



UMA APLICAÇÃO DE BIDIRECIONAL ENCODER REPRESENTATION FROM TRANSFORMERS (BERT) PARA ANÁLISE DE SENTIMENTOS

Sarah A. SILVA¹; Diego SAQUI²

RESUMO

Este trabalho explora a aplicação do modelo BERT na análise de sentimentos, demonstrando sua eficácia em diversas áreas. BERT supera métodos tradicionais, exibindo compreensão de contextos e nuances emocionais, inclusive sarcasmo. Apesar de desafios computacionais e adaptação, seu potencial na compreensão de opiniões em textos destaca-se, contribuindo para avanços no PLN e aplicações práticas.

Palavras-chave:

Machine Learning, Transfer Learning, análise de sentimentos.

1. INTRODUÇÃO

As modalidades sensoriais desempenham um papel importante na cognição e no comportamento, onde por exemplo, a visão desempenha um papel importante na atenção, memória e tomada de decisão, enquanto a audição é importante para a linguagem e a comunicação (GOLDSTEIN, et al. 2018). Por sua vez, a análise de sentimento, também conhecida como mineração de opinião, é uma área de pesquisa que visa identificar e classificar as emoções, opiniões e atitudes expressas em texto ou outros tipos de dados. Com o crescente volume de informações disponíveis na internet e nas mídias sociais, a análise de sentimento tornou-se uma ferramenta valiosa para entender as percepções e sentimentos das pessoas em relação a produtos, serviços, eventos, recomendações e muito mais.

Um dos desafios na análise de sentimento é a compreensão e representação adequada das emoções expressas, pois estas enfrentam problemas como:

- As emoções humanas são complexas e multifacetadas (SCHERER, K. et al. 2003).
- Os modelos de IA usados para reconhecimento de emoções podem ser afetados por viés, resultando em interpretações imprecisas ou tendenciosas (BUOLAMWINI J. et al. 2018).

¹Discente, IFSULDEMINAS – Campus Muzambinho. E-mail: ssilva.srah@gmail.com

²Docente, IFSULDEMINAS – Campus Muzambinho. E-mail: diego.saqui@muz.ifsuldeminas.edu.br

Neste trabalho foi escolhido o conjunto de dados *Multimodal Emotion Lines Dataset* (MELD) que é um conjunto de dados de reconhecimento de emoções e sentimentos, que contém gravações de diálogos de diferentes situações e estados emocionais (PORIA et al., 2019). O conjunto de dados inclui 1.498 diálogos que apresenta tanto a modalidade áudio e visual como também texto descritivo como referenciado na figura 1, representando uma variedade de emoções, sentimentos e expressões faciais.

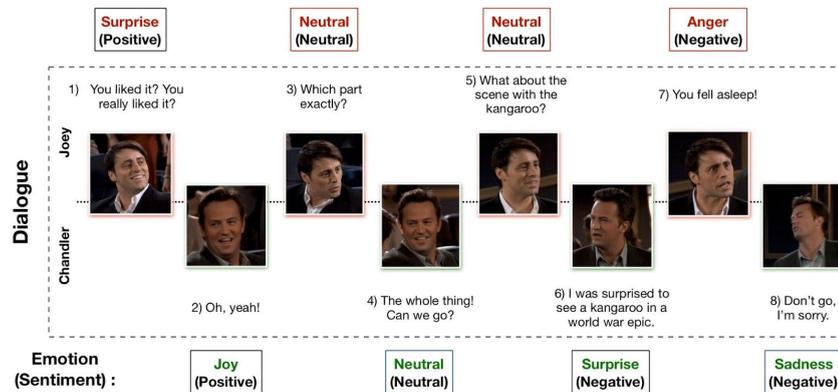


Figura 1: Mudança de emoção dos falantes em um diálogo em comparação com suas emoções anteriores.

Fonte: Poria (2019)

Em síntese, com as informações apresentadas, este trabalho tem o objetivo de classificar textos de alguns estados afetivos humanos em um determinado contexto. Mais especificamente, visa-se aplicar *Transfer Learning* (TL) no conjunto de dados MELD.

2. MATERIAL E MÉTODOS

Com o objetivo de conduzir uma pesquisa quantitativa, será desenvolvido um modelo de classificação multiclasse para analisar sentimentos e classificá-los em categorias positiva, negativa ou neutra, utilizando o modelo pré-treinado *Bidirectional Encoder Representations from Transformers* (BERT) como base aplicado ao *dataset* MELD.

	Utterance	Speaker	Emotion	Sentiment	Dialogue_ID	Utterance_ID	Old_Dialogue_ID	Old_Utterance_ID	Season	Episode	StartTime	EndTime
0	also I was the point person on my company's tr...	Chandler	neutral	neutral	0	0	0	0	8	21	00:16:16,059	00:16:21,731
1	You must've had your hands full.	The Interviewer	neutral	neutral	0	1	0	1	8	21	00:16:21,940	00:16:23,442
2	That I did. That I did.	Chandler	neutral	neutral	0	2	0	2	8	21	00:16:23,442	00:16:26,389
3	So let's talk a little bit about your duties.	The Interviewer	neutral	neutral	0	3	0	3	8	21	00:16:28,820	00:16:29,572
4	My duties? All right.	Chandler	surprise	positive	0	4	0	4	8	21	00:16:34,452	00:16:40,917
5	Now you'll be heading a whole division, so you...	The Interviewer	neutral	neutral	0	5	0	5	8	21	00:16:41,126	00:16:44,337
6	I see.	Chandler	neutral	neutral	0	6	0	6	8	21	00:16:48,800	00:16:51,886
7	But there'll be perhaps 30 people under you so...	The Interviewer	neutral	neutral	0	7	0	7	8	21	00:16:48,800	00:16:54,514
8	Good to know.	Chandler	neutral	neutral	0	8	0	8	8	21	00:16:59,477	00:17:00,478
9	We can go into detail	The Interviewer	neutral	neutral	0	9	0	9	8	21	00:17:00,478	00:17:02,719

Figura 2: Visualização de dataset usado na implementação

Fonte: Autoral

BERT é um modelo de linguagem pré-treinado projetado para compreender o contexto das palavras em uma frase, capturando relações semânticas e melhorando o desempenho em tarefas de processamento de linguagem natural, como tradução automática e análise de sentimentos. O conjunto de dados tem mais de 1.400 diálogos e 13.000 declarações, com diversos oradores onde a

distribuição dos dados se dá em 11 colunas sendo essas: *Sr No, Utterance, Speaker, Emotion, Sentiment, Dialogue_ID, Utterance_ID, Season, Episode, StartTime, EndTime*. O desenvolvimento tem foco nas colunas *Utterance* que diz respeito aos enunciados e na coluna *Sentiment* que diz respeito aos sentimentos expressos nos enunciados.

4. RESULTADOS E DISCUSSÃO

Os dados foram separados em duas épocas e depois de executar o algoritmo de análise de sentimento usando o modelo BERT, os seguintes resultados são obtidos.

Épocas	Tempo	Loss	Val_loss	Accuracy	Val_accuracy
Época 1/2	6813s 41s/step	0.8992	0.7219	0.5939	0.6939
Época 2/2	6856s 42s/step	0.5704	0.5988	0.7833	0.7959

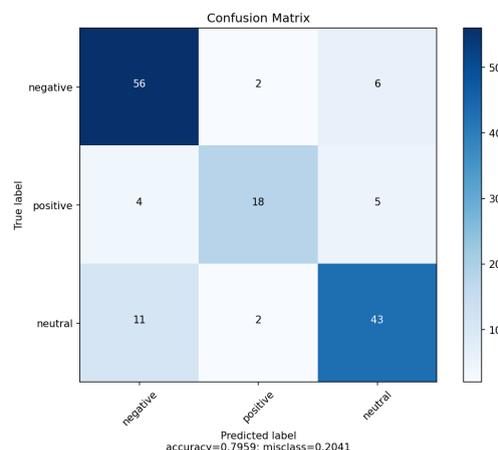
Quadro 10: Resultados de execução

Avaliando o modelo obtemos a seguintes previsões:

Épocas	Tempo	Loss	Accuracy
<code>bert_model.evaluate</code>	248s 13s/step	0.5988	0.7959
<code>bert_model.predict</code>	236s 12s/step	***	***

Quadro 12: Resultados da avaliação

O modelo foi treinado por 165 iterações, cada iteração levando cerca de 41 segundos. Durante o treinamento da primeira época, a perda diminui gradativamente e finalmente chega a 0,8992, enquanto a precisão aumenta para 0,5939. Por outro lado, para o conjunto de validação, a perda final é de 0,7219 e a precisão é de 0,6939. Por outro lado, durante o treinamento da segunda época, a perda diminui gradativamente e finalmente chega a 0,5704, enquanto a precisão aumenta para 0,7833. Por outro lado, para o conjunto de validação, a perda final é de 0,5988 e a precisão é de 0,7959.



A análise da matriz de confusão gerada acima, revela que na classe "negativa", o modelo obteve alto índice de acerto, com a maioria das amostras sendo classificadas corretamente. No entanto, a categoria "positivo" teve um desempenho um pouco pior, com algumas amostras sendo erroneamente classificadas como "negativas" ou "neutras". A classe "neutral" também apresentou um desempenho razoável, embora tenha havido uma pequena quantidade de amostras classificadas incorretamente. Além disso, é importante destacar que o tempo de treinamento foi significativo, levando aproximadamente 6813 segundos (cerca de 113 minutos) para concluir as 165 iterações, em uma época.

5. CONCLUSÃO

Com base nos resultados obtidos, o algoritmo usando o BERT mostra que o modelo funciona satisfatoriamente em tarefas de classificação de sentimentos. A perda diminuiu gradualmente durante o treinamento, indicando que o modelo é capaz de aprender a mapear os recursos dos dados de entrada para prever corretamente o sentimento relevante. A precisão também melhorou, mostrando que o modelo foi capaz de fazer previsões precisas para os rótulos fornecidos. Os resultados mostraram que o modelo alcançou uma precisão de 0,7959 no conjunto de validação, mostrando que ele generalizou bem e fez previsões precisas em dados inéditos.

Em síntese, mostra-se que nos dados de treinamento os resultados podem ter um melhor desempenho, podendo assim ser usado para classificar sentimentos em texto com precisão razoável.

REFERÊNCIAS

NG, Andrew. O aprendizado profundo. São Paulo: Novatec Editora, 2017.

Buolamwini, J., & Gebru, T. (2018). Gender shades: Intersectional accuracy disparities in commercial gender classification. *Proceedings of the 1st Conference on Fairness, Accountability and Transparency*, 77-91.

Goldstein, E. B. (2018). *Sensation and Perception*. Cengage Learning.

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

PICARD, Rosalind Wright. *Affective computing*. Cambridge, MA: MIT Press, 1997.

S. Poria, D. Hazarika, N. Majumder, G. Naik, E. Cambria, R. Mihalcea. MELD: A Multimodal Multi-Party Dataset for Emotion Recognition in Conversation. *ACL 2019*.

Scherer, K. R. (2003). Vocal communication of emotion: A review of research paradigms. *Speech Communication*, 40(1-2), 227-256.