

## RELATO DE EXPERIÊNCIA

### Modelos BERT aplicados à análise de sentimentos

**Vitor Amadeu Souza**<sup>1</sup>

1 – UniFOA, Centro Universitário de Volta Redonda, Volta Redonda, RJ.

[vitor.amadeu@foa.org.br](mailto:vitor.amadeu@foa.org.br)

<https://orcid.org/0009-0002-1857-6799>

**Resumo:** Este artigo apresenta a implementação e avaliação de uma solução de análise de sentimento para textos em português utilizando um modelo multilíngue baseado em BERT (Bidirectional Encoder Representations from Transformers). A metodologia empregada utiliza o pipeline de análise de sentimento da biblioteca Transformers da Hugging Face, com o modelo pré-treinado "nlptown/bert-base-multilingual-uncased-sentiment". Foram analisadas quatro frases em português com diferentes polaridades emocionais para demonstrar a eficácia do modelo. Os resultados obtidos evidenciam a capacidade do modelo em categorizar corretamente textos positivos, negativos e neutros, atribuindo scores de confiança condizentes com a intensidade do sentimento expresso. A pesquisa contribui para o avanço das aplicações de Processamento de Linguagem Natural (PLN) em língua portuguesa, especialmente no contexto de análise de opinião e mineração de sentimentos em textos.

**Palavras-chave:** Análise de Sentimento. BERT. Processamento de Linguagem Natural. PLN. Transformers. Aprendizado de Máquina.

## INTRODUÇÃO


A análise de sentimento, também conhecida como mineração de opinião, é uma área do Processamento de Linguagem Natural (PLN) dedicada à identificação e extração de opiniões, sentimentos e subjetividade em textos (LIU, 2020). Esta técnica tem se tornado cada vez mais relevante em diversas aplicações, como monitoramento de mídias sociais, análise de feedback de clientes, pesquisas de mercado e sistemas de recomendação (GUPTA, 2022).

Com o desenvolvimento de modelos de linguagem baseados em arquiteturas Transformer, especialmente o BERT (Bidirectional Encoder Representations from Transformers) introduzido por Devlin et al. (2019), houve um avanço significativo na capacidade de compreensão contextual de textos por sistemas computacionais. O BERT revolucionou o PLN ao implementar um mecanismo de atenção bidirecional que permite uma compreensão mais profunda das relações entre palavras em um texto, superando limitações de modelos anteriores (ROGERS; KOVALEVA; RUMSHISKY, 2020).

Apesar dos progressos significativos em análise de sentimento para o idioma inglês, idiomas como o português ainda enfrentam desafios devido à menor disponibilidade de recursos e modelos específicos (SOUZA; NOGUEIRA; LOTUFO, 2020). Neste contexto, modelos multilíngues como o BERT surgem como alternativas promissoras para superar estas limitações, permitindo transferência de conhecimento entre idiomas (PIRES; SCHLINGER; GARRETTE, 2019).

Este trabalho tem como objetivo avaliar a eficácia de um modelo BERT multilíngue pré-treinado na tarefa de análise de sentimento em textos em português. Utilizamos o modelo "nlptown/bert-base-multilingual-uncased-sentiment" disponibilizado pela plataforma Hugging Face, que foi treinado para classificar textos em cinco níveis de sentimento, variando de muito negativo a muito positivo. A implementação é realizada através da biblioteca Transformers, que facilita o uso de modelos de estado da arte em PLN.

A presente pesquisa se justifica pela crescente demanda por ferramentas de análise de sentimento em português, especialmente em contextos empresariais para monitoramento de reputação de marca, análise de opinião do consumidor e inteligência competitiva. Além disso, contribui para a literatura ao demonstrar a



aplicabilidade e adaptabilidade de modelos multilíngues baseados em BERT para o idioma português.

### **METODOLOGIA**

O desenvolvimento seguiu uma abordagem experimental, com foco na aplicação e avaliação do modelo em um conjunto selecionado de frases em português com diferentes características emocionais. Para a implementação do sistema, utilizamos a biblioteca Transformers desenvolvida pela Hugging Face, que oferece interfaces simplificadas para utilização de modelos de PLN no estado da arte. O modelo escolhido foi o "nlptown/bert-base-multilingual-uncased-sentiment", desenvolvido especificamente para análise de sentimento em múltiplos idiomas, incluindo o português.

O BERT multilíngue foi treinado com 104 idiomas diferentes, utilizando a técnica de modelagem de linguagem mascarada (Masked Language Modeling) e predição da próxima sentença (Next Sentence Prediction), conforme descrito por Devlin et al. (2019). O modelo possui aproximadamente 110 milhões de parâmetros, distribuídos em 12 camadas de codificação com 12 cabeçotes de atenção cada e 768 dimensões para representação vetorial.

A implementação do sistema seguiu os seguintes passos: (1) instalação da biblioteca Transformers através do gerenciador de pacotes pip; (2) importação das dependências necessárias; (3) carregamento do pipeline de análise de sentimento com o modelo e tokenizador especificados; (4) definição de um conjunto de frases em português para teste; e (5) aplicação do modelo para análise de sentimento em cada frase, com posterior exibição dos resultados. O conjunto de frases para teste foi composto por quatro exemplos em português, selecionados para representar diferentes polaridades emocionais apresentadas na Tabela 1.

Tabela 1 – Frases usadas nas análises de sentimento

Eu amo esse filme, é incrível!
Esse restaurante é horrível, nunca mais volto.
O dia está bonito hoje.
Não gostei muito do atendimento, mas a comida era boa.

Fonte: O Autor

Para cada frase, o modelo fornece uma classificação de sentimento (label) e um score de confiança. As classificações possíveis variam de 1 a 5 estrelas, onde 1 representa um sentimento muito negativo e 5 um sentimento muito positivo. O score de confiança é um valor entre 0 e 1 que indica o grau de certeza do modelo em sua classificação.

É importante ressaltar que, diferentemente de abordagens tradicionais que requerem pré-processamento extensivo (como remoção de stopwords, stemming ou lematização), os modelos baseados em BERT possuem seu próprio tokenizador que segmenta o texto em subpalavras, preservando maior parte da informação semântica e morfológica original. Isso representa uma vantagem significativa em termos de preservação de contexto e significado, especialmente para idiomas morfológicamente ricos como o português (SOUZA; NOGUEIRA; LOTUFO, 2020).

A avaliação dos resultados foi realizada de forma qualitativa, analisando a coerência entre a classificação atribuída pelo modelo e o sentimento esperado para cada frase, considerando também o score de confiança como indicador da robustez da classificação.

O código-fonte desta implementação está disponível no link: [https://github.com/vitor-souza-ime/pln\\_bert](https://github.com/vitor-souza-ime/pln_bert) e o mesmo foi testado no Google Colab.

## RESULTADOS E DISCUSSÃO

Os resultados obtidos são apresentados a seguir, incluindo a classificação atribuída (label) e o score de confiança para cada caso. Para a frase positiva "Eu amo esse filme, é incrível!", o modelo atribuiu a classificação "5 stars" com um score de confiança de 0,8108. Este resultado indica que o modelo identificou corretamente o forte sentimento positivo expresso na frase. A presença de palavras com carga emocional positiva intensa como "amo" e "incrível", aliada à estrutura exclamativa da frase, contribuiu para a atribuição da pontuação máxima de sentimento, embora com um nível de confiança moderadamente alto.

Já para a frase negativa "Esse restaurante é horrível, nunca mais volto.", o modelo classificou como "1 star" com score de 0,9181. Observa-se que o modelo foi capaz de identificar com alta precisão o sentimento fortemente negativo, reconhecendo termos como "horrível" e a expressão "nunca mais volto" como indicadores claros de insatisfação extrema. Destaca-se que, entre os quatro casos analisados, este apresentou o maior score de confiança, sugerindo que o modelo identifica expressões negativas com maior assertividade.

Na análise da frase neutra "O dia está bonito hoje.", o resultado foi "4 stars" com score de 0,4132. Este caso é particularmente interessante, pois embora a frase tenha sido concebida como neutra em termos de opinião ou avaliação, o modelo a interpretou como moderadamente positiva. Este resultado pode ser explicado pela presença do adjetivo "bonito", que carrega uma conotação positiva mesmo em um contexto descritivo. O score de confiança relativamente baixo sugere que o modelo reconheceu significativa ambiguidade na polaridade do sentimento, indicando uma limitação na capacidade de distinguir entre descrições neutras e expressões de opinião.

Por fim, para a frase mista "Não gostei muito do atendimento, mas a comida era boa.", o modelo atribuiu "2 stars" com score de 0,4383. Esta classificação tendendo ao negativo revela que o modelo priorizou a primeira parte da frase ("Não gostei muito do atendimento") em detrimento do elemento positivo ("a comida era boa"). O score de confiança baixo indica a complexidade da tarefa de classificar sentenças que expressam sentimentos contraditórios ou nuançados, revelando uma possível tendência do modelo a dar maior peso a expressões negativas quando presentes em construções adversativas.

Estes resultados corroboram parcialmente as observações de Britto et al. (2022), que demonstraram a eficácia de modelos baseados em BERT para análise de sentimento em português, destacando sua capacidade de capturar nuances contextuais. Contudo, os baixos scores de confiança em frases neutras ou mistas revelam limitações importantes, sugerindo que o desempenho do modelo pode não ser tão robusto quanto o esperado para todos os tipos de expressões em português.

Um aspecto notável dos resultados é a capacidade do modelo em fornecer não apenas uma classificação binária (positivo/negativo), mas uma gradação de sentimento em cinco níveis, o que permite análises mais refinadas. Esta característica

é particularmente valiosa em aplicações práticas, como análise de feedback de clientes, onde a intensidade do sentimento pode ser tão importante quanto sua polaridade básica.

Entretanto, cabe ressaltar importantes limitações observadas. O modelo demonstrou tendência a interpretar frases descritivas com adjetivos positivos como expressões de opinião positiva, como evidenciado pelo caso da frase "O dia está bonito hoje.", porém com baixa confiança. Ainda mais significativo foi o tratamento dado à frase com estrutura adversativa, onde o modelo aparentemente priorizou o componente negativo (atribuindo 2 estrelas), mas com um score de confiança muito baixo (0,4383), indicando substancial incerteza na classificação.

Uma possível explicação para estas limitações está relacionada ao conjunto de dados de treinamento do modelo, predominantemente composto por reviews de produtos e serviços em inglês, onde expressões de opinião tendem a seguir padrões específicos que podem não se generalizar completamente para outros domínios do discurso ou idiomas (ROGERS; KOVALEVA; RUMSHISKY, 2020). Os baixos scores de confiança nas frases neutra e mista sugerem que o modelo reconhece suas próprias limitações ao lidar com expressões mais complexas ou ambíguas em português.

Outro ponto relevante a considerar é que o modelo "nlptown/bert-base-multilingual-uncased-sentiment", apesar de ser multilíngue, foi provavelmente treinado com predominância de dados em inglês, o que claramente afeta seu desempenho em português. Os resultados observados, especialmente os baixos scores de confiança em dois dos quatro casos, indicam que a transferência entre idiomas, embora possível conforme observado por Pires, Schlinger e Garrette (2019), apresenta desafios significativos que não podem ser ignorados.

## **CONCLUSÕES**

Este estudo demonstrou a aplicabilidade de um modelo multilíngue baseado em BERT para análise de sentimento em textos em português. Os resultados indicam que o modelo é capaz de identificar diferentes níveis de polaridade emocional, atribuindo classificações geralmente coerentes com o conteúdo semântico das frases analisadas, porém com variações significativas nos níveis de confiança.

A utilização de modelos pré-treinados, como o implementado através da biblioteca Transformers, representa uma abordagem potencialmente eficiente para superar limitações de recursos específicos para o português. No entanto, os resultados obtidos evidenciam que o conhecimento transferido de treinamentos em múltiplos idiomas pode ser insuficiente para capturar plenamente as nuances da expressão de sentimento em português, especialmente em casos de frases neutras ou com sentimentos mistos.

Desta forma, este trabalho contribui para o avanço das aplicações de PLN em língua portuguesa, especialmente no domínio da análise de sentimento, mas também evidencia importantes limitações dos modelos multilíngues atuais quando aplicados a tarefas específicas em português. Os resultados sugerem que, embora os modelos baseados em arquiteturas Transformer ofereçam um ponto de partida valioso, ainda há um caminho significativo a percorrer para atingir níveis ótimos de compreensão contextual de emoções e opiniões expressas textualmente em português.

## REFERÊNCIAS

DEVLIN, J.; CHANG, M.-W.; LEE, K.; TOUTANOVA, K. BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding. In: PROCEEDINGS OF THE 2019 CONFERENCE OF THE NORTH AMERICAN CHAPTER OF THE ASSOCIATION FOR COMPUTATIONAL LINGUISTICS: HUMAN LANGUAGE TECHNOLOGIES, 1, 2019, Minneapolis. Anais [...]. Minneapolis: Association for Computational Linguistics, 2019. p. 4171-4186.

LIU, B. Sentiment Analysis: Mining Opinions, Sentiments, and Emotions. 2. ed. Cambridge: Cambridge University Press, 2020.

GUPTA, Sowmya; NANDY, Anuj; MENDES, Aayush. Practical Natural Language Processing: A Comprehensive Guide to Building Real-World NLP Systems. 1. ed. Sebastopol: O'Reilly Media, 2020.

PIRES, T.; SCHLINGER, E.; GARRETTE, D. How multilingual is Multilingual BERT? In: PROCEEDINGS OF THE 57TH ANNUAL MEETING OF THE ASSOCIATION FOR COMPUTATIONAL LINGUISTICS, 2019, Florence. Anais [...]. Florence: Association

for Computational Linguistics, 2019. p. 4996-5001.

ROGERS, A.; KOVALEVA, O.; RUMSHISKY, A. A Primer in BERTology: What We Know About How BERT Works. Transactions of the Association for Computational Linguistics, v. 8, p. 842-866, 2020.

BRITTO, Larissa F. S.; PESSOA, Luis A. S.; AGOSTINHO, Sylvania C. C. Cross-domain sentiment analysis in Portuguese using BERT. In: ENCONTRO NACIONAL DE INTELIGÊNCIA ARTIFICIAL E COMPUTACIONAL (ENIAC), 2022. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2022. Disponível em: <https://sol.sbc.org.br/index.php/eniac/article/view/22770>. Acesso em: 10 maio 2025.

SOUZA, F.; NOGUEIRA, R.; LOTUFO, R. BERTimbau: Pretrained BERT Models for Brazilian Portuguese. In: BRAZILIAN CONFERENCE ON INTELLIGENT SYSTEMS (BRACIS), 9., 2020, Rio Grande. Anais [...]. Cham: Springer, 2020. p. 403-417.