

Mineração de Argumentos em Textos de Redes Sociais no Idioma Português

Vitor Domingos Baldoino dos Santos¹, Livia Alabarse dos Santos¹, Orlando B. Coelho (*in memoriam*)¹, Renata Mendes de Araujo^{1,2}, Ivan Carlos Alcântara de Oliveira¹

¹Faculdade de Computação e Informática e Programa de Pós-Graduação em Computação Aplicada - Universidade Presbiteriana Mackenzie
São Paulo - SP - Brasil.

²Programa de Pós-Graduação em Sistemas de Informação - EACH/USP
São Paulo - SP - Brasil

{vitordomingos.santos, liviaalabarse.santos}@mackenzista.com.br
{renata.araujo, orlando.coelho, ivan.oliveira}@mackenzie.br

Abstract. *This paper presents the challenges and research advances aimed at developing computational solutions capable of supporting the understanding of debates on social media in the Portuguese language. One of the fundamental bases of these solutions is the application of Argument Mining techniques. We present the strategies used to address the challenges of argument mining on social media, particularly the use of deep learning. The results obtained show the effectiveness of the selected models for the considered tasks, achieving an F1-Score of 0.85 for sentiment analysis, 0.97 for position detection, and 0.76 for irony detection.*

Resumo. *Este artigo apresenta os desafios e os avanços de pesquisa voltada à construção de soluções computacionais capazes de apoiar o entendimento do debate em redes sociais no idioma português. Uma das bases fundamentais dessas soluções é a aplicação de técnicas de Mineração de Argumentos. Apresentamos as estratégias utilizadas para o endereçamento de desafios da mineração de argumentos em redes sociais, em particular, o uso de deep learning. Os resultados obtidos demonstram boa eficácia dos modelos selecionados para as tarefas consideradas, tendo atingido um F1-Score de 0,85 para a análise de sentimento, 0,97 na detecção de posição e 0,76 na detecção de ironia.*

1. Introdução

A área de Mineração de Argumentação (MA) é uma área multidisciplinar onde se encontram a Linguística Computacional e a Ciência de Dados, cujo objetivo é identificar, extrair e compreender a estrutura de argumentação em textos e/ou discussões [Lawrence e Reed 2020][Lyts et al. 2019][Stede e Schneider 2019].

Argumentação é o processo pelo qual argumentos são construídos, compartilhados e avaliados a partir de outros argumentos [Palau e Moens 2009]. Uma argumentação se estrutura a partir de evidências, premissas, fatos e falas que suportam ou não uma determinada alegação, em uma cadeia de raciocínio que leva à conclusão de discussões e à tomada de decisão [Toulmin 2003]. A argumentação tem papel importante nas atividades humanas, e tem sido compreendida como uma área de pesquisa que surge com base em campos como a Retórica e a Filosofia, mas que hoje

inclui estudos de Processamento de Linguagem Natural e modelos teóricos de discussão [Palau e Moens 2009][Lawrence et. al. 2012], tendo como áreas antecessoras a Mineração de Opiniões e a Análise de Sentimentos, entre outras [Lawrence e Reed 2020][Lytos et.al. 2019].

O projeto HEIWA¹ pretende construir soluções computacionais de análise de redes sociais baseadas em técnicas de MA para a compreensão de discussões em redes sociais, com um olhar específico para o contexto brasileiro. O principal resultado esperado com o projeto é a construção de uma plataforma que permita o acompanhamento de discussões em redes sociais, preferencialmente pelos usuários das próprias redes, mas também para interessados no estudo de comportamentos e mediação em redes sociais. A plataforma será composta por ferramentas computacionais capazes de apoiar um processo de curadoria, mineração de argumentos e visualização do debate para usuários de redes sociais. As implicações da construção dessas tecnologias envolvem aspectos sociais, como o aperfeiçoamento da qualidade do debate e a democracia, aspectos educacionais e de desenvolvimento de pensamento crítico.

Neste artigo, apresentamos os avanços obtidos no escopo do projeto, especificamente em relação ao uso da MA para a identificação de argumentos em textos extraídos de redes sociais em português. Em linhas gerais, os avanços compreendem a necessidade de lidar com linguagem informal, uso de ironia e a polarização presente nos debates online. Além disso, destacamos o uso de modelos de *deep learning*, que se mostraram eficazes em tarefas como análise de sentimento, detecção de posição e detecção de ironia, tendo alcançado bons resultados de *F1-Scores* nas tarefas em um contexto de grande relevância, como os eventos de 8 de janeiro de 2023 em Brasília.

O artigo se estrutura da seguinte forma: a Seção 2 apresenta o conceito e abordagens na literatura para a MA em redes sociais; a Seção 3 descreve as propostas já exploradas no projeto baseadas em análise de sentimentos e *deep learning*; a Seção 4 discute a proposta atual de *pipeline* para execução de tarefas de identificação de tópicos, entidades, sentimentos e ironia; a Seção 5 mostra os resultados dos experimentos computacionais realizados; a Seção 6 conclui o artigo e apresenta os próximos passos da pesquisa.

2. Mineração de Argumentos em Redes Sociais

O processo de identificar, extrair e compreender a estrutura argumentativa a partir de dados textuais é o objetivo da mineração de argumentos (MA) [Stede e Schneider 2019]. A MA tem sido explorada cientificamente para a análise de diferentes conteúdos textuais (documentos, transcrições de debates, transcrições de áudios, etc.), com o objetivo principal de extrair a estrutura de argumentação contida nesses textos e que, eventualmente, levaram para uma deliberação ou decisão [Lawrence e Reed 2020] e para a construção de tecnologias capazes de facilitar discussões ou debater com humanos [Slonim et. al. 2021].

Nos últimos anos, a comunidade científica na área de MA também explora a oportunidade de aplicar o conceito e as técnicas de MA no estudo da argumentação em textos extraídos de redes sociais [Addawood e Bashir 2016][Bosc et. al. 2016][Schaefer

¹ <https://ciberdem.mack.com.br/index.php/projeto-heiwa/>

e Stede 2021][Vecchi et. al. 2021]. Essas pesquisas partem da ideia de que esses textos possam conter uma atividade argumentativa e que a compreensão dos argumentos utilizados durante a interação nas redes sociais pode agregar para a tomada de decisões, gestão da informação e o entendimento do comportamento coletivo em diversos domínios, principalmente as ciências políticas e sociais.

Em um levantamento de literatura preliminar, identificamos que os esforços recentes na aplicação de MA em redes sociais focaram, em alguns casos, na criação e anotação de *datasets* apropriados para a aplicação das técnicas de MA, em maior número, na definição e execução de sequências pré-definidas de tarefas consideradas essenciais para um *pipeline* de mineração de argumentos, e poucos trabalhos na visualização dos resultados (estruturas de argumentação) [Schaefer e Stede 2021].

A despeito dos esforços crescentes, a mineração de argumentos em redes sociais ainda enfrenta desafios significativos. Problemas antigos, apontados desde [Bosc et al. 2016a], permanecem, como a escassez de *datasets* anotados; a baixa qualidade e/ou informalidade dos textos nas redes; o tamanho reduzido das falas (*tweets*, *posts*), que impedem a riqueza de ideias, a ausência de foco ou tópico em discussão, enquanto outros se intensificam, como o crescente custo e restrição de uso das APIs das plataformas de redes sociais de maior escala (*X*, *Facebook* etc). Além disso, a literatura mostra abordagens ainda exploratórias e nenhum dos trabalhos encontrados tratam de conteúdos em português brasileiro.

No que se refere à definição e ao desenvolvimento de *pipelines* para MA em redes sociais, Schaefer e Stede (2021) e Bosc et al. (2016a) mencionam que as tarefas necessárias para aplicação de MA, em linhas gerais, incluem: (i) a anotação de *corpus*; (ii) a detecção de argumentos e suas relações; e (iii) a detecção de posicionamentos. No que se refere à tarefa (i) anotação de *corpus*, a literatura mostra um número escasso de bases anotadas e, pelo menos no material levantado pela presente pesquisa, nenhuma considerando conteúdo em português. No projeto de pesquisa em tela, avançamos nesse aspecto, ao anotar *datasets* de *tweets* em português coletados durante o período eleitoral brasileiro em 2022 [Silva et. al. 2024]. A tarefa seguinte, (ii) detecção de argumentos e relações, envolve, primeiramente, a identificação, no conteúdo de cada postagem, de elementos (alegações), que possam caracterizar as falas como argumentos ou não e, posteriormente, a identificação de relações entre elas (oposição, apoio), permitindo a identificação de estruturas (grafos) de argumentação [Stede e Schneider, 2019][Bosc et. al, 2016a]. Por fim, a tarefa (iii) detecção de posicionamentos consiste em extrair os diferentes pontos de vista sobre um determinado tópico em uma discussão. As tarefas (ii) e (iii) são o foco deste artigo, conforme detalharemos nas seções a seguir.

3. Estudos Iniciais

Os primeiros estudos de MA em redes sociais realizados por esta equipe focaram na identificação de relações de oposição e apoio entre falas em um *corpus* de postagens. As falas dos participantes foram tratadas como sentenças, e as relações entre elas foram identificadas pelo direcionamento das falas entre os interlocutores. Usando os identificadores extraídos das redes sociais, criou-se uma estrutura de dados que preserva a organização entre um argumento e outro, mantendo a estrutura de *threads* de discussão. A natureza da relação (oposição ou apoio) foi determinada pela análise de

sentimentos (negativo, positivo ou neutro).

Os primeiros resultados desta estratégia são reportados por [Sousa et. al. 2021], que explora o pipeline definido por Lippi e Torroni (2016). Para cada uma das sentenças, utilizamos técnicas de análise de sentimentos para determinar a polaridade das manifestações no discurso, utilizando o algoritmo SGD (Pedregosa et al. 2011) para a classificação, treinado com as discussões já classificadas presentes na base *Internet Argument Corpus* (IAC) [Walker et.al. 2012]. A base IAC, contém discussões com um teor politizado, porém amplas o bastante para que pudéssemos usá-la em debates mais genéricos. Quanto ao método de classificação dos argumentos, a classificação se deu sentença a sentença, fornecendo três rótulos que caracterizavam a polaridade de um argumento: apoio, oposição ou neutro. Os resultados obtidos demonstraram uma precisão de 74% na identificação das polaridades dos argumentos, criando assim uma alternativa promissora para a classificação.

Uma segunda abordagem desenvolvida pela equipe envolveu o uso de técnicas de análise de sentimentos baseadas em *deep learning*. A abordagem, apresentada em [Tokuda et. al. 2021], explora a arquitetura BERT [Devlin et al. 2019] como estratégia para elucidar a polaridade das afirmações presentes em um *corpus* de argumentação extraído de uma rede social. Os experimentos realizados demonstraram resultados satisfatórios na extração da polaridade de uma afirmação. A acurácia dos experimentos chegou a 88% em dados não vistos anteriormente pelo modelo, a partir de um conjunto de dados com diversidade extremamente alta de palavras e estruturação livre dos dados, em um formato livre de discussões online com razoável incidência de erros gramaticais e de digitação. Em outro trabalho [Salles e Coelho 2022], foi utilizada uma rede *deep learning* derivada da BERT, a DistilBERT [Zhang et al. 2020], para realizar a análise das emoções presentes em frases que constam do *dataset* em inglês *GoEmotions* [Demszky et al. 2020]. Os resultados obtidos aperfeiçoam os melhores resultados publicados por Cortiz (2021).

Os estudos anteriores demonstram resultados satisfatórios para o uso da análise de sentimentos como parte do processo de MA, mas ainda não avançam em tarefas mais sofisticadas de identificação da estrutura de argumentos e não contemplam conteúdos em português. A estratégia atual do projeto é avançar na identificação de outros componentes de argumentação além de sentimentos, explorando o uso de modelos baseados no *Transformer* [Vaswani et al. 2017] e semelhantes ao BERT aplicados a dados extraídos de redes sociais em português.

4. Proposta de Pipeline para Mineração de Argumentos

Optamos por avançar em nosso projeto a partir da expansão do leque de tarefas consideradas para um *pipeline* de mineração de argumentos, sendo elas: análise de sentimento, identificação de tópico, reconhecimento de entidades, detecção de ironia, detecção de posição, e do uso de redes neurais como principal ferramenta para MA. Destaca-se que as tarefas do *pipeline*, em conjunto, são essenciais para o entendimento do discurso nas redes sociais, visando a posterior identificação de argumentos.

A inclusão das tarefas de identificação de tópico e reconhecimento de entidades nomeadas objetiva desagregar duas grandes atividades vistas na literatura: (i) a

identificação do assunto da discussão; e (ii) a detecção de relação entre pares de texto. Com a desagregação, será possível investigar a eliminação da anotação de um *dataset* para pares de *tweets* relacionados, como o apresentado em [Bosc et al. 2016a]. Adicionalmente, a inclusão da detecção de ironia visa resolver a dificuldade adicional da MA em redes sociais relacionada ao alto grau de informalidade do texto [Schaefer e Stede 2021] e a mudança de semântica gerada pelo uso desse recurso linguístico.

Optamos por não incluir a tarefa de detecção de argumentação, prevista pela literatura, no *pipeline* proposto. Como exposto em [Schaefer e Stede 2021], a literatura recente despendeu muito esforço na construção de *datasets* com alguma definição teórico-conceitual de argumentação. O formato geral do *pipeline* está na Figura 1.




Figura 1. Pipeline proposto da mineração de argumentos.

Posto que o objetivo geral deste trabalho é compreender o debate em uma rede social, cujas características textuais exigem uma análise mais sofisticada de entendimento do texto antes de realizar a identificação da argumentação, entendemos que as tarefas de identificação de tópicos, entidades, sentimentos, posição e ironia de uma discussão oferecem vantagem para o seu entendimento, ainda que ali possamos constatar que não ocorra argumentação. Um exemplo simplificado desta estratégia, tendo por base textos sintéticos sem o pré-processamento e sem considerar todas as tarefas do *pipeline*, é demonstrado na Figura 2. Nela, são apresentados três *tweets* sintéticos e sem pré-processamento a respeito do filme “Duna: Parte Dois”, tópico correspondente a esses *posts*. Com os *tweets* pré-processados, é possível encontrar: as entidades “Duna”, “Aila” e “Paul Atreids”; os sentimentos de cada um deles; e a ironia existente. A partir disso, uma estrutura do debate realizado sobre esse tópico pode ser montada.

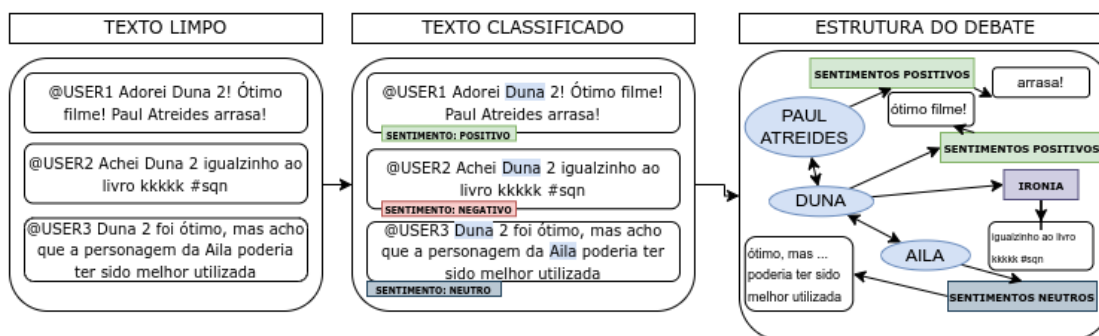


Figura 2. Exemplo do processamento de textos em redes sociais para a identificação da estrutura do debate (entidades, sentimentos e ironia).

5. Experimentos

Para dar cabo das tarefas selecionadas, procurou-se por modelos pré-treinados em português ou que tivessem sofrido *fine-tuning* para tarefas em português com um bom resultado. Um fator crucial para a seleção de modelos foi a sua presença no *HuggingFace Hub*², repositório que visa armazenar e distribuir modelos de *deep learning* para facilitar sua utilização em pesquisas e aplicações comerciais. A Tabela 1 apresenta os modelos selecionados para os experimentos, com a coluna “Modelo” sendo o ID dos modelos na plataforma da *HuggingFace* e coluna ID sendo a utilizada para referenciar os modelos ao longo desta seção.

O modelo 1, apelidado na literatura de BERTimbau (Souza et al., 2020), foi pré-treinado na base de dados brWaC [Wagner Filho et al., 2018], ou seja, em dados sem domínio específico em português brasileiro. Já os modelos 2 e 3, BERTweet.BR [Carneiro, 2023] e BERTaporu [Costa et al., 2023], respectivamente, foram pré-treinados em milhares de *tweets* em português. Entretanto, o modelo 4, RoBERTuito [Pérez et al., 2022], foi pré-treinado em *tweets* na língua espanhola, mas já demonstrou bons resultados para a tarefa de análise de sentimento em português [Pérez et al., 2023].

Tabela 1. Modelos escolhidos para os experimentos computacionais.

ID	Modelo	Endereço Web
1	neuralmind/bert-base-portuguese-cased	huggingface.co/neuralmind/bert-base-portuguese-cased
2	melll-uff/bertweetbr	huggingface.co/melll-uff/bertweetbr
3	pablocosta/bertaporu-base-uncased	huggingface.co/pablocosta/bertaporu-base-uncased
4	pysentimiento/robertuito-base-cased	huggingface.co/pysentimiento/robertuito-base-cased

Por sua vez, a base de dados utilizada para realizar o *fine-tuning* dos modelos, [Silva et. al. 2024], foi construída a partir das discussões realizadas em torno dos eventos de 8 de janeiro de 2023 na praça dos Três Poderes, em Brasília, e anotada em etapas manuais e automáticas (com uso de LLMs) para as tarefas de análise de sentimento (AS) (positivo, negativo ou neutro), detecção de ironia (DI) (contém ironia, não contém ironia) e detecção de posição (DP) (a favor da invasão, contra a invasão). Considerando que a base foi construída a partir de um evento marcante, inferimos que o *corpus* já está intrinsecamente associado a um único tópico central. Dessa forma, a tarefa de identificação de tópico foi considerada redundante e removida desta bateria de experimentos. A detecção de posição, por sua vez, foi conduzida em relação a esse tópico pré-definido, permitindo uma análise mais precisa das opiniões expressas no contexto específico do evento. Além disso, optou-se por explorar o reconhecimento de entidades nomeadas (NER) futuramente devido ao tempo significativo que seria necessário para uma anotação manual da base de dados e treinamento do modelo, considerando o cronograma previsto.

A Tabela 2 apresenta a quantidade de *tweets* utilizada para os experimentos de cada tarefa, bem como a distribuição entre as classes de cada tarefa. Deve-se notar que a base está balanceada para a tarefa de AS, mas não para as tarefas de DP e DI. Adicionalmente, cabe destacar que os *tweets* utilizados em cada uma das tarefas não

² <https://huggingface.co/>

possuem total sobreposição, isto é, não são necessariamente os mesmos entre as bases de cada tarefa.

Tabela 2. Quantidade de tweets entre as tarefas e classes.

Tarefa	Classe	Treino	Validação	Teste	Total
Análise de Sentimento	Neutro	234	50	50	334
	Positivo	233	50	51	334
	Negativo	234	50	50	334
Detecção de Posição	Neutro	77	16	17	110
	A favor	19	4	4	27
	Contra	1453	312	312	2077
Detecção de Ironia	Contém ironia	232	50	50	332
	Não contém ironia	615	132	132	879

Os resultados do ajuste dos modelos podem ser vistos na Tabela 3. Os modelos foram treinados com 5 passagens completas pelo conjunto de treino e aquele com melhor desempenho no conjunto de validação foi salvo e utilizado para avaliação no conjunto de teste. Todos os modelos foram treinados variando o número de camadas treinadas (as 2 ou 4 últimas camadas) e o *batch size* (testes realizados com 8, 16, 32 e 64). Utilizou-se a taxa de aprendizado de 0.001 para todos os modelos e a entropia cruzada na função de custo, com ajuste para penalizar mais severamente os erros nas classes minoritárias. Na tarefa de DI, o melhor modelo foi o RoBERTuito (ID 4 - Tabela 1), tendo sido ajustado nas últimas duas camadas e com um *batch size* de 16. Nas tarefas de AS e DP, o melhor modelo foi o BERTimbau (ID 1 - Tabela 1), sendo ajustado nas últimas 4 camadas e com o mesmo *batch size* do modelo anterior.

Tabela 3. Métricas de avaliação dos melhores modelos por tarefa.

Tarefa	Modelo	F1-Score	Precision	Recall
Análise de Sentimento	neuralmind/bert-base-portuguese-cased	0,85	0,86	0,86
Detecção de Ironia	pysentimiento/robertuito-base-uncased	0,76	0,76	0,76
Detecção de Posição	neuralmind/bert-base-portuguese-cased	0,97	0,97	0,97

Embora os resultados obtidos aqui não sejam diretamente comparáveis com a literatura por serem obtidos em uma base de dados diferente, eles são numericamente superiores aos encontrados em Pérez et al. (2023). Comparativamente, o modelo de AS em português ajustado em Pérez et al. (2023), treinado a partir do BERTweet.BR na base de dados apresentada em Brum & Volpe Nunes (2018), alcançou uma macro *F-Score* de 0,73 no conjunto de teste do *dataset* [Silva et. al. 2024]. Além disso, a título de exemplo, a Tabela 4 apresenta dois *tweets* do conjunto de teste, a classificação dada pelo modelo e a classe tida como verdadeira. Os dois *tweets* foram levemente modificados para evitar a sua identificação na rede social sem comprometimento do seu significado e avaliação.

Tabela 4. Exemplos de classificação de dois tweets do conjunto de teste.

Texto	Análise de Sentimento		Detecção de Posição		Detecção de Ironia	
	Classe Verdadeira	Classe Prevista	Classe Verdadeira	Classe Prevista	Classe Verdadeira	Classe Prevista
mano passei a noite toda no meu quarto assistindo tbt e fui ver agr que tava a maior confusao em brasilia k super antenada eu sou	Positivo	Neutro	Contra	Contra	Não contém ironia	Não contém ironia
nem eu acreditei quando vi onde ela tava me mandou corrente de excursao pra brasilia e tudo e nem dei bola	Neutro	Neutro	Contra	Contra	Não contém ironia	Contém ironia

6. Conclusão

Este artigo apresenta os avanços desta pesquisa em andamento voltada à construção de soluções computacionais capazes de apoiar o entendimento do debate em redes sociais. Uma das bases fundamentais destas soluções, explorada neste artigo, é a aplicação de técnicas de mineração de argumentos capazes de identificar a estrutura de argumentação presente nas diversas falas na rede. A expectativa é que a identificação e visualização da estrutura de argumentação possa auxiliar usuários da rede a compreenderem, refletirem e, eventualmente, melhor participarem do debate público.

No treinamento dos modelos, os resultados mais significativos incluem o bom desempenho do modelo BERTimbau na tarefa de detecção de posição, com *F1-Score* de 0,97. Adicionalmente, o modelo RoBERTuito também obteve um desempenho bom, com um *F1-Score* de 0,76 na detecção de ironia, uma tarefa ainda mais complexa no contexto das redes sociais. No entanto, destaca-se como limitação o fato de o *dataset* utilizado ser pequeno e desbalanceado, o que pode comprometer a representatividade estatística necessária para treinar e testar adequadamente modelos de *deep learning*, especialmente na tarefa de detecção de posição. Esse aspecto pode restringir a generalização dos resultados obtidos para diferentes contextos e tópicos. Os resultados de aplicação do *pipeline* proposto nos ajudarão, em passo seguinte, a projetar as abordagens para a realização da tarefa de detecção de argumentação, sofisticando a identificação da estrutura do debate. Como trabalhos futuros, planejamos aumentar a quantidade de dados anotados utilizados para treinamento dos modelos, bem como explorar outras tarefas de um *pipeline* de mineração de argumentos. Outra estratégia prevista é explorar a utilização de *Large Language Models (LLMs)* [Zhao et al. 2023][(Brown et al., 2020)], abrindo a possibilidade de resumir o *pipeline* para apenas um modelo.

Agradecimentos

Os autores agradecem à FAPESP pelo financiamento desta pesquisa (#2021/14772-1). Renata Araujo é bolsista de produtividade em desenvolvimento tecnológico e extensão inovadora do CNPq (#305645/2022-6). Vitor dos Santos é bolsista TT1 pela FAPESP (#2023/04752-9). Livia Alabarse dos Santos é bolsa TT1 pela FAPESP (2023/04042-1).

Referências

- Addaood, A. e Bashir, M. (2016). “What Is Your Evidence? A Study of Controversial Topics on Social Media”. Em: *Proceedings of the Third Workshop on Argument Mining (ArgMining2016)*. Berlin, Germany. Association for Computational Linguistics. pages 1–11.
- Bosc, T., Cabrio, E. e Villata, S. (2016). “Tweeties Squabbling: Positive and Negative Results in Applying Argument Mining on Social Media”. *Frontiers in Artificial Intelligence and Applications*, v. 287, p. 21–32.
- Bosc, Tom, Cabrio, E. e Villata, S. (2016a). “DART: a Dataset of Arguments and their Relations on Twitter” Em: *Proceedings of the 10th edition of the Language Resources and Evaluation Conference*. pp. 1258-1263.
- Brown, T., Mann, B., Ryder, N., et al. (2020). Language Models are Few-Shot Learners. Em: *Advances in Neural Information Processing Systems*. Curran Associates, Inc.
- Carneiro, F. P. (2023). “BERTweet.BR: A Pre-Trained Language Model for Tweets in Portuguese”. Dissertação de Mestrado. Universidade Federal Fluminense, Programa de Pós-Graduação em Computação. Niterói.
- Cortiz, D. (2021) “Exploring transformers in emotion recognition: a comparison of bert, distillbert, roberta, xlnet and electra”. *arXiv*. arXiv:2104.02041.
- Costa, P. B., Pavan, M. C., Santos, W. R., Silva, S. C., & Paraboni, I. (2023). “BERTabaporu: Assessing a Genre-Specific Language Model for Portuguese NLP”. Em: *Proceedings of the 14th International Conference on Recent Advances in Natural Language Processing*, p. 217–223. Shoumen, Bulgaria. <https://aclanthology.org/2023.ranlp-1.24>
- Demszky, D., Movshovitz-Attias, D., Ko, J., Cowen, A.S., Nemade, G., & Ravi, S. (2020) “GoEmotions: A Dataset of Fine-Grained Emotions”. *arXiv*. arXiv:abs/2005.00547.
- Devlin, J., Chang, M.-W., Lee, K. and Toutanova, K. (2019). “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding”. Em: *Proceedings of the 2019 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies*, Association for Computational Linguistics.
- Lawrence, J., Bex, F., Reed, C. e Snaith, M. (2012) “AIFdb: Infrastructure for the Argument Web.” Em: *Proceedings of the 6th International Conference on Computational Models of Argument*. IOS Press. pp. 515-516.
- Lawrence, J. e Reed, C. (2020) “Argument mining: A survey”. *Computational Linguistics*, v. 45(4), pp. 765-818, 2020.
- Lippi, M., Torroni, P. (2016). “Argumentation mining: State of the art and emerging trends”. *ACM Transactions on Internet Technology*, 16(2), 1-25.
- Palau, R. M. e Moens, M. F. (2009). “Argumentation mining: the detection, classification and structure of arguments in text”. Em: *Proceedings of the 12th International Conference on Artificial Intelligence and Law*. pp. 98-107.
- Pedregosa, F., Varoquaux, G., Gramfort, A., Michel, V., Thirion, B., Grisel, O., ... e

- Duchesnay, E. (2011) "Scikit-learn: Machine learning in Python". *The Journal of machine Learning research*, 12,2825-2830.
- Pérez, J. M., Furman, D. A., Alonso Alemany, L., & Luque, F. M. (2022). "RoBERTuito: A pre-trained language model for social media text in Spanish". Em: *Proceedings of the Thirteenth Language Resources and Evaluation Conference*, p. 7235–7243. European Language Resources Association. <https://aclanthology.org/2022.lrec-1.785>
- Pérez, J. M., Rajngewerc, M., Giudici, J. C., Furman, D. A., Luque, F., Alemany, L. A., & Martínez, M. V. (2023). "pysentimiento: A Python Toolkit for Opinion Mining and Social NLP tasks". arXiv. <http://arxiv.org/abs/2106>.
- Salles, G. T., Coelho, O. B. (2022). "Reconhecimento de Emoções em Mineração de Argumentos com Deep Learning". Trabalho de Conclusão de Curso. Universidade Presbiteriana Mackenzie.
- Schaefer, R. e Stede, M. (2021). "Argument Mining on Twitter: A survey". *Information Technology*, v. 63, n. 1, p. 45–58.
- Silva, L. J., Santos, L. A.; Araujo, R., Coelho, O. B., Correa, A. G, D.; Oliveira, I. C. A. (2024) "Tweet_Eleições_2022: Um dataset de tweets durante as eleições presidenciais brasileiras de 2022". Brazilian Workshop on Social Network Analysis and Mining (BRASNAM), 13. Brasília/DF. Porto Alegre: Sociedade Brasileira de Computação. p. 193-199. <https://doi.org/10.5753/brasnam.2024.1940>.
- Slonim, N., Bilu, Y., Alzate, C., Bar-Haim, R., Bogin, B., Bonin, F., ... e Aharonov, R. (2021). "An autonomous debating system". *Nature*, 591(7850), p. 379-384.
- Sousa, J.P.S., Nascimento, R. C. U., Araujo, R. M., Coelho, O. B. (2021). "Não se perca no debate! Mineração de Argumentação em Redes Sociais". Brazilian Workshop on Social Network Analysis and Mining (BRASNAM). Porto Alegre: Sociedade Brasileira de Computação. p. 139-150. <https://doi.org/10.5753/brasnam.2021.16132>.
- Souza, F., Nogueira, R., & Lotufo, R. (2020). "BERTimbau: Pretrained BERT Models for Brazilian Portuguese", p. 403–417. https://doi.org/10.1007/978-3-030-61377-8_28
- Stede, M. e Schneider, J. (2019). "Argumentation Mining". Springer. Synthesis Lectures on Human Language Technologies.
- Sun, C., Qiu, X., Xu, Y. e Huang, X. (2019). "How to Fine-Tune BERT for Text Classification?" In Chinese Computational Linguistics. Lecture Notes in Computer Science. Springer International Publishing.
- Tokuda, N. H., Coelho, O. B., Araujo, R.M. (2021). "Análise de Sentimento por meio de Deep Learning aplicada à Mineração de Argumentos". Trabalho de Conclusão de Curso. Universidade Presbiteriana Mackenzie.
- Toulmin, S. E. (2003). *The uses of argument*. Cambridge University Press.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A.N., Kaiser, T. e Polosukhin, I. (2017). "Attention is All you Need". Em: *Advances in Neural Information Processing Systems*. Curran Associates, Inc. 30.
- Vecchi, E. M., Falk, N., Jundi, I., Lapesa, G. (2021). "Towards Argument Mining for

- Social Good: A Survey”. Em: *Proceedings of the 59th Annual Meeting of the Association for Computational Linguistics and the 11th International Joint Conference on Natural Language Processing*. Online. Association for Computational Linguistics. p. 1338–1352.
- Wagner Filho, J. A., Wilkens, R., Idiart, M., & Villavicencio, A. (2018). "The brWaC Corpus: A New Open Resource for Brazilian Portuguese". Em: *Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC 2018)*. European Language Resources Association (ELRA). <https://aclanthology.org/L18-1686>
- Walker, M. A., Tree, J. E. F., Anand, P., Abbott, R. e King, J. (2012). “A Corpus for Research on Deliberation and Debate”. Em: *Proceedings of the Eighth International Conference on Language Resources and Evaluation (LREC '12)* v. 12. Istanbul, Turkey. p. 812–817.
- Zhang, T., Wu, F., Katiyar, A., Weinberger, K. Q., & Artzi, Y. (2020) “Revisiting few-sample BERT fine-tuning”. arXiv preprint arXiv:2006.05987.
- Zhao, W. X., Zhou, K., Li, J., et al. (2023). “A Survey of Large Language Models”. Arxiv. arXiv. <http://arxiv.org/abs/2303.18223>.