

Redes Neurais e Processamento de Linguagem Natural na Detecção de Fake News: Uma Revisão Sistemática da Literatura

Andressa F. Schons¹, Camila F. Antunes¹, Laura O. Cunha¹, Andrws A. Vieira¹, Claudiany C. de Sousa¹.

¹ Coordenação de Ciência da Computação do Instituto Federal do Rio Grande do Sul (IFRS) - R. Nelsi Ribas Fritsch, 1111 - Esperança, Ibirubá - RS, 98200-000

{camilafeLdantunes,oliveiradacunhalaura,andressaschons, andrwsvieira, claudianydesousa}@gmail.com

1. Introdução

O Processamento de Linguagem Natural (PLN) é uma área da Ciência da Computação que investiga e propõe métodos e sistemas para o processamento computacional da linguagem humana [Caseli e Nunes, 2024]. Essa área envolve um conjunto de técnicas e algoritmos que permitem que computadores processem dados textuais ou falados, compreendendo nuances como contexto, significado e estrutura gramatical. Para alcançar tais capacidades, o PLN se apoia em diversas abordagens, sendo uma das mais poderosas o uso de Redes Neurais Artificiais (RNAs).

O estudo de PLN abrange diversas aplicações práticas, incluindo a análise de sentimentos em textos, a busca e recuperação de informações em bancos de dados textuais e a tradução automática, entre outras. Cada uma dessas aplicações é conhecida como uma “tarefa”, cujo objetivo é analisar e representar ocorrências naturais de texto, buscando um processamento que se assemelhe ao realizado pelos seres humanos [Alves, 2019].

As Redes Neurais Artificiais (RNAs), por sua vez, são modelos matemáticos inspirados no funcionamento dos neurônios biológicos. Esses modelos têm capacidade de adaptação, aprendizado e identificação de padrões a partir de grandes volumes de dados, o que possibilita uma compreensão mais profunda e precisa da linguagem. O treinamento de RNAs em vastas bases textuais viabiliza o desenvolvimento de sistemas sofisticados de PLN, como tradutores automáticos, assistentes virtuais e ferramentas de análise de sentimentos, que transformam significativamente a forma como interagimos com as máquinas.

O funcionamento das RNAs baseia-se no recebimento de sinais pelas variáveis de entrada, no processamento desses dados por cada neurônio e na transmissão dos resultados às camadas subsequentes [Silva, 2021], dessa forma, os fundamentos das redes neurais envolvem neurônios artificiais que processam informações realizando uma combinação linear das entradas com seus respectivos pesos. Em seguida, esse resultado é passado por uma função de ativação, que introduz não linearidade ao modelo e permite a representação de padrões mais complexos. Essa estrutura é operada por um algoritmo de aprendizagem, que, conforme Oliveira (2019), treina a rede com base nos dados fornecidos, os quais podem conter tanto informações verdadeiras quanto falsas.

Literaturas mais recentes ampliam essa perspectiva. Teles (2023) destaca as chamadas redes neurais profundas, que empilham múltiplas camadas de neurônios, permitindo a aprendizagem de representações hierárquicas dos dados. Essa profundidade torna possível capturar relações não lineares e padrões abstratos que não seriam modeláveis por estruturas mais

simples, aumentando a capacidade das RNAs de filtrar informações e, por consequência, auxiliar na detecção e contenção da propagação de *fake news*.

Contudo, é necessário cautela ao se referir ao “aprendizado” das RNAs. Negri (2020) argumenta que, diferentemente da aprendizagem humana, que envolve raciocínio abstrato, compreensão contextual e capacidade de generalização, as RNAs apenas ajustam os pesos das conexões neuronais com o objetivo de minimizar erros em tarefas específicas. Essa distinção é essencial para evitar a antropomorfização da inteligência artificial.

Ferreira (2022) chama a atenção para o fato de que, atualmente, redes neurais são amplamente empregadas em aplicações como reconhecimento de padrões de fala, tradução automática e moderação de conteúdo em redes sociais.

Entre os modelos de aprendizagem de máquina, as RNAs são classificadas como modelos paramétricos, pois seu treinamento consiste na estimativa e ajuste de parâmetros com o intuito de caracterizar sua atuação, minimizando as perdas geradas pelos dados de entrada [Alves, 2019].

Teles (2023) ressalta que as RNAs não geram conhecimento de forma autônoma; elas dependem dos dados previamente processados, fornecidos principalmente por técnicas de PLN. Esse pré-processamento envolve a remoção de pontuação, números e palavras irrelevantes, preparando os dados para que possam ser efetivamente utilizados como entrada nos modelos neurais.

Nesse sentido, este artigo tem por objetivo apresentar os resultados de uma investigação de como as RNAs estão sendo aplicadas no reconhecimento de padrões de fala e na tradução automática no contexto das *fake news*. A detecção de notícias falsas é um tema emergente na inteligência artificial, que tem despertado o interesse de pesquisadores ao redor do mundo [Kaliyar *et al*, 2020].

Para alcançar esse objetivo, foi elaborada uma Revisão Sistemática da Literatura (RSL) que é um do método utilizado para identificar, avaliar e interpretar todas as pesquisas disponíveis relevantes para uma determinada questão de pesquisa, área temática ou fenômeno de interesse [Kitchenham e Charters, 2007]. A pesquisa foi guiada pelas seguintes questões:

- Como o PLN está sendo aplicado na identificação de padrões de fala, tradução e assistentes virtuais?
- De que maneira o PLN está sendo utilizado nas redes neurais artificiais?
- Qual é a contribuição das RNAs e do PLN no combate às *fake news*?

Com base nessas questões, foram analisados artigos selecionados a partir de palavras-chave, permitindo uma investigação aprofundada das abordagens apresentadas em cada um deles, além de explorar a relação com os demais temas pertinentes. O presente artigo está estruturado da seguinte forma: a Seção 2 apresenta o percurso metodológico adotado na revisão, a Seção 3 expõe os resultados e a Seção 4 traz as considerações finais.

2. Metodologia

A metodologia utilizada neste estudo foi proposta por Kitchenham e Charters (2007), obedecendo a um protocolo específico de revisões sistemáticas a qual inclui as seguintes atividades: a) Planejamento: responsável por definir os métodos da pesquisa e formular perguntas claras e objetivas, conforme apresentado na Seção 1. b) Condução da Revisão: envolve a busca sistemática em bases de dados, a seleção de estudos com base em critérios definidos e a análise do rigor e validade dos estudos incluídos (Seção 2). c) Relato da Revisão: define como os resultados serão estruturados e apresentados (Seção 3), além da elaboração do texto final.

2.1 Estratégias de Busca

O levantamento da literatura foi realizado por meio de consultas estruturadas em repositórios acadêmicos como IEEE Xplore, Google Acadêmico, Elsevier, além de periódicos científicos, anais de eventos promovidos pela Sociedade Brasileira de Computação e publicados no SBC-Open Lib. Além disso, aplicou-se um filtro temporal, selecionando apenas estudos publicados entre 2020 e 2024.

Como estratégia de busca, foram utilizados termos específicos (palavras-chave) relacionados à pesquisa, como *fake news*, *processamento de linguagem natural* e *redes neurais*, além de termos mais amplos, como *inteligência artificial* e *desinformação*. Para otimizar os resultados, os termos foram combinados usando os operadores booleanos OR e AND, permitindo a recuperação de trabalhos em português e inglês. A string de busca final utilizada foi: (“*fake news*” OR “notícias falsas” OR “desinformação”) AND (“*neural networks*” OR “redes neurais” OR “processamento de linguagem natural” OR “*Natural Language Processing*” OR “inteligência artificial” OR “*Artificial Intelligence*”).

2.2 Critérios de Seleção

O Quadro 1 apresenta os critérios de inclusão e exclusão adotados para a seleção dos trabalhos na revisão sistemática. Esses critérios garantem a relevância e a qualidade dos estudos considerados, filtrando aqueles que não atendem aos requisitos definidos.

Quadro 1. Critérios de Inclusão e Exclusão

Critérios de Inclusão	Critérios de Exclusão
O trabalho deve estar disponível na web.	Resumos, editoriais, cartas ao editor e opiniões.
O trabalho deve estar completo.	Artigos duplicados em diferentes bases de dados.
O trabalho deve apresentar informações claras sobre os autores ou a origem da publicação.	Artigos com amostra insuficiente ou pouco representativa.
O trabalho deve estar no idioma: português ou inglês.	Pesquisas com dados desatualizados ou irrelevantes para o contexto da revisão.
Trabalho publicado entre 2020 e 2024.	Trabalhos publicados fora do intervalo de tempo definido.
O trabalho deve ter relevância abordando diretamente a temática da pesquisa, como <i>fake news</i> , <i>processamento de linguagem natural</i> e <i>redes neurais</i> .	Estudos com metodologia inadequada ou não claramente descrita.

3. Análise e Discussão dos Resultados

Nesta seção, são apresentados os trabalhos selecionados e os resultados das análises, além das discussões e respostas às questões que nortearam o estudo. A análise foi conduzida por meio da leitura exploratória dos trabalhos selecionados, com base na metodologia de análise de conteúdo de Bardin (2011). A sistematização dos textos selecionados possibilitou uma compreensão mais aprofundada do tema.

3.1. Trabalhos selecionados

Para a presente revisão sistemática, foram selecionados oito trabalhos que investigam o uso PLN, Redes Neurais ou IA no contexto de combate à *fake news*. O Quadro 2 apresenta um resumo dos estudos, incluindo título, autores, ano de publicação e o objetivo, envolvendo a abordagem ou técnica utilizada para a detecção de *fake news*.

Quadro 2. Trabalhos selecionados.

Ano de publicação	Autoria e Título dos artigos	Objetivo
2020	OSHIKAWA, Ray; QIAN, Jing; WANG, William Yang. A survey on natural language processing for fake news detection.	Deteção de <i>fake news</i> , em pequenos textos ou grandes artigos, a partir de banco de dados que é escolhido dependendo de qual tipo de texto está sendo analisado.
2021	LIMA, Pablo de Andrades. CFN-AI: Um classificador de notícias falsas baseado em Inteligência Artificial.	Análise de trabalhos sobre o uso de IA para identificação de notícias falsas e criação de um modelo de detecção de <i>fake news</i> utilizando a pesquisa de Zhang e Wallace (2016) como base.
2021	GOLDANI, Mohammad Hadi; MOMTAZI, Saeedeh; SAFABAKHSH, Reza. Detecting fake news with capsule neural networks. Applied Soft Computing.	Propõe um modelo baseado em redes de cápsulas para melhorar a detecção de notícias falsas, sugerindo arquiteturas distintas de acordo com a extensão do texto (curto, médio ou longo) e técnicas avançadas de extração de características para aumentar a precisão do sistema.
2022	VILLELA, Humberto Fernandes et al. Uma análise da acurácia obtida e datasets utilizados em algoritmos de identificação de fake news.	Analisar a acurácia obtida e os <i>datasets</i> utilizados em algoritmos de identificação de <i>fake news</i> , fazendo uma comparação entre eles.
2022	TEMBHURNE, Jitendra Vikram; ALMIN, Md Moin; DIWAN, Tausif. Mc-DNN: Fake news detection using multi-channel deep neural networks. International Journal on Semantic Web and Information Systems (IJSWIS).	Produção de uma rede neural de multicanais para detecção de <i>fake news</i> tanto em títulos quanto nas notícias. Esse modelo utiliza <i>deep learning</i> para capturar padrões sutis na estrutura linguística das notícias falsas e reais, aumentando a precisão da detecção.
2023	YANG, Yang et al. TI-CNN: Convolutional neural networks for fake news detection.	Desenvolver um modelo eficiente de detecção automática de notícias falsas, o TI-CNN, que combina características explícitas e latentes de textos e imagens para superar os desafios da verificação de fatos.
2024	ALVES, Leonardo Emerson A.; OLIVEIRA, Jonice; DA SILVA, Sirius Thadeu F. Reconhecimento e Compartilhamento de Padrões Textuais em Notícias Falsas.	Revisão de literatura e comparação de métodos de modelagem de tópicos LDA e LSA e a aplicação do PLN para analisar e identificar padrões em <i>fake news</i> escritas em português-brasileiro, ajudando a compreender a evolução e estrutura dessas notícias ao longo do tempo.
2024	CASELI, Helena de Medeiros; NUNES, Maria das Graças Volpe (Org.). Processamento de Linguagem Natural: Conceitos, Técnicas e Aplicações em Português. 2ª ed.	Analisar a evolução do PLN no Brasil, destacando o crescimento da comunidade acadêmica, a criação de eventos especializados como o PROPOR e o STIL, e a formação de grupos pioneiros como o NILC. Além de evidenciar a demanda por PLN no mercado, impulsionando novas pesquisas e aplicações na computação.

A leitura dos trabalhos nos mostra que o PLN, área da inteligência artificial que estuda a linguística computacional e se encarrega de analisar e classificar textos ou transcrições antes de processá-los, utiliza técnicas como a ASR (*Automatic Speech Recognition*, ou reconhecimento automático de fala) para identificar padrões de fala e converter sinais acústicos em texto. Tal processo é utilizado em diversas aplicações, como assistentes virtuais, que precisam entender a fala do usuário antes de interagir.

O PLN pode ser aplicado em conjunto com as Redes Neurais Artificiais (RNAs) para otimizar o tratamento de dados de entrada. Como as RNAs não criam novos conhecimentos, mas apenas processam informações com base nos dados fornecidos, é essencial que esses dados sejam pré-processados e organizados corretamente. O PLN desempenha um papel fundamental nesse processo, filtrando e estruturando os dados para garantir que apenas informações relevantes sejam enviadas às redes neurais. Dessa forma, o PLN não apenas melhora a eficiência das RNAs, mas também contribui para a verificação da veracidade das informações, tornando a análise mais precisa e confiável.

A estrutura da rede neural influencia diretamente o processamento dos dados de entrada durante o treinamento, permitindo que um mesmo banco de informações seja utilizado de diferentes maneiras. Por exemplo, uma rede projetada para detectar *fake news* a partir apenas do título de um artigo será treinada de forma distinta de outra que analisa textos completos, pois esta última exige uma compreensão mais profunda do contexto e um volume maior de informações.

Estudos recentes, especialmente no período pós-pandemia, indicam que a disseminação de *fake news* tem aumentado significativamente. Além disso, a inteligência artificial, embora amplamente utilizada para fins benéficos, também tem sido empregada para manipulação do público e criação de *deepfakes*, levantando preocupações sobre seu uso indevido.

3.2 Resposta para as questões de pesquisa

a) Como o PLN está sendo aplicado na identificação de padrões de fala, tradução e assistentes virtuais?

O Processamento de Linguagem Natural mostra-se essencial para identificação de padrões de escrita e fala, usando técnicas como ASR para identificar padrões e converter sinais acústicos em texto. Tal processo serve para muitas aplicações, como assistentes virtuais, que interpretam as informações dos usuários, enquanto técnicas de análise de semântica e aprendizado de máquina aprimoram tradução automática. Os avanços dos estudos sobre PLN têm evoluído a tradução automática e a interação com assistentes virtuais, tornando essas tecnologias mais precisas, acessíveis e eficientes [Caseli, Nunes, 2024].

b) De que maneira o processamento de linguagem natural está sendo utilizado nas redes neurais artificiais?

O processamento de linguagem natural utiliza-se de técnicas que permitem que modelos aprendam representações semânticas mais profundas, sendo essenciais para tarefas como classificação de textos, tradução automática e detecção de *fake news* [Yang et al, 2023], para que posteriormente os dados sejam processados pelas RNAs. A detecção automatizada reduz o tempo e o esforço humano, além de oferecer soluções mais rápidas para identificar as *fake news*. As pesquisas nesse campo buscam modelos mais práticos, além de explorar a importância das soluções de PLN para lidar com esse problema [Oshikawa, Qian, Wang, 2023].

c) Qual é a contribuição das RNAs e do PLN no combate à *fake news*?

O combate às *fake news* torna-se mais fácil utilizando-se das RNAs e o PLN visto que essas ferramentas automatizam a verificação das notícias falsas. Com o crescimento das

plataformas de redes sociais, a disseminação de *fake news* aumentou, tornando ainda mais importante a criação de modelos que identifiquem e previnam sua propagação de maneira rápida e eficaz, analisando os textos em tempo real, funcionando até mesmo em grandes volumes de dados. As pesquisas nesse campo buscam modelos mais práticos, além de explorar a importância das soluções de PLN para lidar com esse problema [Oshikawa, Qian, Wang, 2023].

É notório que o processo para criação de uma rede neural que faça o reconhecimento da *fake news* não é tão fácil, pois os dados necessários para que o assistente aprenda a verificar a veracidade deve ser adequado à forma de construção desse agente. A forma como as notícias são divididas durante o ensinamento da RNA e a modelagem dos dados influencia a otimização das análises de padrão das *fake news* [Alves, Oliveira, da Silva, 2024].

4. Conclusão

Observa-se que a relação entre *fake news*, PLN e RNAs ainda é um campo pouco explorado, especialmente entre pesquisadores brasileiros. No entanto, a disseminação de desinformação continua crescendo. Estudos indicam que a geração de notícias falsas tende a aumentar e que suas características se tornarão cada vez mais sofisticadas e convincentes. Diante disso, pesquisas têm investido no uso de tecnologias de PLN e redes neurais para automatizar a identificação de conteúdos falsos.

Contudo, a automatização levanta questionamentos éticos relevantes. São válidas pesquisas que questionem se a velocidade na detecção proporcionada pela automação compensa possíveis erros de julgamento, pois uma notícia pode ser identificada erroneamente como falsa, e, considerando que as RNAs não compreendem contexto ou intenção, torna-se difícil de diferenciar uma sátira de uma opinião. Esse cenário levanta preocupações sobre o equilíbrio entre eficácia e responsabilidade, especialmente diante do risco do uso intensivo de PLN e RNAs em ambientes como redes sociais, pois pode gerar mecanismos de moderação automatizados que suprimam conteúdos legítimos por engano, causando censura algorítmica. Além disso, a definição de '*fake news*' é subjetiva. Os dados usados no treinamento podem refletir visões de mundo específicas, reforçando vieses ideológicos ou culturais.

Um exemplo emblemático ocorreu durante o início da pandemia de COVID-19, quando a hipótese de que o vírus teria se originado em um laboratório em Wuhan foi rotulada como *fake news* e removida de plataformas digitais. Entretanto, investigações posteriores mostraram que essa possibilidade não era infundada, sendo considerada plausível por agências oficiais de diversos países (Leblanc, 2023). Esse caso evidencia que, em contextos complexos e politicamente sensíveis, decisões automatizadas podem classificar como desinformação conteúdos que, mais tarde, revelam-se parte de um debate científico legítimo.

Felizmente, muitos pesquisadores têm estudado sobre o uso do PLN na detecção de *fake news*, buscando transformar essa tecnologia em uma aliada no combate à desinformação. Estudos sobre bases de dados utilizadas no treinamento de RNAs e Inteligências Artificiais focadas na verificação da autenticidade das informações mostram que, quando treinadas adequadamente, as IAs podem desempenhar um papel central na identificação e mitigação da propagação de notícias falsas.

Acredita-se que, para futuras pesquisas, seria importante aprofundar o estudo sobre as formas de constituição das bases de dados, visando aumentar sua capacidade de entrada, especialmente em línguas que não o inglês, uma vez que o idioma é fundamental para o treinamento e a verificação da veracidade das notícias. Essa limitação pode reforçar desigualdades informacionais, já que modelos treinados majoritariamente em inglês tendem a ser menos precisos em outros contextos linguísticos e culturais.

Apesar desses desafios, os avanços na pesquisa sobre PLN e RNAs oferecem um grande potencial para mitigar a propagação de *fake news*, desde que as bases de dados sejam mais inclusivas e ajustadas para refletir a diversidade linguística e cultural global. Portanto, enquanto as tecnologias de PLN e RNAs têm um papel central a desempenhar no combate à desinformação, elas devem ser implementadas com cautela, sempre considerando a necessidade de equilibrar eficácia e responsabilidade ética.

5. Referências

ALVES, J. L. D. (2019) "Redes neurais recorrentes aplicadas à classificação de fake news em língua portuguesa". 158 f. Dissertação (Mestrado Profissional em Engenharia de Produção e Sistemas Computacionais) – Universidade Federal Fluminense, Rio das Ostras. Disponível em: <https://app.uff.br/riuff/handle/1/13195>. Acesso em: nov. 2024.

ALVES, L. E. A.; OLIVEIRA, J.; DA SILVA, S. T. F. (2024) "Reconhecimento e Compartilhamento de Padrões Textuais em Notícias Falsas". In: *Anais do Congresso da Sociedade Brasileira de Computação*. Porto Alegre, p. 138-145.

BARDIN, L. (2011) *Análise de conteúdo*. Tradução de Luís Antero Reto e Augusto Pinheiro. São Paulo: Edições 70. Tradução de: *L'Analyse de Contenu*, 1997. Disponível em: <https://ia802902.us.archive.org/8/items/bardin-laurence-analise-de-conteudo/bardin-laurence-analise-de-conteudo.pdf>. Acesso em: nov. 2024.

CASELI, H. M.; NUNES, M. G. V. (2024) *Processamento de Linguagem Natural: conceitos, técnicas e aplicações em português*. São Carlos: BPLN. Disponível em: <https://brasileiraspln.com/livro-pln/>. Acesso em: nov. 2024.

FERREIRA, A. B. N. M. (2022) "Otimização multiobjetivo baseada em modelos substitutos para compressão de redes neurais artificiais". Monografia (Graduação em Engenharia de Controle e Automação) – Universidade Federal de Ouro Preto. Disponível em: https://monografias.ufop.br/bitstream/35400000/3940/1/MONOGRRAFIA_OtimizacaoMultiobjetivoBaseada.pdf. Acesso em: novembro de 2024.

GOLDANI, M. H.; MOMTAZI, S.; SAFABAKHSH, R. (2021) "Detecting fake news with capsule neural networks". *Applied Soft Computing*, v. 101, p. 106991.

KALIYAR, R. K.; GOSWAMI, A.; NARANG, P.; SINHA, S. (2020) "FNDNet – Uma rede neural convolucional profunda para detecção de notícias falsas". *Cognitive Systems Research*, v. 61, p. 32-44, jun. Disponível em: https://www.sciencedirect.com/science/article/pii/S1389041720300085?dgcid=api_sd_search. Acesso em: nov. 2024.

KITCHENHAM, B. A.; CHARTERS, S. (2007) Guidelines for performing systematic literature reviews in software engineering. Tech. Rep. EBSE-2007-01, Keele University.

LEBLANC, P. (2023) "Análise: nova avaliação sobre origem da Covid-19 aumenta confusão". CNN Brasil. Disponível em: <https://www.cnnbrasil.com.br/saude/analise-nova-avaliacao-sobre-origem-da-covid-19-aumenta-confusao/>. Acesso em: 15 maio 2025.

LIMA, I.; PINHEIRO, C. A. M.; SANTOS, F. A. O. (2014) *Inteligência Artificial*. Rio de Janeiro: GEN LTC. 1 recurso online. ISBN 9788595152724.

LIMA, P. A. (2021) CFN-AI: *Um classificador de notícias falsas baseado em Inteligência Artificial*. 63 p. Trabalho de Conclusão de Curso (Bacharelado em Engenharia da Computação) – Universidade Federal do Pampa, Curso de Ciência da Computação, Bagé.

NEGRI, S. M. C. A. (2020) "Robôs como pessoas: a personalidade eletrônica na robótica e na inteligência artificial". Disponível em: https://www.researchgate.net/publication/343727531_Robos_como_pessoas_a_personalidade_eletronica_na_Robotica_e_na_Inteligencia_Artificial. Acesso em: novembro de 2024.

OLIVEIRA, L. M. R. (2019) "Inteligência Artificial Aplicada à Detecção de Fake News". Monografia (Graduação em Ciência da Computação) – Universidade Federal do Maranhão, 15 jul. Disponível em: <http://hdl.handle.net/123456789/4251>. Acesso em: nov. 2024.

OSHIKAWA, R.; QIAN, J.; WANG, W. Y. (2020) "A survey on natural language processing for fake news detection". *arXiv preprint*, arXiv:1811.00770, v.2.

SILVA, D. E. (2021) "Redes neurais artificiais e processamento de linguagem natural aplicados à previsão do minicontrato futuro do índice Ibovespa". Disponível em: https://rc.cplp.org/Record/oasisbr_lr_34e256d1f8f83365530f894992c12d8a. Acesso em: novembro de 2024.

TELES, G. (2023) "Uso de redes neurais profundas para detecção de fake news". Bacharelado em Sistemas de Informação – Universidade Federal de Uberlândia, Uberlândia, Brasil. Disponível em: <https://repositorio.ufu.br/bitstream/123456789/40984/1/RedesNeuraisProfundas.pdf>. Acesso em: novembro de 2024.

TEMBHURNE, J. V.; ALMIN, M. M.; DIWAN, T. (2022) "Mc-DNN: Fake news detection using multi-channel deep neural networks". *International Journal on Semantic Web and Information Systems (IJSWIS)*, v. 18, n. 1, p. 1-20.

VILLELA, H. F.; CORRÊA, F.; NERY RIBEIRO, J. S. A.; RABELO, A.; COSTA, E. E. (2022) "Uma análise da acurácia obtida e datasets utilizados em algoritmos de identificação de fake news". In: *ISLA 2022 Proceedings*, v. 3. Disponível em: <https://aisel.aisnet.org/isla2022/3>.

YANG, Y. et al. (2023) "TI-CNN: Convolutional neural networks for fake news detection". *arXiv preprint*, arXiv:1806.00749, v.2.

ZHANG, Y.; WALLACE, B. (2016) "A Sensitivity Analysis of (and Practitioners' Guide to) Convolutional Neural Networks for Sentence Classification". *arXiv preprint*, arXiv:1510.03820. Disponível em: <https://arxiv.org/abs/1510.03820>.