

## 25º Congresso Nacional de Iniciação Científica

**TÍTULO:** ALETHEIA: DETECÇÃO DE FAKE NEWS COM MODELOS DE LINGUAGEM QUE RACIOCINAM

**CATEGORIA:** EM ANDAMENTO

**ÁREA:** CIÊNCIAS EXATAS, DA TERRA E AGRÁRIAS

**SUBÁREA:** Computação e Informática

**INSTITUIÇÃO:** UNIVERSIDADE TECNOLÓGICA FEDERAL DO PARANÁ - UTFPR

**AUTOR(ES):** IGOR ARAUJO DE MATTOS

**ORIENTADOR(ES):** ROBSON PARMEZAN BONIDIA

## CATEGORIA EM ANDAMENTO

### 1. RESUMO

A rápida propagação da desinformação na *internet*, sobretudo pelas redes sociais e aplicativos de mensagens, intensifica a necessidade de tecnologias que auxiliem na verificação da veracidade de conteúdos compartilhados. Este trabalho propõe elaborar uma aplicação baseada em modelos de linguagem de última geração, integrada à abordagem de raciocínio automatizado e à de explicabilidade, conforme a realidade linguística e sociocultural do Brasil. Nomeada Aletheia, que em grego se refere à revelação da verdade, a aplicação funcionará como um sistema transparente e acessível à detecção de *fake news*, priorizando a interpretabilidade das decisões tomadas pelo modelo. Para isso, foi recorrido a um conjunto robusto de dados rotulados em português, oriundos de diversas fontes jornalísticas e repositórios de *fact-checking*. Como aplicação final, pretende-se desenvolver um protótipo funcional em forma de bot para plataformas como Telegram ou WhatsApp, permitindo acessibilidade da solução a um público abrangente, principalmente em comunidade marginalizadas. Este trabalho visa acima de tudo promover a confiança e o engajamento crítico do usuário, reforçando a importância de ferramentas responsáveis e interpretáveis no combate às *fake news*.

### 2. INTRODUÇÃO

A proliferação da desinformação online representa um desafio crítico para o bem-estar social, a confiança pública e os processos democráticos. Notícias falsas possuem o potencial de incitar o medo, manipular a opinião pública e influenciar decisões cruciais. As *fake news* se espalham em uma velocidade sem precedentes, e um único indivíduo pode alcançar uma audiência tão vasta quanto os veículos midiáticos tradicionais, por exemplo, Fox News, CNN ou The New York Times (Aïmeur; Brassard, 2023; Flaminio et al., 2023).

Além disso, os recentes avanços em Inteligência Artificial (IA) Generativa, especialmente os Modelos de Linguagem de Grande Escala (*Large Language Models* – LLMs), apresentam uma espécie de paradoxo: se, de um lado, eles podem

gerar conteúdos extremamente realistas, mas falsos, aumentando a dificuldade de detecção da desinformação (Sun et al., 2024); por outro, disponibilizam técnicas avançadas para a detecção, a identificação e a mitigação do avanço das *fake news*, convertendo-se em parte da solução para o próprio problema que contribuem para produzir (Kareem; Abbas, 2023).

Sites de verificação de fatos, como PolitiFact e Snopes, utilizam profissionais especializados para realizar a checagem manual das informações, porém a rápida propagação da desinformação torna esse processo extremamente trabalhoso, demorado e pouco escalável. Como resposta a esse desafio, nos últimos anos, foram desenvolvidos modelos baseados em IA para automatizar a verificação de fatos e aprimorar a detecção de notícias falsas (Liao et al., 2023).

Nesse contexto, o presente trabalho se justifica pela necessidade de aprimorar os métodos de verificação de fatos, combinando LLMs com técnicas *reasoning*, a fim de aumentar a transparência e a interpretabilidade dos modelos de detecção. A pesquisa pretende contribuir tanto com o progresso acadêmico quanto com o desenvolvimento de soluções práticas que possam ser aplicadas por jornalistas, pesquisadores e cidadãos comuns no combate à desinformação. Além disso, este estudo busca oferecer um sistema que auxilie na escolha de fontes confiáveis, promovendo um ambiente digital mais seguro e informativo.

### **3. OBJETIVOS**

O objetivo desta pesquisa é desenvolver e implementar um modelo de Processamento de Linguagem Natural capaz de mitigar a desinformação online, detectando a possibilidade de notícias serem falsas ou reais. Para isso, serão analisados os principais LLMs em combinação com técnicas de raciocínio automatizado e explicabilidade (XAI/*reasoning*), visando avaliar a porcentagem de veracidade de uma determinada afirmação ou artigo. Além disso, busca-se incentivar a disseminação responsável de informações, contribuindo para a redução da propagação de notícias falsas e para o aumento da confiabilidade das análises.

### **4. METODOLOGIA**

A metodologia está organizada em quatro etapas principais. (1) Primeiro, é realizada a aquisição de notícias rotulados como verdadeiras ou falsas, provenientes de fontes jornalísticas e plataformas de checagem de fatos de língua portuguesa. A etapa busca assegurar a qualidade, diversidade temática e representatividade linguística, em diferentes domínios (como política, saúde e ciência).

Em seguida, (2) técnicas de Engenharia de *Prompts* serão analisadas, incluindo abordagens *zero-shot*, *few-shot* e *chain-of-thought*, visando extrair raciocínios claros e justificativas interpretáveis por parte do modelo. Na etapa de (3) Configuração Experimental e Arquitetura *Ensemble* foram selecionados alguns LLMs, como Llama 3, Gemini 1.5, DeepSeek, Phi 4, Qwen 3 e Gemma 3, focando no desempenho, compatibilidade com o português e capacidade de explicabilidade.

Para aumentar a precisão e a robustez, será implementada uma Arquitetura *Ensemble*. Essa abordagem combinará múltiplos LLMs por meio de estratégias de votação e raciocínio estruturado, explorando os pontos fortes de cada modelo para reduzir vieses e melhorar a generalização. As métricas de desempenho e de explicabilidade serão usadas para validar a eficácia da abordagem.

Por fim, uma aplicação para o usuário final será disponibilizada, com base nos modelos e estratégias mais promissores, em formato de bot para plataformas como Telegram ou WhatsApp. O grande objetivo é oferecer uma ferramenta acessível, confiável e interpretável para identificação de possíveis notícias falsas.

## 5. DESENVOLVIMENTO

O desenvolvimento do projeto encontra-se em andamento. Até o momento, foram selecionados e preparados os conjuntos de dados, com destaque para a base FakeTrue.Br (Chavarro et al., 2023), com cerca de 3.582 notícias diversas em português, publicadas entre 2017 e 2023 (1.791 verdadeiras e 1.791 falsas), e o Dataset-Fake-news-and-True-news (Rodrigues, 2025), que contém 65.204 notícias, sendo 32.602 verdadeiras e 32.602 falsas. Essa escolha permitiu trabalhar com dados atualizados e relevantes para a realidade linguística e cultural do Brasil.

Além disso, a estrutura de código para o agente já foi implementada e uma série de testes de estratégias de *prompting* e a avaliação comparativa de LLMs com

foco em *Reasoning* está sendo conduzida. Com a conclusão desta fase de testes, os próximos passos incluem a análise quantitativa e qualitativa das previsões dos modelos. Em seguida, será disponibilizado o protótipo funcional, validado e otimizado para a luta contra a desinformação.

## 6. RESULTADOS PRELIMINARES

Na etapa de desenvolvimento e testes das estratégias de *prompting* da pesquisa, foram definidos seis *prompts* baseados em técnicas de Engenharia de *Prompts*. Três deles utilizam o conhecimento interno dos modelos, enquanto os outros três recorrem ao conhecimento externo, coletado por meio de APIs e incorporado como contexto via RAG (*Retrieval-Augmented Generation*). As APIs utilizadas para a coleta das fontes externas foram *DuckDuckGo*, *GDELT* e *Google Fact Check*. Utilizou-se três APIs como precaução, para garantir que, caso alguma não retornasse informações, as demais pudessem suprir essa necessidade.

Atualmente, o trabalho encontra-se na fase de avaliação comparativa, com foco em *reasoning* e desempenho. Os modelos utilizados até o momento nesta fase foram *Falcon3-10B-Instruct*, *Mistral-7B-Instruct-v0.2-GPTQ*, *Llama-3.1-8B-Instruct*, *Phi-4*, *DeepSeek-V2-Lite-Chat* e *Gemma-3-27b-pt*. Futuramente, pretende-se incluir outros modelos, como *Sabiá-7b*, *Qwen3-32B*, *Gemini-1.5-Flash* e *GPT-3.5-Turbo*.

Durante essa fase, foram realizados testes iniciais com 50 notícias verdadeiras e 50 falsas, utilizando os seis modelos mencionados e as seis diferentes abordagens de *prompting*, tanto com conhecimento interno quanto externo. Observou-se que os modelos cujos resultados ficaram mais próximos dos rótulos reais foram *Llama-3.1-8B-Instruct* (~90% de acerto), *Falcon3-10B-Instruct* (~85% de acerto) e *Mistral-7B-Instruct-v0.2-GPTQ* (~80% de acerto). Para viabilizar essa análise, foi desenvolvida uma função que extrai manualmente, das respostas dos modelos, a classificação e a probabilidade de certeza atribuída à notícia ser “fake” ou “real”.

A pesquisa segue em contínua fase de desenvolvimento. No qual, o foco atual é testar os modelos em um conjunto mais expressivo de notícias, incrementar os modelos propostos, aplicar a abordagem *Ensemble* com os modelos que

apresentarem os melhores resultados, tanto em assertividade quanto em qualidade das respostas, e, por fim, desenvolver um protótipo funcional da aplicação.

## 7. FONTES CONSULTADAS

AIMEUR, S. A. E.; BRASSARD, G. Fake news, disinformation and misinformation in social media: a review. **Social Network Analysis and Mining**, v. 13, p. 30, 2023. ISSN 1869-5469. Disponível em: <https://doi.org/10.1007/s13278-023-01028-5>.

CHAVARRO, J. et al. Faketruebr: Um corpus brasileiro de notícias falsas. In: ANAIS DA XVIII ESCOLA REGIONAL DE BANCO DE DADOS. 2023, Porto Alegre, RS, Brasil. **Anais [...]** Porto Alegre, RS, Brasil: SBC, 2023. p. 108–117. ISSN 2595-413X. Disponível em: <https://sol.sbc.org.br/index.php/erbd/article/view/24352>.

FLAMINO, J. et al. Political polarization of news media and influencers on twitter in the 2016 and 2020 US presidential elections. **Nature Human Behaviour**, v. 7, p. 904–916, 2023. Disponível em: <https://doi.org/10.1038/s41562-023-01550-8>.

KAREEM, W.; ABBAS, N. Fighting lies with intelligence: Using large language models and chain of thoughts technique to combat fake news. In: BRAMER, M.; STAHL, F. (Ed.). **ARTIFICIAL INTELLIGENCE XL**. 2023, Cham. **Anais [...]** Cham: Springer Nature Switzerland, 2023. p. 253–258. ISBN 978-3-031-47994-6.

LIAO, H. et al. Muser: A multi-step evidence retrieval enhancement framework for fake news detection. In: **PROCEEDINGS OF THE 29TH ACM SIGKDD CONFERENCE ON KNOWLEDGE DISCOVERY AND DATA MINING**. 2023. **Anais [...]** ACM, 2023. p. 4461–4472. Disponível em: <http://dx.doi.org/10.1145/3580305.3599873>.

RODRIGUES, M. D. L. **Dataset Fake News and True News Brazil**. 2025. Repositório GitHub. Licença CC BY 4.0. Disponível em: <https://github.com/michelleluzrodrigues/Dataset-Fake-news-and-True-news>.

SUN, Y. et al. **Exploring the Deceptive Power of LLM-Generated Fake News: A Study of Real-World Detection Challenges**, 2024. Disponível em: <https://arxiv.org/abs/2403.18249>.