

REDES NEURAIS EM GRAFOS COM ATENÇÃO PARA ANÁLISE DE SENTIMENTO EM NÍVEL DE ASPECTO EM PORTUGUÊS BRASILEIRO

GABRIEL ALMEIDA GOMES¹; LARISSA ASTROGILDO DE FREITAS²
RICARDO MATSUMURA DE ARAÚJO³; ULISSES BRISOLARA CORRÊA⁴

¹ Universidade Federal de Pelotas - gagomes@inf.ufpel.edu.br

² Universidade Federal de Pelotas - larissa@inf.ufpel.edu.br

³ Universidade Federal de Pelotas - ricardo@inf.ufpel.edu.br

⁴ Universidade Federal de Pelotas - ulisses@inf.ufpel.edu.br

1. INTRODUÇÃO

As opiniões sobre assuntos e produtos possuem uma relevância imensa no contexto empresarial, uma vez que fornecem informações valiosas sobre a aceitação de clientes de determinados produtos ou serviços, e permanecem como uma abordagem sólida para a pesquisa de mercado geral, orientando o processo de tomada de decisão.

Técnicas como as desenvolvidas na área de Análise de Sentimentos (AS) são essenciais para compreender e quantificar as emoções humanas expressas em dados textuais. Inserida no campo de Processamento de Linguagem Natural (PLN), a Análise de Sentimentos pode ser entendida como o processo de analisar e identificar a polaridade de sentimento transmitida pelos autores de um determinado texto. Na prática, a Análise de Sentimentos avalia se a opinião contida no texto é positiva, negativa ou neutra.

Textos opinativos frequentemente expressam múltiplos sentimentos conflitantes sobre diferentes tópicos dentro de uma mesma sentença (por exemplo, no contexto de avaliações de hotéis, um autor pode fornecer um feedback positivo sobre a cama e negativo sobre o café da manhã). Identificar esses aspectos e seus respectivos sentimentos é geralmente mais valioso do que extrair o tom geral de sentimento de um documento inteiro. A Análise de Sentimentos Baseada em Aspectos (ABSA) fundamenta-se na ideia de que todas as opiniões consistem em uma polaridade de sentimento e seu alvo (LIU, 2012).

A forma mais comum de inserir dados textuais em Redes Neurais é adaptá-los em representações vetorizadas por meio de embeddings. Embora os embeddings sejam certamente capazes de reter grandes quantidades de informações textuais, é possível adicionar informações complementares com o objetivo de capturar explicitamente relações estruturais nos dados textuais. Os grafos são um tipo adequado de representação para modelar essas relações e argumenta-se que utilizá-los para apresentar conexões sintáticas ao modelo pode potencialmente melhorar seu desempenho em tarefas subsequentes. Para dados textuais, podemos assumir que as palavras são nós, enquanto suas relações sintáticas são arestas, modelando assim uma camada adicional de informação que pode ser incorporada aos embeddings, em vez de utilizar apenas o texto.

As Redes Neurais com Grafos (Graph Neural Networks - GNNs) são Redes Neurais que utilizam grafos como dados de entrada. A abordagem mais comum para aproveitar as informações conectadas inerentes à estrutura do grafo é através do uso do Mecanismo de Passagem de Mensagem (Message-Passing Mechanism - MPN). Esse processo é semelhante a uma convolução e opera da seguinte forma:

Agradecemos à CAPES, à FAPERGS e à NVIDIA Corporation pelo financiamento parcial deste trabalho.



para cada nó, os nós conectados são identificados; em seguida, uma função de agregação é aplicada entre o nó focal e seus nós vizinhos, atualizando o estado do nó focal (CAI et al., 2021). Diferentes tipos de funções de agregação podem ser empregadas para essa tarefa, sendo que cada tipo é mais adequado para domínios específicos de problemas.

Nos últimos anos, a arquitetura Transformer tem ganhado destaque na área de PLN, especialmente pelo uso do mecanismo de Self-Attention, que permite a um token agregar informações de contexto de seus vizinhos. Embora eficaz, o Transformer é computacionalmente custoso devido às conexões entre todos os tokens, aumentando a complexidade do treinamento e da inferência, o que requer hardware mais poderoso e eleva os custos. Propõe-se que o uso de grafos esparsos possa reduzir essa complexidade, mantendo a qualidade do modelo. As Redes de Atenção em Grafos (GATs), que aplicam Self-Attention como função de agregação aos grafos, têm mostrado bom desempenho em tarefas de classificação de nós, oferecendo uma solução mais eficiente.

Alguns trabalhos amplamente reconhecidos exploram o uso de GATs para ABSA, com foco na língua inglesa (WANG et al., 2020). No entanto, até onde sabemos, não existem outros estudos que avaliem essa abordagem para a língua portuguesa do Brasil. Em função disso, este trabalho propõe um modelo GAT para abordar a tarefa de Classificação de Sentimentos por Aspectos em ABSA no contexto do português brasileiro.

2. METODOLOGIA

O dataset escolhido para a aplicação da metodologia é o mesmo utilizado na competição ABSAPT 2022 (SILVA et al., 2022). Existem poucos conjunto de dados para o português brasileiro com aspectos já anotados e classificados quanto à orientação de sentimento, por isso, selecionamos este conjunto, que se encaixa nesta categoria.

O dataset é formado por reviews de hotéis de Nova Iorque, Las Vegas, Paris e Porto Alegre. Todos os dados foram extraídos do site TripAdvisor, estão escritos em Português e possuem pelo menos 300 caracteres. Cada anotação possui a polaridade da orientação de sentimento ligada ao aspecto em questão. A polaridade pode assumir os valores de 1 se a orientação de sentimento expresso em relação ao aspecto for positiva, 0 se for neutra e -1 se for negativa. O Conjunto de dados possui 3.797 anotações, de 1.031 reviews com 77 aspectos.

É importante informar que o *dataset* é desbalanceado em relação às polaridades dos aspectos, com mais anotações positivas do que negativas e neutras somadas. Por isto, é preciso pensar métricas específicas para esse tipo de distribuição.

Como primeira etapa, precisamos definir a representação de texto em grafos. A forma que adotamos para esta representação é dada pela assumpção de cada nodo do grafo representa uma palavra, e as relações sintáticas das palavras são as arestas.

Os grafos foram gerados utilizando a biblioteca spaCy (HONNIBAL; MONTANI, 2017), que possui diversas ferramentas para NLP, inclusive a de geração de árvores de dependência sintática, utilizada para a criação dos grafos.

Além disso, a utilização de um modelo gerador de embeddings é fundamental para a criação de representações numéricas dos dados textuais. Para essa

finalidade, selecionamos o BERTimbau (SOUZA; NOGUEIRA; LOTUFO, 2020), um modelo da família BERT (DEVLIN et al., 2019), pré-treinado com corpora em português. Este modelo é amplamente reconhecido na literatura devido à sua alta eficácia na geração de embeddings, uma vez que os modelos do tipo encoder baseados em transformers demonstram desempenho superior na criação de representações semânticas. Ressalta-se que utilizamos o BERTimbau exclusivamente para a inferência dos embeddings, sem realizar qualquer tipo de ajuste fino (fine-tuning).

Um dos desafios do uso do BERTimbau é a discrepância na tokenização, que ocorre em nível de palavras para a construção dos grafos, enquanto o modelo gera embeddings em nível de sub-tokens. Para contornar essa diferença, foi utilizado o método do estudo DualGCN (LI et al., 2021), no qual os sub-tokens herdam as mesmas relações sintáticas da palavra raiz, replicando as conexões do grafo.

Para o desenvolvimento do modelo GAT, utilizamos o framework Pytorch Geometric, uma ferramenta robusta que facilita a implementação de redes neurais em grafos na plataforma Pytorch. A arquitetura do modelo é composta por duas camadas de atenção em grafos, cada uma gerando vetores de saída com a mesma dimensão dos vetores de entrada, que neste caso é de 4.096. Esta escolha foi feita para garantir uma adequada aplicação do mecanismo de atenção.

Após o processamento realizado pela GAT, integramos uma camada linear destinada à classificação dos aspectos em polaridades de sentimento, sendo estas Positiva, Negativa ou Neutra. O tamanho da entrada da camada linear é definido pela quantidade de tokens no maior aspecto identificado, que neste estudo foi de seis. Para aspectos com menor número de tokens, foi aplicado preenchimento (padding) para garantir a compatibilidade do tamanho da entrada.

3. RESULTADOS E DISCUSSÃO

A competição *Aspect-Based Sentiment Analysis in Portuguese* (ABSAPT) (SILVA et al., 2022), realizada em 2022, sob organização do Hub de Inovação em Inteligência Artificial, da Universidade Federal de Pelotas, empregou as tarefas de Extração de Aspectos e Classificação de Sentimentos.

Na Tabela 1 apresentamos uma comparação dos resultados obtidos com as quatro abordagens com melhor desempenho na competição, considerando a tarefa de Determinação da Orientação de Sentimento.

Tabela 1: Resultados Obtidos no Conjunto de Testes.

Nome	Bacc	F1	Precision	Recall
<i>Team Deep Learning Brasil</i>	0,82	0,81	0,81	0,82
<i>Team PiLN</i>	0,78	0,77	0,76	0,78
GAT-PT	0,74	0,72	0,70	0,74
<i>Team UFSCAR</i>	0,62	0,61	0,65	0,62
<i>Team UFPR</i>	0,62	0,61	0,65	0,62

Os modelos gerados pela nossa metodologia superaram o terceiro e quarto colocados da competição. Porém, não conseguimos superar o primeiro e segundo colocados. Porém, é importante salientar que todos os competidores selecionados para comparação utilizaram metodologias baseadas em Transformers, com modelos maiores e mais lentos do que o gerado pela nossa metodologia.

4. CONCLUSÃO

Este trabalho teve como objetivo analisar a adaptação de uma arquitetura de GAT para a tarefa de ABSA na língua Portuguesa Brasileira. O modelo resultado da nossa abordagem obteve métricas superiores as do terceiro colocado na competição ABSAPT, porém inferiores as do segundo. Além disso, nosso modelo é menor em termos de parâmetros do que os modelos que obtiveram primeiro e segundo lugar, sendo assim mais rápido e menor. Os resultados mostraram ser competitivos aos demais métodos.

5. REFERÊNCIAS

- CAI, S.; LI, L.; DENG, J.; ZHANG, B.; ZHA, Z.-J.; SU, L.; HUANG, Q. Rethinking graph neural architecture search from message-passing. In: **Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition**. [S.I.]: s.n., 2021. p. 6657–6666.
- DEVLIN, J.; CHANG, M.-W.; LEE, K.; TOUTANOVA, K. **BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding**. 2019. Disponível em: <<https://arxiv.org/abs/1810.04805>>.
- HONNIBAL, M.; MONTANI, I. spaCy 2: Natural language understanding with Bloom embeddings, convolutional neural networks and incremental parsing. To appear. 2017.
- LI, R.; CHEN, H.; FENG, F.; MA, Z.; WANG, X.; HOVY, E. Dual graph convolutional networks for aspect-based sentiment analysis. In: **Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing (Volume 1: Long Papers)**. Online: Association for Computational Linguistics, 2021. Disponível em: <<https://aclanthology.org/2021.acl-long.494>>.
- LIU, B. **Sentiment Analysis and Opinion Mining**. [S.I.]: Morgan & Claypool Publishers, 2012.
- SILVA, F. L. V. da; XAVIER, G. da S.; MENSENBURG, H. M.; RODRIGUES, R. F.; ARAÚJO, L. P. dos Santos y R. M.; CORRÊA, U. B.; FREITAS, L. A. de. Absapt 2022 at iberlef: Overview of the task on aspect-based sentiment analysis in portuguese. **Procesamiento del Lenguaje Natural**, v. 69, n. 0, p. 199–205, 2022. ISSN 1989-7553. Disponível em: <<http://journal.sepln.org/sepln/ojs/ojs/index.php/pln/article/view/6440>>.
- SOUZA, F.; NOGUEIRA, R.; LOTUFO, R. Bertimbau: Pretrained bert models for brazilian portuguese. In: **Intelligent Systems: 9th Brazilian Conference, BRA-CIS 2020, Rio Grande, Brazil, October 20–23, 2020, Proceedings, Part I**. Berlin, Heidelberg: Springer-Verlag, 2020. p. 403–417. ISBN 978-3-030-61376-1. Disponível em: <https://doi.org/10.1007/978-3-030-61377-8_28>.
- WANG, K.; SHEN, W.; YANG, Y.; QUAN, X.; WANG, R. Relational graph attention network for aspect-based sentiment analysis. In: JURAFSKY, D.; CHAI, J.; SCHLUTER, N.; TETREAULT, J. (Ed.). **Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics**. Online: Association for Computational Linguistics, 2020. p. 3229–3238. Disponível em: <<https://aclanthology.org/2020.acl-main.295>>.