

Caracterização, Evolução e Identificação de Padrões em Notícias Falsas: Uma Abordagem Voltada à Modelagem de Tópicos

Leonardo Emerson André Alves¹, Jonice Oliveira¹, Sirius Silva¹

¹Universidade Federal do Rio de Janeiro (UFRJ) – Rio de Janeiro – RJ – Brazil

{leonardoemerson,sirius}@ufrj.br, jonice@ic.ufrj.br

Abstract. *This study proposes a methodology capable of carrying out the characterization, evolutionary study and identification of writing patterns in fake news. In this way, the treatment and improvement of an unbalanced corpus was carried out. Subsequently, news analysis was carried out using natural language processing techniques and topic modeling using traditional algorithms (LDA and LSA). The results include the creation of a dictionary that characterizes the writing patterns present in the fake news studied, as well as the comparison of efficiency between the algorithms used through the use of the coherence metric.*

Resumo. *Este estudo propõe uma metodologia capaz de realizar a caracterização, o estudo evolucionar e a identificação de padrões de escrita em notícias falsas. Dessa forma, foi realizado o tratamento e aperfeiçoamento de um corpus não-balanceado. Posteriormente, foi realizada a análise das notícias com o uso de técnicas de processamento de linguagem natural e modelagem de tópicos fazendo uso de algoritmos tradicionais (LDA e LSA). Os resultados compreendem a criação de um dicionário que caracteriza os padrões de escrita presentes nas notícias falsas estudadas, bem como a comparação de eficiência entre os algoritmos utilizados por meio do uso da métrica de coerência.*

1. Introdução

Nos tempos atuais, o crescimento do número de usuários nas mídias sociais modificou os relacionamentos humanos na Internet. Nesse contexto, as informações falsas são frequentemente – e facilmente – propagadas [Vosoughi et al. 2018] [Guo et al. 2019] [Su et al. 2020], o que representa um risco tanto para a integridade dos meios de informação, quanto para a sociedade.

Como consequência da disseminação de desinformação, temos que as mesmas podem tanto moldar opiniões de cidadãos, quanto reforçar crenças em informações sem credibilidade [Gelfert 2021] e, conseqüentemente, temos que o comportamento dos indivíduos impactados é afetado [Bastick 2021]. Dessa forma, o combate à desinformação é um assunto de extrema importância para o atual fluxo informacional global, tendo em vista o impacto negativo de informações falsas em diversos processos sociais, tais como: eleições, administração de crises de saúde, consultas públicas de

opinião, entre outros. Esses impactos tanto ocorrem em processos democráticos, quanto em violações de direitos humanos ao redor do mundo [Colomina et al. 2021].

Esse trabalho propõe uma abordagem computacional para o combate a desinformação, sendo seu principal diferencial, a abordagem de um *corpus* não-balanceado de notícias falsas com texto em língua portuguesa, visando suprir a baixa quantidade de estudos com esse foco específico. Dessa forma, neste trabalho é investigado o avanço temporal dessas notícias, bem como são identificados os padrões de palavras e tópicos mais frequentes ao decorrer do texto, e suas influências na elaboração das principais *fake news*, visando a construção de um dicionário de tópicos que caracteriza as notícias falsas estudadas de acordo com seu período temporal de propagação. Para esse estudo foi utilizada uma versão do *corpus* FAKEPEDIA [Charles et al. 2022], que abrange conteúdos desinformativos disseminados entre os anos de 2013 e 2021.

2. Revisão de Literatura

A revisão de literatura da presente pesquisa compreendeu tanto o estudo de trabalhos voltados para a detecção automática de desinformação com o uso de técnicas de *machine learning*, quanto o estudo de trabalhos voltados à construção de bases de dados de notícias falsas, bem como o estudo de trabalhos associados à identificação de padrões e análise evolucionária de notícias falsas. Os principais trabalhos analisados na revisão de literatura visando abordagens computacionais para o combate à desinformação foram: [Melo e Figueiredo 2021], [Pérez-Rosas et al. 2017], [Reis 2020], [Monteiro et al. 2018], [Newman et al., 2006], [Pritzkau 2022] e [Nwankwo et al. 2020]. Ao analisar os trabalhos supracitados, é possível identificar uma lacuna no estudo da desinformação associado à caracterização de conjuntos de dados não-balanceados. No presente trabalho foi realizada uma análise exploratória considerando tanto o fator temporal, quanto o fator categórico para a caracterização de notícias falsas de um *corpus* não-balanceado contendo apenas notícias falsas. Adicionalmente, foram realizadas modelagens de tópicos a partir de divisões no *corpus*, de forma a compreender e caracterizar tanto temporalmente, quanto categoricamente as notícias falsas estudadas por meio da identificação de padrões nos textos estudados. Um dos pontos mais importantes do presente trabalho consiste na comprovação da hipótese de que os períodos temporais de disseminação, as temáticas abordadas e as entidades nomeadas mencionadas nas notícias falsas estudadas são fatores importantes para a identificação de padrões textuais em conjuntos não-balanceados.

3. Tratamento e Aperfeiçoamento do Corpus

O tratamento textual do *corpus* consistiu em um processo onde, inicialmente, foi realizada a remoção de frações de dados textuais não relevantes para a pesquisa, dentre as quais é possível destacar: anúncios, *e-mails*, telefones, sinais de pontuação, entre outras. O principal motivo para a limpeza realizada tem relação com a necessidade de obter um conjunto de dados sem ruídos para os posteriores processos de análise e modelagem de tópicos que, por sua vez, necessitam de dados textuais com o menor número de redundâncias. Além disso, outro motivo compreende o fato de que o dicionário de tópicos foi construído visando sua utilização em trabalhos futuros

concentrados no processo de identificação e classificação de notícias falsas e, conseqüentemente, a limpeza torna-se importante em sua construção para evitar a presença de palavras não coerentes com os tópicos construídos. Para o tratamento, foram adicionados dois atributos novos à base de dados, um dos atributos foi utilizado para o armazenamento do texto tratado com a remoção das *stopwords*, enquanto o outro atributo armazenou o texto tratado sem remoção de *stopwords*, o que permitiu a análise paralela dos dados trazendo benefícios para a interpretabilidade dos mesmos. A limpeza foi efetuada em um processo iterativo de três etapas, onde inicialmente foram realizadas consultas e buscas para a identificação de padrões de dados textuais sem relevância para a pesquisa como os já mencionados. Posterior a identificação dos padrões, foram construídas expressões regulares para captura desses padrões. Por fim, foram realizados os tratamentos adequados para cada tipo de padrão, tais como: remoção, substituição, entre outros.

Após a etapa de tratamento dos dados existentes no *corpus*, foi identificada a necessidade de adicionar novos dados ao *corpus* com o intuito de realizar a análise temporal e categórica das notícias falsas estudadas. Desse modo, foi aplicada a técnica de *Web Scraping* no site de origem das notícias presentes no *corpus* para obter tanto as datas de publicação, quanto às categorias temáticas de cada notícia. Após a obtenção desses dados, os mesmos foram adicionados ao *corpus* por meio da criação de dois novos atributos à base de dados.

4. Análise Exploratória e Evolução das Notícias Falsas

As notícias falsas estudadas foram analisadas temporalmente considerando informações, tais como: quantidade de publicações (ou disseminações), categorias temáticas, entidades nomeadas citadas nos conteúdos desinformativos, entre outras. O principal objetivo consistiu em compreender a evolução dos assuntos abordados nesse tipo de conteúdo. Os anos de 2013, 2014 e 2015 demonstraram uma quantidade muito baixa de publicações de desinformação em comparação com os outros anos e, conseqüentemente, foram estudados de maneira conjunta como um triênio.

Uma das primeiras descobertas feitas ao analisar o *corpus*, consiste na presença do advérbio “não” como a palavra mais frequente do *corpus* considerando as *stopwords*. Ao analisar essa evidência, é possível perceber a tendência para a falsidade das notícias estudadas, pois trabalhos anteriores mostram que declarações falsas podem ser detectadas a partir do estilo de escrita dos autores ou da linguística e, às vezes, podem ser usadas para inferir suas personalidades [Pennebaker e King 2000]. Adicionalmente, alguns autores mostraram que os mentirosos podem ser detectados enquanto contam histórias complexas, onde fazem menos auto-referências – para se dissociar da história, e tendem a utilizar com mais frequência a emoção negativa nas palavras – como sinal de culpa [Newman e Pennebaker 2003]. Logo, é possível associar emoções presentes nos textos estudados como uma sugestão para o exercício da disseminação de notícias falsas. Outro detalhe importante consiste na percepção de que ao analisar as palavras mais frequentes do *corpus* sem a presença de *stopwords*, surgiram: “Brasil”, “pessoas”, “Bolsonaro”, “Lula”, “presidente”, “governo”, entre outras. Dessa forma, é possível compreender um indício geral para o conteúdo mais abordado nas notícias falsas, isto é, assuntos ligados a acontecimentos nacionais e política. Analisando temporalmente, é

possível observar no triênio (2013-2015) um total de 220 notícias, com uma média de 7,3 notícias disseminadas por mês, onde o pico de disseminação ocorre em novembro de 2015 com 24 notícias falsas. Do ponto de vista temático, assuntos nacionais abrangem 20% do total, política corresponde a 16,36% e saúde detém 14,55%. As entidades mais recorrentes no triênio são: “Brasil” com 17 ocorrências, “Mensagem” e “Facebook” ambas com 6 ocorrências e “Lula” com 5 ocorrências. Portanto, essas entidades reforçam as categorias temáticas mais frequentes, e apontam assuntos nacionais e política como pautas mais recorrentes nesse período.

No ano de 2016 ocorre um aumento de 160% na quantidade de notícias falsas disseminadas com um total de 512 notícias no *corpus*. A média mensal de notícias falsas é de 47,6 notícias, nesse período. O ápice ocorre no mês de novembro com 66 notícias falsas. As temáticas mais abordadas são: política com 30,07% do total, assuntos nacionais com 25,52% e entretenimento com 11,01%. Nesse ano, as principais entidades nomeadas são: “Brasil” com 27 ocorrências, “Lula” com 26 ocorrências e “Dilma” com 21 ocorrências. Em 2017, também ocorre um aumento na quantidade de notícias falsas disseminadas, com um total de 739 notícias falsas, o que caracteriza 29,19% de crescimento em relação ao ano anterior. Nesse caso, assuntos nacionais é a categoria temática mais abordada com 32,34% do total, seguido por política com 24,63% e entretenimento com 8,39%. As entidades nomeadas que se destacaram nesse período foram: “Brasil” com 59 ocorrências, “R\$” (símbolo monetário) com 35 ocorrências e “Lula” com 29 ocorrências. A entidade nomeada “R\$” tem a maior parte de suas ocorrências associadas a notícias envolvendo falsos casos de corrupção.

Ao analisar o ano de 2018, é possível identificar um aumento de 39,91% em relação ao ano anterior, contabilizando um total de 1.034 notícias falsas no *corpus* nesse período. O tema política continua sendo um dos mais abordados com 36,94% do total, seguido por assuntos nacionais com 18,18% e tecnologia com 10,06%. Em 2018, a entidade “Bolsonaro” possui 110 ocorrências, a entidade “Lula” compreende 67 ocorrências e “Brasil” possui 61 ocorrências. As eleições de 2018 se caracterizam como um dos principais assuntos utilizados para construção de notícias falsas nesse período. No ano de 2019, ocorreu um decréscimo de 15,08% na quantidade notícias falsas disseminadas, totalizando 878 notícias falsas. A temática sobre política compreende 33,94% das notícias, seguida por assuntos nacionais com 19,93% e tecnologia com 10,25%. As entidades nomeadas com maior número de menções são: “Bolsonaro” com 100 ocorrências, “Lula” com 58 ocorrências e “Whatsapp” com 48 ocorrências.

O ano de 2020 volta a apresentar crescimento na quantidade de notícias falsas com 32,34% de aumento, contabilizando 1.162 notícias no *corpus*. Neste ano, a temática sobre política segue sendo a mais recorrente com 24,87% do total, seguido por notícias falsas sobre saúde com 22,63% e assuntos internacionais com 16,01%. A entidade nomeada “Covid-19” é a mais frequente com 143 ocorrências, seguida por “Bolsonaro” com 112 ocorrências e “China” com 66 ocorrências. Esses números evidenciam a pandemia de COVID-19 como o principal assunto utilizado para fabricação de conteúdos desinformativos nesse período. Em 2021, ocorre uma diminuição de 49,13% na quantidade de notícias falsas em relação ao ano anterior, totalizando 591 amostras. Nesse caso, saúde torna-se a temática mais abordada com 27,58% das notícias, seguida por política com 25,21% e tecnologia com 12,52%. Nesse

ano, novamente “Covid-19” é a entidade nomeada mais recorrente com 114 menções, seguida por “Bolsonaro” com 52 ocorrências e “Whatsapp” com 42 ocorrências.

5. Dicionário de Tópicos via Modelagem de Tópicos

Um dos principais artefatos construídos na presente pesquisa consiste no dicionário de tópicos que, por sua vez, tem como objetivo caracterizar as notícias falsas estudadas por meio da identificação dos padrões textuais mais usuais. Para a etapa de construção do dicionário de tópicos, foram utilizadas duas técnicas de modelagem de tópicos distintas: *Latent Dirichlet Allocation* (LDA) e *Latent Semantic Analysis* (LSA). Para cada uma das duas abordagens, foram gerados três dicionários de tópicos, totalizando seis dicionários de tópicos. Os três dicionários para cada modelagem têm as seguintes funções: caracterizar os tópicos do *corpus* por período de tempo (ano de publicação da notícia), descrever os tópicos do *corpus* por categoria (assunto da notícia publicada) e identificar os tópicos utilizando todas as amostras existentes no *corpus*, ou seja, realizando uma modelagem geral das notícias falsas presentes no conjunto de dados.

A construção do dicionário contou com uma etapa prévia de seleção e preparação dos dados, onde foi realizada a separação das porções de dados de acordo com o período temporal e a categoria temática. Nesse caso, as divisões temporais foram realizadas considerando o triênio (2013-2015) como um único conjunto, principalmente devido ao fato do período apresentar uma quantidade menor de notícias em relação aos outros anos, considerados individualmente. Por outro lado, as categorias temáticas foram todas separadas individualmente em: política, assuntos nacionais, assuntos internacionais, religião, ciência, entretenimento, esporte, saúde e tecnologia.

Posteriormente, os documentos foram tokenizados por meio da biblioteca para modelagem de tópicos *gensim*, onde a função *simple_preprocess* [Řehůřek e Sojka 2010] transformou os textos em listas de termos, denominados tokens, a partir das *strings* que representavam os textos por completo. As acentuações também foram removidas. Após essa etapa, foi realizado o tratamento em relação aos bigramas e trigramas presentes nos dados. Por fim, foi realizado o processo de lematização nos dados finais. O processo de lematização foi utilizado em decorrência dos benefícios que traz para a modelagem por meio do método LDA conforme pode ser visto em [May et al. 2019], onde é comprovado que a lematização otimiza os resultados relativos à modelagem de tópicos em linguagens morfologicamente ricas. Além disso, ao considerar o método LSA, temos que para sua execução, processar um *corpus* lematizado tende a ser computacionalmente mais eficiente conforme pode ser visto em [Zipitria et al. 2006].

A modelagem de tópicos utilizando o método LDA consistiu na realização inicial de uma modelagem com 10 tópicos para cada uma das divisões do *corpus*, visando obter um valor inicial para a métrica de coerência que indica quantitativamente a ocorrência mútua entre os termos associados ao tópico estudado que, por sua vez, se traduz em um valor que indica o pertencimento dos termos a um mesmo tema. O estudo [Röder et al. 2015], mostra que a métrica de coerência tem correlação com resultados advindos de observações humanas, ou seja, o julgamento humano sendo usado para determinar a qualidade dos tópicos se assemelha aos resultados calculados por meio da coerência. Posteriormente, foi realizada a modelagem de tópicos por meio da

otimização da métrica de coerência, onde foram ajustados os seguintes hiperparâmetros do modelo: número de tópicos (K), hiperparâmetro alfa do modelo de Dirichlet (α) e hiperparâmetro beta do modelo de Dirichlet (β). O ajuste desses hiperparâmetros foi realizado por meio de testes em sequência para cada hiperparâmetro e considerando dois conjuntos de validação do *corpus*. Um dos conjuntos de validação consiste em 75% dos dados do *corpus* utilizado, e o outro consiste em 100% dos dados do *corpus* utilizado.

No caso da modelagem geral foi obtido valor de coerência de 0,5467 para a modelagem com 10 tópicos, e após otimização dos hiperparâmetros com a metodologia proposta nesse trabalho foi alcançado um valor de 0,6136 para a métrica de coerência, o que caracteriza um percentual de melhora de aproximadamente 12,23%. A tabela 1 representa os valores de coerência obtidos na aplicação do método LDA nas divisões temporais. A média de ganho após otimização dos hiperparâmetros entre as modelagens em comparação com a modelagem inicial foi de 25,58%.

Tabela 1. Métrica de coerência do método LDA por período temporal

Ano	Coerência (Experimento inicial)	Coerência (Após otimização)	Percentual de ganho
2013-2015	0,4199	0,5511	31,24%
2016	0,3595	0,4952	37,74%
2017	0,4445	0,4802	8,03%
2018	0,4144	0,5172	24,80%
2019	0,3777	0,4735	25,36%
2020	0,4280	0,4929	15,16%
2021	0,3735	0,5108	36,76%

A tabela 2 traz informações sobre a métrica de coerência entre as categorias temáticas com o método LDA. A média de ganho após otimização dos hiperparâmetros nas modelagens em comparação com a modelagem inicial foi de 42,11%.

Tabela 2. Métrica de coerência do método LDA por categoria temática

Categoria	Coerência (Experimento inicial)	Coerência (Após otimização)	Percentual de ganho
Política	0,4642	0,6615	42,50%
Brasil	0,4016	0,6033	50,22%
Saúde	0,3275	0,4963	51,54%
Entretenimento	0,4305	0,6090	41,46%
Tecnologia	0,4288	0,5481	27,82%
Ciência	0,4517	0,5096	12,81%
Esporte	0,4147	0,5800	39,86%
Mundo	0,3230	0,5115	58,35%
Religião	0,3715	0,5738	54,45%

Na modelagem de tópicos com o uso do método LSA, o número K de tópicos foi a principal característica estudada para o treinamento do modelo, visto que é o principal hiperparâmetro para o treinamento do modelo final de tópicos. Dessa forma, foram treinados 17 modelos distintos, e para cada modelo foi alterado o número de tópicos, considerando o intervalo [4, 20] como possibilidades de valores para K . O valor de coerência de cada modelo foi obtido com o uso da classe *CoherenceModel*. Por fim, o modelo final é obtido com o valor de tópicos que resulta em máxima coerência. Na modelagem geral, a coerência atingiu o valor máximo com 8 tópicos. Para a modelagem temporal, a evolução da métrica de coerência com o percentual de ganho em relação à média pode ser vista na tabela 3.

Tabela 3. Métrica de coerência do método LSA por período temporal

Ano	Coerência Máxima	Coerência Média	Ganho
2013- 2015	0,6807	0,5994	13,56%
2016	0,4814	0,3890	23,75%
2017	0,5397	0,4424	21,99%
2018	0,6170	0,5130	20,27%
2019	0,4893	0,4110	19,05%
2020	0,4990	0,3884	28,47%
2021	0,4759	0,3941	20,75%

A tabela 4 caracteriza a métrica de coerência obtida nas divisões por categoria temática com o método LSA. A média de ganho após otimização dos hiperparâmetros entre as modelagens comparando com a modelagem inicial foi de 19,35%.

Tabela 4. Métrica de coerência do método LSA por categoria temática

Categoria	Coerência Máxima	Coerência Média	Ganho
Política	0,4335	0,3855	12,45%
Brasil	0,4979	0,4289	16,08%
Saúde	0,4476	0,3929	13,92%
Entretenimento	0,4520	0,4220	7,10%
Tecnologia	0,6435	0,5055	27,29%
Ciência	0,7869	0,6606	19,11%
Esporte	0,6926	0,5394	28,40%
Mundo	0,5302	0,4544	16,68%
Religião	0,6038	0,4534	33,17%

Comparando os métodos LDA e LSA na modelagem categórica, temos que a abordagem utilizando o método LDA obteve melhor resultado de modelagem nas seguintes categorias: Política, Assuntos Nacionais (Brasil), Saúde e Entretenimento. Por outro lado, a abordagem utilizando o método LSA obteve melhor resultado de modelagem nas seguintes categorias: Tecnologia, Ciência, Esporte, Assuntos internacionais (Mundo) e Religião. Na modelagem considerando os períodos temporais, o LDA obteve melhores resultados nos anos de 2016 e 2021, enquanto que o método LSA obteve valores maiores de coerência nos períodos de 2013-2015, 2017, 2018, 2019

e 2020. Por fim, considerando as modelagens gerais realizadas com as duas abordagens, o método LSA atingiu 0,4992, enquanto que o método LDA atingiu 0,6136. Portanto, é possível observar que o método LDA consegue melhores resultados ao lidar com *corpus* com maiores quantidades de documentos. Os dicionários de tópicos podem ser vistos com mais detalhes tanto em [Alves 2023], quanto no repositório¹ digital.

6. Contribuições em SI e Considerações Finais

A presente pesquisa demonstrou que o fator temporal (períodos temporais), o fator categórico (categorias/temáticas) e as entidades nomeadas presentes nos conteúdos de desinformação (notícias falsas, boatos, rumores, etc) estudados são fatores determinantes na identificação de padrões textuais. Como **contribuição científica** podemos mencionar que foi desenvolvida, no presente trabalho, uma metodologia para análise de padrões textuais de bases não-balanceadas de notícias falsas. Muitos dos trabalhos que foram estudados na revisão de literatura abordam o problema da desinformação utilizando conjuntos de documentos balanceados e, principalmente, com textos em língua inglesa. O *framework* desenvolvido pode ser utilizado em qualquer cenário que justifique a análise de desinformação, principalmente quando há um número desproporcional (base desbalanceada) de classes de documentos, sendo esta a principal **contribuição tecnológica** e **social**. O presente trabalho gerou um artigo [Alves et al., 2023] que foi selecionado e apresentado na Semana de Integração Acadêmica da UFRJ (SIAC/UFRJ).

Um sistema de informação pode ser entendido a partir de três dimensões: pessoas, organizações e tecnologia. Nesta pesquisa, as **Pessoas** englobam aqueles ligados diretamente aos resultados obtidos, como os que desenvolvem produtos ou pesquisas que auxiliem ao combate de *fake news*, ou ligados indiretamente, como os usuários de redes sociais online. As **Organizações** são compostas por unidades organizacionais públicas (e.g., Ministérios, unidades de comunicação) ou privadas (e.g., agências de *fact checking*, plataformas de conteúdo, jornais) que tenham como finalidade combater a desinformação. Além disso, estão envolvidos os centros ou laboratórios de pesquisas que estejam estudando o assunto. A **Tecnologia** é o ferramental (análises, código e dicionário) produzido, e que pode ser reutilizado.

Esta pesquisa tange alguns dos **Grandes Desafios da área de SI** descritos em [Araujo et al. 2017]. Inicialmente, as redes sociais online podem ser consideradas “Sistemas de Sistemas”, trazendo desafios para a sua construção e principalmente para a gestão do seu conteúdo. Conforme dito no capítulo “Sistemas de Informação e os desafios do mundo aberto”: “...Nos defrontamos com a complexidade que nos oferece a construção de sistemas cada vez menos caracterizados como um artefato fechado e intraorganizacional e cada vez mais como um organismo de conexão intra, inter e socio-organizacional, de comportamento imprevisível e emergente”. A criação de informação (seja ela verídica ou desinformação) está ligada ao desafio de mundo aberto, tendo em vista que a criação, disseminação, uso e alteração de um conteúdo nas mídias sociais não possui mais fronteiras tecnológicas, geográficas e institucionais. A rápida proliferação de uma desinformação pode trazer consequências danosas e imprevisíveis. Consequentemente, surgem desafios no desenvolvimento deste tipo de sistema. Desafios

¹ Disponível em: <https://github.com/leonardoemerson/TCC-Leonardo-Emerson>

no quesito técnico, como identificar automaticamente ou semi-automaticamente uma desinformação para a tomada de uma decisão, seja esta decisão um alerta sobre o conteúdo, a sua remoção ou a conscientização popular. Outro desafio é uma abordagem Sociotécnica, envolvendo uma “Visão Sistêmica e Socialmente Consciente”. Como principal trabalho futuro mencionamos a inclusão da abordagem “*human-in-the-loop*”, adicionando a colaboração humana para inferências em conteúdos falsos.

Referências

- Alves, L. E. A. (2023). Caracterização, evolução e identificação de padrões em notícias falsas: uma abordagem voltada à modelagem de tópicos. Trabalho de Conclusão de Curso. Universidade Federal do Rio de Janeiro. Disponível em: <https://pantheon.ufrj.br/handle/11422/21240>. Acessado em 06/01/2024.
- Alves, L.E.A et al. (2023). Caracterização, evolução e identificação de padrões em notícias falsas via modelagem de tópicos (id: 2845). Semana de Integração Acadêmica da UFRJ (12.:2023): CCMN.
- Araujo, R.M.; Maciel, R.S.; Boscarioli, C. “I GranDSI-BR: Grandes Desafios de Pesquisa em Sistemas de Informação no Brasil (2016-2026)” - Relatório Técnico. Comissão Especial de Sistemas de Informação (CE-SI) da Sociedade Brasileira de Computação (SBC). 67P, 2017. ISBN 978-85-7669-359-8.
- Bastick, Z. (2021). Would you notice if fake news changed your behavior? An experiment on the unconscious effects of disinformation. *Computers in Human Behavior*, v. 116, p. 106633.
- Charles, A., Ruback, L. and Oliveira, J. (2022). Fakepedia Corpus: A Flexible Fake News Corpus in Portuguese. International Conference on Computational Processing of the Portuguese Language (pp. 37-45). Springer International Publishing.
- Colomina, C., Margalef, H. S. and Youngs, R. (2021). The impact of disinformation on democratic processes and human rights in the world. Brussels: European Parliament.
- Gelfert, A. (2021). Fake News, False Beliefs, and the Fallible Art of Knowledge Maintenance. In: Bernecker, S.; Flowerree, A. K.; Grundmann, T.[Eds.]. *The Epistemology of Fake News*. Oxford University Press. p. 0.
- Guo, B., Ding, Y., Yueheng, S., Ma, S. and Li, K. (2019). *The Mass, Fake News, and Cognition Security*.
- May, C., Cotterell, R. and Van Durme, B. (2019). An Analysis of Lemmatization on Topic Models of Morphologically Rich Language. arXiv. Disponível em <http://arxiv.org/abs/1608.03995>. Acessado em 11/01/2024.
- Monteiro, R. A., Santos, R. L. S., Pardo, T. A. S., et al. (2018). Contributions to the Study of Fake News in Portuguese: New Corpus and Automatic Detection Results. [A. Villavicencio, V. Moreira, A. Abad, et al., Eds.]In *Computational Processing of the Portuguese Language*. , Lecture Notes in Computer Science. Springer International Publishing.
- Melo, Tiago de; Figueiredo, Carlos M. S. Comparing News Articles and Tweets About

- COVID-19 in Brazil: Sentiment Analysis and Topic Modeling Approach. *JMIR Public Health and Surveillance*, v. 7, n. 2, p. e24585, 2021.
- Newman, D., Chemudugunta, C., Smyth, P. and Steyvers, M. (2006). Analyzing Entities and Topics in News Articles Using Statistical Topic Models. [S. Mehrotra, D. D. Zeng, H. Chen, B. Thuraisingham, & F.-Y. Wang, Eds.]In *Intelligence and Security Informatics*. , Lecture Notes in Computer Science. Springer.
- Newman, Matthew; Pennebaker, James; Berry, Diane; et al. Lying Words: Predicting Deception from Linguistic Styles. *Personality & social psychology bulletin*, v. 29, p. 665–75, 2003.
- Nwankwo, E., Okolo, C., Habonimana, C. and Beach, C.-L. (2020). Topic Modeling Approaches for Understanding COVID-19 Misinformation Spread in Sub-Saharan Africa.
- Pennebaker, James & King, Laura. (2000). Linguistic styles: Language use as an individual difference. *Journal of personality and social psychology*. 77. 1296-312. 10.1037//0022-3514.77.6.1296.
- Pérez-Rosas, V., Kleinberg, B., Lefevre, A. and Mihalcea, R. (2017). Automatic Detection of Fake News. arXiv. Disponível em <http://arxiv.org/abs/1708.07104>. Acessado em 11/01/2024.
- Pritzkau, A., Blanc, O., Geierhos, M. and Schade, U. (2022). NLYtics at CheckThat! 2022: Hierarchical multi-class fake news detection of news articles exploiting the topic structure.
- Řehůřek, R. and Sojka, P. (2010). Software Framework for Topic Modelling with Large Corpora.
- Reis, J. C. S. and Benevenuto, F. (2021). Towards Automatic Fake News Detection in Digital Platforms: Properties, Limitations, and Applications. In *Anais do Concurso de Teses e Dissertações (CTD)*. SBC. Disponível em <https://sol.sbc.org.br/index.php/ctd/article/view/15754>. Acessado em 11/01/2024.
- Röder, M., Both, A. and Hinneburg, A. (2015). Exploring the Space of Topic Coherence Measures. In *Proceedings of the Eighth ACM International Conference on Web Search and Data Mining*. , WSDM '15. Association for Computing Machinery. Disponível em <https://doi.org/10.1145/2684822.2685324>. Acessado em 11/01/2024.
- Su, Q., Wan, M., Liu, X. and Huang, C.-R. (2020). Motivations, Methods and Metrics of Misinformation Detection: An NLP Perspective. *Natural Language Processing Research*, v. 1, n. 1–2, p. 1–13.
- Vosoughi, S., Roy, D. and Aral, S. (2018). The spread of true and false news online. *Science*, v. 359, n. 6380, p. 1146–1151.
- Zipitria, I., Arruarte, A. and Elorriaga, J. A. (2006). Observing Lemmatization Effect in LSA Coherence and Comprehension Grading of Learner Summaries. [M. Ikeda, K. D. Ashley, & T.-W. Chan, Eds.]In *Intelligent Tutoring Systems*. , Lecture Notes in Computer Science. Springer.