neutro, positivo e negativo",  
    "utilize somente as palavras neutro, positivo e negativo",  
    "Exemplos:",  
    "texto: Gostei da viagem",  
    "classificação: positivo",  
    "texto: O filme foi okay",  
    "classificação: neutro",  
    "texto: Não gostei da janta",  
    "classificação: negativo",  
    "texto: www.google.com",  
    "classificação: neutro",  
    "texto: {texto}",  
    "classificação:"  
]
```

**Figura 1.** *Prompt de orientação para o modelo de linguagem *GPT-4o-mini*, criado a partir da abordagem *Few-Shot Prompting**

Em função do modelo *GPT-4o-mini* ter uma característica de seguir instruções, foi desenvolvida uma instrução (do inglês *prompt*) com as regras que o modelo deveria utilizar para classificar as mensagens submetidas. A estratégia para elaboração dessas instruções considerou a abordagem *Few-Shot Prompting* [Brown et al. 2020]. Essa abordagem consiste em fornecer, além de orientações gerais sobre a análise de sentimentos, alguns exemplos de textos já classificados para que o modelo de linguagem entenda como deve se comportar em relação a essa tarefa. A Figura 1 ilustra as orientações passadas para esse modelo.

A Tabela 4 apresenta exemplos de textos submetidos a 3 dos modelos selecionados, sendo eles o *caramelo-smile-2*, o *distilbert-base-uncased-finetuned-sst2-pt* e o *GPT-4o-mini*. A tabela mostra o comportamento dos modelos em relação às mesmas 3 mensagens submetidas para cada um deles, representando cada uma das classes analisadas (“positivo”, “negativo” ou “neutro”). Da esquerda para a direita, as colunas representam o modelo, o texto analisado, a resposta original retornada pelo modelo e a resposta tratada para análise dos resultados.

Por fim, os modelos passaram por um processo de validação, onde foram extraídas as métricas *precision*, *recall* e *f1-score*. Nesta etapa, foi utilizada a linguagem de programação *Python*<sup>4</sup>. A biblioteca *scikit-learn*<sup>5</sup> foi usada para auxiliar na extração das métricas. A análise dos resultados foi realizada com auxílio da biblioteca *Pandas*<sup>6</sup>. Para a interação com o modelo *GPT-4o-mini*, foi considerada a biblioteca *LangChain*<sup>7</sup>.

<sup>4</sup><https://www.python.org/>

<sup>5</sup><https://scikit-learn.org/>

<sup>6</sup><https://pandas.pydata.org/>

<sup>7</sup><https://www.langchain.com/>


**Tabela 4. Exemplo de classificação de sentimentos realizada pelos modelos**

Modelo	Texto analisado	Resposta Modelo	Resposta Tratada
caramelo-smile-2	O dia de hoje foi bom, obrigada :)	Positive	1
	Comi um misto quente e ainda tô com fome :((	Negative	0
	Produção de petróleo do Brasil cai em junho para 2,59 mi de bpd, diz ANP <a href="https://t.co/zJXTlpBbDW">https://t.co/zJXTlpBbDW</a>	Neutral	2
distilbert-base-uncased-finetuned-sst2-pt	O dia de hoje foi bom, obrigada :)	label_1	1
	Comi um misto quente e ainda tô com fome :((	label_0	0
	Produção de petróleo do Brasil cai em junho para 2,59 mi de bpd, diz ANP <a href="https://t.co/zJXTlpBbDW">https://t.co/zJXTlpBbDW</a>	label_0	0
GPT-4o-mini	o dia de hoje foi bom, obrigada :)	classificação: positivo	1
	comi um misto quente e ainda to com fome :((	classificação: negativo	0
	Produção de petróleo do Brasil cai em junho para 2,59 mi de bpd, diz ANP <a href="https://t.co/zJXTlpBbDW">https://t.co/zJXTlpBbDW</a>	classificação: neutro	2

Para os demais modelos foi utilizada a biblioteca *transformers*<sup>8</sup> com a tarefa de análise de sentimentos (*sentiment-analysis*).

### 3.2. Resultados

A Figura 2 apresenta os resultados obtidos pelos modelos através das métricas *precision*, *recall* e *f1-score*. Para todas as métricas, quanto maior o valor, melhor o modelo em relação à métrica analisada. Desta forma, é possível comparar o desempenho obtido entre os modelos de linguagem explorados.



**Figura 2. Métricas de desempenho obtidas pelos modelos de linguagem durante o processo de experimentação**

O modelo *caramelo-smile-2* [Adilmar Coelho Dantas 2025] obteve o melhor desempenho no experimento realizado, atingindo aproximadamente 0.8 em todas as

<sup>8</sup><https://huggingface.co/docs/transformers/index>

métricas analisadas. O segundo melhor modelo foi o *GPT-4o-mini* [OpenAI 2024], que obteve valores de aproximadamente 0.7 em cada métrica. O terceiro melhor modelo foi o *clf-sentimentos-cmts* [Bluhm 2025], com precisão de aproximadamente 0.7, mas com *recall* e *f1-score* abaixo de 0.6.

Nesse sentido, o modelo com desempenho positivo mais estável foi o *caramelo-smile-2*. O *clf-sentimentos-cmts* registrou a segunda maior precisão e o *GPT-4o-mini* destacou-se como o mais estável após o *caramelo-smile-2*. Por outro lado, os modelos *distilbert-base-multilingual-cased-sentiments-student* [Yuan 2025], *multilingual-sentiment-analysis* [TabularisAI 2025] e *distilbert-base-uncased-finetuned-sst2-pt* [Wang 2025] apresentaram desempenho abaixo do esperado, com métricas abaixo de 0.42.

Os modelos *multilingual-sentiment-analysis*, *distilbert-base-uncased-finetuned-sst2-pt* e *distilbert-base-multilingual-cased-sentiments-student* são baseados no modelo *distilBERT*, uma versão 60% menor e que mantém 95% da eficiência do BERT [Hugging Face 2025a]. O *clf-sentimentos-cmts* é uma adaptação de *XLM-RoBERTa*, um modelo treinado em mais de 100 idiomas [Hugging Face 2025b]. O modelo *caramelo-smile-2* não especifica qual foi o seu modelo de base.

#### 4. Discussão

Ao avaliar a capacidade dos modelos, o *caramelo-smile-2* [Adilmar Coelho Dantas 2025] demonstrou um desempenho notável, tendo em vista que não houve treinamento prévio dos modelos no conjunto de dados utilizado [Kouloumpis et al. 2021]. Além disso, esse modelo atingiu desempenho similar aos modelos *BERT* e *BiLSTM* propostos por trabalhos relacionados para análise de sentimentos em comentários de clientes sobre restaurantes [Branco et al. 2024] e para conjuntos de dados multilíngue independentes de domínio [Chaves et al. 2022].

Portanto, estes resultados mostram um potencial deste modelo, que pode ser explorado para a utilização em aplicações que envolvam análise de sentimentos como, por exemplo, a análise de mensagens de pacientes diagnosticados com transtornos mentais. Além do desempenho satisfatório, a utilização desse modelo de linguagem pré-treinado também elimina a necessidade de treinamento de um novo modelo. Desta forma, o modelo agiliza a exploração e prototipação de novos sistemas para análise de sentimentos, já que o treinamento de modelos pode demandar custos financeiros, computacionais e cronológicos significativos.

Por fim, considerando o custo para o treinamento de modelos, é importante ressaltar que outras técnicas de Aprendizado de Máquina podem ser suficientes dependendo da atividade a ser realizada, como, por exemplo, o uso de *Random Forest* para a leitura de dados tabulares [Grinsztajn et al. 2022]. Essencialmente, os modelos de linguagem são treinados para processar e gerar sequências de textos sem estruturas bem definidas, o que pode prejudicar a lógica de processamento de dados estruturados.

#### 5. Conclusão

Este artigo apresentou uma comparação de modelos de linguagem para análise de sentimentos de textos com o idioma português brasileiro. Considerando a limitação de pesquisas na área, este estudo explorou diferentes modelos de linguagem pré-treinados, a fim

de avaliar a capacidade desses modelos para análise de sentimentos. Embora este estudo não seja exaustivo, através dos resultados desta pesquisa foi possível observar que o modelo *caramelo-smile-2* apresenta desempenho relevante para analisar textos em português brasileiro, viabilizando a utilização do modelo em diferentes domínios.

Por fim, estudos complementares podem ser realizados com vistas à continuidade desta pesquisa em relação à análise de sentimentos, tais como: (i) explorar diferentes modelos de linguagem, como versões multilíngue, modelos genéricos e especializados para domínios específicos; (ii) investigar o desempenho dos modelos validados nesta pesquisa em conjuntos de dados de textos de diferentes domínios, incluindo outras redes sociais e aplicativos, a fim de validar a capacidade de generalização dos modelos; e (iii) analisar o desempenho de modelos de linguagem ao processar dados de diferentes domínios além de textos, como dados de sensores, comportamentos em redes sociais e fenótipos digitais.

## Agradecimentos

Os autores agradecem ao Conselho Nacional de Desenvolvimento Científico e Tecnológico (CNPq), à Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) – Código de Financiamento 001, e à Universidade do Vale do Rio dos Sinos (Unisinos) pelo apoio ao desenvolvimento deste trabalho.

## Referências

- Adilmar Coelho Dantas (2025). *caramelo-smile* (revision 2707a19). doi: <https://doi.org/10.57967/hf/2061>. Disponível em: <https://huggingface.co/Adilmar/caramelo-smile>. Acessado em: 24-02-2025.
- Almeida, C., Castro, C., Leiva, V., Braga, A. C., and Freitas, A. (2024). Optimizing sentiment analysis models for customer support: Methodology and case study in the portuguese retail sector. *Journal of Theoretical and Applied Electronic Commerce Research*, 19(2):1493–1516. doi: <http://doi.org/10.3390/jtaer19020074>.
- American Psychiatric Association (2022). *Diagnostic and Statistical Manual of Mental Disorders - Text Revision (DSM-5-TR)*. American Psychiatric Association Publishing, 5th edition. doi: <http://dx.doi.org/10.1176/appi.books.9780890425787>.
- Beck, A. T. and Alford, B. A. (2008). *Depression*. University of Pennsylvania Press, Baltimore, MD, 2nd edition.
- Bengio, Y., Lecun, Y., and Hinton, G. (2021). Deep learning for ai. *Communications of the ACM*, 64(7):58–65. doi: <http://dx.doi.org/10.1145/3448250>.
- Birjali, M., Kasri, M., and Beni-Hssane, A. (2021). A comprehensive survey on sentiment analysis: Approaches, challenges and trends. *Knowledge-Based Systems*, 226:107134. doi: <http://dx.doi.org/10.1016/j.knosys.2021.107134>.
- Bluhm, T. D. F. (2025). *clf-sentimentos-cmts*. Disponível em: <https://huggingface.co/tbluhm/clf-sentimentos-cmts>. Acessado em: 24-02-2025.
- Branco, A., Parada, D., Silva, M., Mendonca, F., Mostafa, S. S., and Morgado-Dias, F. (2024). Sentiment analysis in portuguese restaurant reviews: Application of transformer models in edge computing. *Electronics*, 13(3). doi: <http://doi.org/10.3390/electronics13030589>.

- Brown, T. B., Mann, B., Ryder, N., Subbiah, M., Kaplan, J., Dhariwal, P., Neelakantan, A., Shyam, P., Sastry, G., Askell, A., Agarwal, S., Herbert-Voss, A., Krueger, G., Henighan, T., Child, R., Ramesh, A., Ziegler, D. M., Wu, J., Winter, C., Hesse, C., Chen, M., Sigler, E., Litwin, M., Gray, S., Chess, B., Clark, J., Berner, C., McCandlish, S., Radford, A., Sutskever, I., and Amodei, D. (2020). Language models are few-shot learners. doi: <http://doi.org/10.48550/ARXIV.2005.14165>.
- Cardoso, M. H., Maria da Rocha Fernandes, A., Marin, G., Quietinho Leithardt, V. R., and Crocker, P. (2021). Comparison between different approaches to sentiment analysis in the context of the portuguese language. In *16th Iberian Conference on Information Systems and Technologies (CISTI)*, pages 1–6. doi: <http://doi.org/10.23919/CISTI52073.2021.9476501>.
- Carosia, A. E. O., Coelho, G. P., and Silva, A. E. A. (2020). Analyzing the brazilian financial market through portuguese sentiment analysis in social media. *Applied Artificial Intelligence*, 34(1):1–19. doi: <http://doi.org/10.1080/08839514.2019.1673037>.
- Carvalho, I., Oliveira, H. G., and Silva, C. (2023). The importance of context for sentiment analysis in dialogues. *IEEE Access*, 11:86088–86103. doi: <https://doi.org/10.1109/ACCESS.2023.3304633>.
- Chaves, I. C., Martins, A. D. F., Praciano, F. D. B. S., Brito, F. T., Monteiro, J. M., and Machado, J. C. (2022). Bpa: A multilingual sentiment analysis approach based on bilstm. In Filipe, J., Smialek, M., Brodsky, A., and Hammoudi, S., editors, *Proceedings of the 24th International Conference on Enterprise Information Systems (ICEIS)*, volume 1, pages 553–560. INSTICC, SCITEPRESS - Science and Technology Publications. doi: <https://doi.org/10.5220/0011071400003179>.
- Corrêa, E. A., Marinho, V. Q., dos Santos, L. B., Fe C. Bertaglia, T., Treviso, M. V., and Brum, H. B. (2017). Pelesent: Cross-domain polarity classification using distant supervision. In *2017 Brazilian Conference on Intelligent Systems (BRACIS)*, pages 49–54. doi: <http://doi.org/10.1109/BRACIS.2017.45>.
- da Silva, A. N., de Souza, O., and de Souza, J. N. (2020). Sentiment parser based on x-bar theory to brazilian portuguese. In *2020 International Conference on Computing, Electronics Communications Engineering (iCCECE)*, pages 166–171. doi: <http://doi.org/10.1109/iCCECE49321.2020.9231145>.
- da Silva, F. C. D., Garcia, A. C. B., and Siqueira, S. W. M. (2023). Sentiment gradient-improving sentiment analysis with entropy increase. *Inteligencia Artificial - Iberoamericana Journal of Artificial Intelligence*, 26(71):114–130. doi: <http://doi.org/10.4114/intartif.vol26iss71pp114-130>.
- Go, A., Bhayani, R., and Huang, L. (2009). Twitter sentiment classification using distant supervision. In *Proceedings of the International Conference on Machine Learning*. Disponível em: <https://www-cs.stanford.edu/people/alecmgo/papers/TwitterDistantSupervision09.pdf>. Acessado em: 24-02-2025.
- Grinsztajn, L., Oyallon, E., and Varoquaux, G. (2022). Why do tree-based models still outperform deep learning on tabular data? doi: <http://doi.org/10.48550/ARXIV.2207.08815>.

- Heckler, W. F., de Carvalho, J. V., and Barbosa, J. L. V. (2022). Machine learning for suicidal ideation identification: A systematic literature review. *Computers in Human Behavior*, 128.
- Heckler, W. F., Feijó, L. P., de Carvalho, J. V., and Barbosa, J. L. V. (2023). Thoth: An intelligent model for assisting individuals with suicidal ideation. *Expert Systems with Applications*, 233:120918.
- Heckler, W. F., Feijó, L. P., de Carvalho, J. V., and Barbosa, J. L. V. (2025). Digital phenotyping for mental health based on data analytics: A systematic literature review. *Artificial Intelligence in Medicine*, 163:103094.
- Hugging Face (2025a). Distilbert model documentation. Disponível em: [https://huggingface.co/docs/transformers/model\\_doc/distilbert](https://huggingface.co/docs/transformers/model_doc/distilbert). Acessado em: 24-02-2025.
- Hugging Face (2025b). Xlm-roberta model documentation. Disponível em: [https://huggingface.co/docs/transformers/model\\_doc/xlm-roberta](https://huggingface.co/docs/transformers/model_doc/xlm-roberta). Acessado em: 24-02-2025.
- Kaggle (2025). Portuguese tweets for sentiment analysis. Disponível em: <https://www.kaggle.com/datasets/augustop/portuguese-tweets-for-sentiment-analysis/data>. Acessado em: 24-02-2025.
- Kouloumpis, E., Wilson, T., and Moore, J. (2021). Twitter Sentiment Analysis: The Good the Bad and the OMG! *Proceedings of the International AAAI Conference on Web and Social Media*, 5(1):538–541. doi: <http://dx.doi.org/10.1609/icwsm.v5i1.14185>.
- Lopes, F. C., da Costa, M. P., Fernandez-Lazaro, I. C., Lara-Abelenda, F. J., Pereira-Sanchez, V., Teo, A. R., and Alvarez-Mon, M. A. (2024). Analysis of the hikikomori phenomenon - an international infodemiology study of twitter data in portuguese. *BMC Public Health*, 24(1). doi: <http://doi.org/10.1186/s12889-023-17617-0>.
- Marques, T., Cezario, S., Lacerda, J., Pinto, R., Silva, L., Santana, O., Ribeiro, A. G., Cruz, A. S., Miranda, A. E., Cadaxa, A., Nunez, L. S., Oliveira, H. G., Atun, R., and Valentim, R. (2022). Sentiment analysis in understanding the potential of online news in the public health crisis response. *International Journal of Environmental Research and Public Health*, 19(24). doi: <http://doi.org/10.3390/ijerph192416801>.
- Martins, R., Almeida, J. J., Henriques, P., and Novais, P. (2021). A sentiment analysis approach to increase authorship identification. *Expert Systems*, 38(5). doi: <http://doi.org/10.1111/exsy.12469>.
- Moreira, V. D. S., Siqueira, S. W., Andrade, L., and Pimentel, M. (2016). Análise de sentimentos: Comparando o uso de ferramentas e a análise humana. In *Anais do Simpósio Brasileiro de Sistemas de Informação (SBSI)*, SBSI 2016, page 441–448. Sociedade Brasileira de Computação.
- OpenAI (2024). Gpt-4o mini: Modelo de linguagem multimodal compacto. Disponível em: <https://openai.com/index/gpt-4o-mini-advancing-cost-efficient-intelligence/>. Acessado em: 24-02-2025.

- Radford, A., Wu, J., Child, R., Luan, D., Amodei, D., and Sutskever, I. (2019). Language Models are Unsupervised Multitask Learners. Technical report, OpenAI.
- Raychowdhary, N., Das, A., Bhattacharya, S., Dozier, G., and Seals, C. D. (2024). Optimizing multilingual sentiment analysis in low-resource languages with adaptive pre-training and strategic language selection. In Abdalgawad, A., Jamil, A., and Hameed, A., editors, *IEEE 3rd International Conference on Computing and Machine Intelligence (ICMI)*. IEEE. doi: <http://doi.org/10.1109/ICMI60790.2024.10585876>.
- Sakiyama, K. M., Silva, A. Q. B., and Matsubara, E. T. (2019). Twitter breaking news detector in the 2018 brazilian presidential election using word embeddings and convolutional neural networks. In *International Joint Conference on Neural Networks (IJCNN)*, pages 1–8. doi: <http://doi.org/10.1109/IJCNN.2019.8852394>.
- Souza, F. D. and Baptista de Oliveira e Souza Filho, J. (2021). Sentiment analysis on brazilian portuguese user reviews. In *IEEE Latin American Conference on Computational Intelligence (LA-CCI)*, pages 1–6. doi: <http://doi.org/10.1109/LA-CCI48322.2021.9769838>.
- Statista (2024). Prevalence of mental health conditions in Brazil as of 2022, by selected category. Disponível em: <https://www.statista.com/statistics/1337966/prevalence-mental-health-conditions-brazil/#statisticContainer>. Acessado em: 24-02-2025.
- TabularisAI (2025). multilingual-sentiment-analysis. Disponível em: <https://huggingface.co/tabularisai/multilingual-sentiment-analysis>. Acessado em: 24-02-2025.
- Wang, R. (2025). distilbert-base-uncased-finetuned-sst2-pt. Disponível em: <https://huggingface.co/rwang5688/distilbert-base-uncased-finetuned-sst2-pt>. Acessado em: 24-02-2025.
- World Health Organization (2021). Mental Health Action Plan 2013-2030 flyer: what Member States can do. Disponível em: [https://cdn.who.int/media/docs/default-source/campaigns-and-initiatives/world-mental-health-day/2021/mental\health\\\_action\\\_plan\\\_flyer\\\_member\\\_states.pdf?sfvrsn=b420b6f1\&download=true](https://cdn.who.int/media/docs/default-source/campaigns-and-initiatives/world-mental-health-day/2021/mental\health\_action\_plan\_flyer\_member\_states.pdf?sfvrsn=b420b6f1\&download=true). Acessado em: 24-02-2025.
- Yuan, L. X. (2025). distilbert-base-multilingual-cased-sentiments-student. Disponível em: <https://huggingface.co/lxyuan/distilbert-base-multilingual-cased-sentiments-student>. Acessado em: 24-02-2025.