

# ***BIBLIOGRAFIAS SINTÉTICAS: uma análise empírica de LLMs para busca de referência acadêmica<sup>1</sup>*** ***SYNTHETIC BIBLIOGRAPHIES: an empirical analysis on LLMs for academic reference search***

Beatriz Gasparette dos Santos Montenegro <sup>2</sup>

**Resumo:** *Este artigo se propõe a examinar empiricamente os vieses de modelos de linguagem de grande escala (LLMs) para busca de referências acadêmicas, mapeando a acurácia, nacionalidade e pertinência dos resultados. A elaboração teórica se apoia em estudos de “culturas de ranking” e demais explorações sobre impacto algorítmico na difusão de informação e conhecimento, contextualizados dentro do fenômeno da “plataformização da ciência”. A coleta foi feita em quatro modelos diferentes (ChatGPT, DeepSeek, Gemini e Mistral), e as referências coletadas foram examinadas com uma análise de conteúdo categorial. Os resultados apontam que inacurácia, com textos e autores falsos, é um problema minoritário na média, mas consideravelmente maior nas referências brasileiras.*

**Palavras-Chave:** *Inteligência Artificial. Plataformização da ciência. Culturas de ranking.*

**Abstract:** *This article aims to examine empirically the biases of large language models (LLMs) for search of academic references, mapping their accuracy, author's nationality and relevance to field. The experiment is supported by “ranking cultures” and other work regarding algorithmic impact on knowledge and information transmission, further contextualized within the phenomenon of “platformization of science”. Data was collected from four different models (ChatGPT, DeepSeek, Gemini and Mistral), and references were then labeled according to a categorial content analysis. Results suggest tha inaccuracy, with fake texts and authors, is a minor problem on average, but it's considerably larger on Brazilian references.*

**Keywords:** *Artificial Intelligence. Platformization of Science. Ranking Cultures.*

## **1. Introdução**

No Brasil, cerca de um terço de todos os usuários de internet usam inteligência artificial (IA) generativa (CETIC, 2025). O ChatGPT, modelo de linguagem em grande escala (*large language model*, ou LLM) pioneiro no mercado, atingiu 800 milhões de usuários semanais e 29.000 prompts sendo feitos por segundo poucos anos após o lançamento (EDMONDS, 2025). Com a ampla adoção deste tipo de ferramenta, está em curso uma reconfiguração de paradigma nas formas de buscar, consumir e produzir conteúdo e informação em diversas esferas sociais:

<sup>1</sup> Trabalho apresentado ao Grupo de Trabalho Materialidades Digitais e Práticas Comunicacionais. 35º Encontro Anual da Compós, Universidade Federal do Rio Grande do Norte (UFRN). Natal - RN. 9 a 12 de junho de 2026.

<sup>2</sup> Mestranda no programa de pós graduação em Comunicação na PUC-RIO, bgsmontenegro@gmail.com

se antes buscava-se no Google, hoje pergunta-se para o chat de sua escolha. Considerando o mundo acadêmico – ou seja, a produção de conhecimento na prática –, já existe toda uma oferta de ferramentas de IA especializadas, como SciSpace, Elicit, ScienceDirect e Jenni. As aplicações, com diversas funcionalidades de busca e texto, prometem “ajudar pesquisadores a serem 10x mais baseados em evidências”<sup>3</sup>, e contam com “a confiança de mais de 5 milhões de acadêmicos”<sup>4</sup>. O próprio ChatGPT, que não é exclusivamente acadêmico, foi equiparado a uma “equipe de PhDs a sua disposição”<sup>5</sup>.

Apesar das proposições comerciais, a ética do uso de ferramentas de IA para produção científica ainda é nebulosa. Em 2025, ao menos 770 publicações usaram inteligência artificial sem sinalização (MENDONÇA et al, 2025). No Brasil, o Conselho Nacional de Educação está trabalhando em uma proposta de regras de uso e rotulamento (Ibid.). O debate crítico sobre a adoção de inteligência artificial no mundo acadêmico se faz essencial não apenas para definir uma possível regulamentação, mas principalmente porque a decisão de uso é, sobretudo, uma escolha de epistême. Ao compor o aparato técnico de pesquisa, IA tem o potencial de modificar as culturas vigentes de produção de conhecimento. Considerando “culturas epistêmicas” as combinações dos arranjos e mecanismos que determinam como produzimos conhecimento em determinado campo (CETINA, 1999), a adoção de uma ferramenta tão emblemática e possivelmente infra-estruturante quanto IA traz impactos substanciais. Como colocou Alvarado (2023), inteligência artificial é, por definição, uma tecnologia epistêmica: suas programações e possibilidades de uso envolvem manipulações (análises, categorizações e elaborações) do tipo epistêmico, feitas com conteúdo também epistêmico.

As possíveis reconfigurações de cultura se dão em diversos níveis, da coleta de dados a redação de texto e preparação de apresentação para congressos. Cada etapa da produção científica tem um conjunto específico de possibilidades de uso de modelos de linguagem, e os impactos podem ser diversos. Assim como o processo de transformações tecnológicas conhecidos como plataformização da ciência não foi linear ou distribuído igualmente em todas as etapas (NETO e CHIARINI, 2023), as mudanças trazidas por IA não serão uniformes. A partir desta premissa, o presente trabalho optou por examinar uma etapa inicial do processo de

<sup>3</sup> Página inicial da aplicação Elicit, Disponível em: [[www.elicit.com](http://www.elicit.com)]. Acessado em 13/01/2026

<sup>4</sup> Página inicial da aplicação Jenni, Disponível em: [[www.jenni.ai](http://www.jenni.ai)]. Acessado em 13/01/2026

<sup>5</sup> Declaração de Sam Altman, CEO da OpenAI, no lançamento do ChatGPT-5 - “OpenAI releases GPT-5, calling it a ‘team of PH.D. level experts in your pocket’”, 07/08/2025, disponível em: [<https://www.nbcnews.com/tech/tech-news/openai-releases-chatgpt-5-rcna223265>] acessado em 03/02/2025

pesquisa: a busca de referências. Quais os impactos de adotar IA generativa para mapeamento de referências acadêmicas? Que vieses e visões de mundo ela pode trazer ao construir um referencial teórico?

O objetivo da pesquisa, então, é mapear padrões nas respostas de LLMs, levantando estes possíveis vieses que podem surgir no processo. O teste empírico será feito utilizando modelos de linguagem como buscadores de bibliografia acadêmica. O estudo adota uma proposta metodológica comparativa, com uso de prompts para a construção de uma base dados de referências bibliográficas do campo de métodos digitais, mapeando as tendências e vieses apresentados. A coleta foi feita a partir das respostas únicas do ChatGPT, Gemini, Mistral e DeepSeek, que no tratamento foram tabeladas para a construção do *corpus* e então rotuladas a partir de uma análise de conteúdo categorial (AC). A categorização explorou acurácia de referência, pertinência para o campo e nacionalidade de autores, seguindo como modelo metodológico as definições de AC de Sampaio e Licarião (2021).

O artigo irá se dividir em quatro seções, para além da introdução: uma seção teórica explorando “culturas de ranking”<sup>6</sup> (RIEDER et al. 2018), LLMs, plataformação da ciência e epistêmes de IA, uma seção metodológica, uma de resultados, e, por fim, as considerações finais.

## 2. Modelos de linguagem e a academia plataformizada

A ciência não está embalada à vácuo: o mundo acadêmico também integra a chamada “sociedade de plataformas” (VAN DJICK et al. 2018). O processo de produção de pesquisa foi afetado em diferentes graus, de forma não linear (NETO e CHIARINI, 2023), e a natureza algorítmicas das plataformas é um dos grandes fatores envolvidos no processo. O problema de pesquisa é indissociável deste contexto, demandando uma elaboração dos estudos de “culturas de ranking” e algoritmos, além de uma exploração do que exatamente significa a plataformação da produção acadêmica. A primeira seção debate os desafios de opacidade de *machine learning* tanto para a interpretabilidade de algoritmos quanto LLMs, colocando similaridades e diferenças necessárias na abordagem. A segunda seção expande sobre a ciência plataformizada e cultura epistêmica, descrevendo o contexto que recebe esta nova leva de ferramentas de IA generativa.

<sup>6</sup> “Ranking cultures” no original (RIEDER et al., 2018)

## 2.1 *Machine Learning*, culturas de ranking e os modelos de linguagem

Na última década, o termo “algoritmo” ganhou tração no imaginário popular, deixando de ser apenas um conceito técnico da ciência da computação e se tornando central em debates políticos e sociais altamente polarizados (BURREL, 2016). A mediação algorítmica é uma das características centrais das plataformas e do processo de plataformização (POELL et al., 2020), com toda uma bibliografia dedicada ao mapeamento dos seus impactos e vieses (BUCHER, 2012; GILLESPIE, 2018; NOBLE, 2018; SANDVIG et al., 2014). Nestes estudos, a opacidade emerge como uma questão central: segundo Gillespie (2018), a adoção ampla de algoritmos é uma sujeição do discurso e conhecimento humano às lógicas da computação – lógicas estas que podem ser bastante opacas, ocultando uma série de decisões humanas que ocorrem por detrás delas.

Sendo assim, “auditar” algoritmos é uma tarefa complexa. As culturas de ranking de plataformas como o YouTube, ao serem auditadas de forma experimental, oferecem um vislumbre da complexidade das métricas utilizadas e da dificuldade em estabelecer uma causalidade linear ou mesmo simplificada (RIEDER et al., 2018). É possível elaborar maneiras de mensurar e descrever resultados algorítmicos, detectando vieses e levantando problemáticas, mas justificá-los é um desafio que, por vezes, simplesmente não é possível (BURREL, 2016). O *machine learning*, método de aprendizagem de máquina aplicado à maioria dos algoritmos de curadoria de “relevância pública” (GILLESPIE, 2018), tem obstáculos intrínsecos para a interpretação humana que vão muito além da transparência corporativa. O “segredo empresarial” mantido pelas plataformas para evitar cópia de concorrentes e uso adversarial de usuários (CRAWFORD, 2016; GILLESPIE, 2018) não é a única causa da opacidade algorítmica: a escala de dados consumidos no processo de *machine learning* faz com que as lógicas maquínicas adotadas não sejam facilmente explicáveis para olhos humanos, mesmo de especialistas (BURREL, 2016).

Inteligência artificial generativa herda diretamente as problemáticas algorítmicas. Se algoritmos trazem embutidos o desafio de legibilidade de *machine learning*, modelos de linguagem como ChatGPT, Gemini e DeepSeek complexificam ainda mais a questão pela natureza generativa e a escala do seu *deep learning* (modalidade específica de aprendizagem, de escala ainda maior). Novas questões técnicas surgem: modelos de IA transcendem a mera curadoria por gerarem informações e textos próprios. Estes modelos podem, inclusive, fabricar informações falsas espontaneamente, sem nenhuma explicação aparente – as chamadas

“alucinações” (KALAI, 2025). O processamento de linguagem natural (idiomas humanos) dos modelos pode oferecer textos aparentemente coerentes, mas com falsas premissas ou dados completamente inexistentes. A quantidade massiva de dados usados na aprendizagem de LLMs torna virtualmente impossível mapear tanto a origem ou lógica de alucinações quanto a própria “cultura de ranking” adotada pela máquina, quando providencia informações que de fato existem.

Assim, acumulam-se desafios na utilização de ferramentas de IA, por limitações técnicas e vieses complexos de mapear. Jazwinska e Chandrakesar (2025) avaliaram oito LLMs diferentes e verificaram um problema geral para citação e localização de fontes. As autoras constataram que, além de uma alta taxa de erro, todos os modelos tiveram problemas para se recusar a responder sobre o que não tinham informação, fabricando artigos e links para bancar respostas alucinadas. Gillespie (2024) mapeou não a inacurácia, mas os vieses de representatividade de modelos de linguagem – que, ao gerarem histórias românticas, majoritariamente criavam casais héteros. Kerche et al. (2026) descreveram o “olhar do silício”<sup>7</sup>, conceito que criaram para explicar a forma que LLMs reproduzem e amplificam desigualdades geográficas e espaciais. Perez et. al. (2022) detectaram a tendência dos modelos à bajulação, ao constatarem que perguntas políticas e filosóficas eram respondidas com vieses de confirmação para o suposto ponto de vista da pessoa que fez o prompt.

A gênese destes fenômenos está na natureza estatística de LLMs, explicada pelo seu contexto técnico. O desenvolvimento de inteligência artificial, desde a fundação do campo em 1956, tinha duas vertentes: simbólica e conexionista (RÉGIS, 2023). A programação simbólica parte de regras pré-programadas, encarando algoritmos como um manual preciso que vai capacitar o programa a executar tarefas diversas. O simbolismo foi a corrente inicialmente mais financiada, por partir de uma série de premissas sobre inteligência e cognição da época e ter obtido bons resultados iniciais. Seu modelo segue a lógica “de cima para baixo”, ou seja, a programação dita a ação. No entanto, a complexidade do processamento de informação humano se revelou difícil de codificar em regras pré-estabelecidas, e entre as décadas de 1970 e 80 houve a chamada virada cognitiva e a crescente do conexionismo, aproveitando o crescimento de poder computacional disponível (Ibid.).

<sup>7</sup> No original, “*silicon gaze*”

O conexionismo parte dos dados de treinamento, permitindo que os programas computacionais aprendam padrões sem pré-programação, trabalhando com uma lógica “de baixo para cima”, ou seja, a base de dados dita a ação (Ibid). LLMs herdaram a lógica conexcionista, partindo de bases de dados massivas para processar a linguagem natural (idiomas humanos) e respondê-la de acordo. São máquinas estatísticas, que a partir de cálculos probabilísticos avaliam e montam cadeias de palavras, sem uma compreensão de seus significados (BENDER et al. 2021).

IA generativa herdou a problemática algorítmica por partir de um contexto técnico similar, mas o efeito de “papagaio estocástico” – a aparência de coesão e entendimento gerada pelo processamento de linguagem natural (Ibid.) – se apresenta como uma questão específica de LLMs. Como elaboraram Bender et. Al (2021): há um perigo na “mistura de vieses humanos e a linguagem aparentemente coerente”, que pode aumentar o “potencial para viés de automação, mal uso deliberado e amplificação de visões de mundo hegemônicas” (p. 616). Explorar as culturas de ranking de modelos de linguagem deve, simultaneamente, considerar a bibliografia de estudos de plataforma e algoritmos que contextualiza a realidade atual, mas expandir a visão técnica e empírica para abarcar a natureza generativa dos chatbots de IA.

## *2.2 Plataformização da ciência e culturas epistêmicas*

No cenário acadêmico, Neto e Chiarini (2022) definiram plataformas científicas como sistemas de governança de espaços virtuais que alavancam efeitos de rede em uma ou mais fases do processo científico. Esta definição não inclui, portanto, plataformas de uso geral que apenas tangenciam o universo acadêmico, como Twitter, LinkedIn ou Amazon Mechanical Turk. O conceito também não se atém a obrigatoriedades tradicionalmente adotadas em definições de estudos de plataformas, como a coleta de dados, a natureza algorítmica e a organização de mercados multilaterais. (VAN DIJICK et al. 2018).

Plataformas científicas projetadas a partir da comunidade acadêmica, civil ou pelo próprio Estado existem em todas as etapas do processo acadêmico (NETO e CHIARINI, 2022). Todos os momentos de pesquisa - conceitualização e financiamento, coleta de dados, experimentação e análise, publicação, divulgação e avaliação de impactos - hoje, têm uma oferta de plataformas disponíveis. Algumas etapas têm sistemas que se tornaram infraestruturais, como a plataforma Lattes para pedidos de financiamento de pesquisa no Brasil, enquanto outras possuem sistemas em crescimento mas sem um efeito de rede definitivo para

sua consolidação como ferramenta essencial, como as redes sociais acadêmicas, ou ASNS (*Academic Social Network Sites*). (Ibid.).

A metrificação da vida acadêmica é um caso claro que ilustra a realidade científica plataformizada. As ASNS não são infraestruturais para o processo de pesquisa, mas ao compor um ecossistema complexo de produção de visibilidades, formam “assembleias métricas” (BURROWS, 2012 *apud* FURTADO e D’ANDRÉA, 2024). Estes mecanismos de mensuração, entrelaçados às estruturas de poder, são um incentivo não apenas para tornar nosso desempenho visível para os outros, mas também para torná-lo passível de ser avaliado de forma comparativa (BEER, 2016, p.93 *apud* FURTADO e D’ANDRÉA, 2024).

Este processo de plataformização é, necessariamente, uma transformação no modo de produção de conhecimento. As plataformas digitais, o modelo econômico embutidos na lógica de internet e a metrificação que se torna possível, somados, contribuem para a organização de regimes de visibilidade específicos (FURTADO e D’ANDRÉA, 2024). As dinâmicas e lógicas de produção científica se modificam não só porque algumas pesquisas, pessoas do campo ou temas específicos se tornam mais evidentes em detrimento de outros, mas por transformar a produção e legitimação de conhecimentos contemporâneos (Ibid.).

Van Dijck et al. (2018) citam três mecanismos centrais na lógica de plataformas: dataficação, comodificação e seleção. O atravessamento de diversas esferas da vida humana com a coleta de dados em tempo real, validada pelo oximoro “dados brutos”, é a dataficação. A comodificação é possibilitada por essa circulação de dados, que transforma objetos online e offline (emoções, atividades, ideias) em *commodities*. A seleção é o processo geral de curadoria de tópicos, termos, atores, objetos, serviços – trabalho anteriormente feito por profissionais e instituições, e atualmente levado por algoritmos. Estes mecanismos têm embutidos em si uma série de premissas com impactos epistemológicos. Há culturas epistêmicas próprias na lógica dataficação, na comodificação e na curadoria da plataformização. A ciência não tem um funcionamento uniforme e monolítico (CETINA, 1999), sendo assim as plataformas (re)constituem as culturas epistêmicas vigentes em diferentes intensidades, complexas de serem mensuradas com exatidão.

Inteligência artificial generativa se insere neste contexto tendo uma sobreposição técnica e discursiva com o processo de plataformização. A dataficação, comodificação e seleção também são mecanismos essenciais no funcionamento de LLMs. Considerando IA como uma “tecnologia epistêmica” (ALVARADO, 2023), é necessário não só a compreensão

de sua realidade técnica e de seus discursos atrelados, mas também de sua materialidade e as premissas que se constituem a partir dela. O aprimoramento de *machine learning* depende de extração e exploração de minérios, trabalho e dados, configurando uma cultura de extrativismo inerente ao seu desenvolvimento (CRAWFORD, 2020). O uso de eletricidade é massivo, tanto no período de treinamento dos modelos quanto no uso cotidiano (BREVINI, 2020). Existe a crença de que, a partir de determinado patamar, inteligência artificial será capaz de atingir níveis de eficiência impensáveis para o modo de vida humano e, portanto, destravar novas soluções para uma série de desafios ambientais, mas pouco se elabora neste discurso sobre a atual pegada de carbono da tecnologia (Ibid.) Como coloca sucintamente Brevini (2020), fazendo referência à opacidade técnica mas também discursiva ao redor de IAs, “caixas pretas não são verdes” (p. 4).

A exploração da materialidade e da cultura epistêmica embutida na inteligência artificial a partir de um objeto bem definido como LLMs permite que as relações (re)produzidas pela adoção destas ferramentas sejam examinadas com cuidado. Em um mergulho de profundidade, faz-se necessário refletir: o quanto as lógicas próprias de inteligência artificial generativa como LLMs impactam o ecossistema de informação e produção de conhecimento? Como elas passam a modificá-lo e moldá-lo, criando lógicas específicas, culturas epistêmicas próprias? Como o processo científico plataformizado recebe estes impactos?

### 3. Metodologia

O objetivo da pesquisa é refletir sobre a utilização de LLMs na construção de referencial teórico, mapeando possíveis vieses das ferramentas. Sendo assim, estabeleceram-se duas premissas: as respostas de modelos de linguagem são a fonte de dados, e as unidades de análise são as referências bibliográficas citada nestas respostas. A abordagem metodológica se dividiu em três etapas: coleta, tratamento e análise.

O escopo da coleta é baseado em trabalhos como o de Gillespie (2024), que a partir de prompts repetidos coletou histórias românticas geradas por LLMs para mapear representatividade, e de Kerche et al. (2026), que auditaram vieses geográficos do ChatGPT com uma coleta automatizada em escala. A metodologia da presente pesquisa se diferencia de ambas ao optar pelo português e utilizar quatro modelos diferentes – Gillespie (2024) utilizou três, e Kerche et al. (2026) manteve o foco em um -, além de seguir um prompt único e uma escala de amostra reduzida, coletada manualmente. Optou-se por examinar mais de um LLM

para possibilitar comparação, cobrindo diferentes empresas e nacionalidades, para que os resultados possam se aproximar mais de uma visão geral e não de um mapeamento de uma aplicação particular. Os modelos selecionados para análise foram ChatGPT (OpenAI), pela ampla penetração (LABATE, 2025); Gemini (Google), pelo posicionamento da Google enquanto *Big Tech* já estabelecida; DeepSeek (Hangzhou), pela origem chinesa; e Mistral (Mistral AI SAS), pela origem francesa.

A coleta foi realizada via o prompt “*Cite em norma ABNT dez referências essenciais para estudar o campo de métodos digitais na comunicação*”. Cada prompt foi realizado sem *login*, em conversas zeradas na aba anônima do navegador, para evitar a influência de perfilação e histórico. Foram cinco prompts por LLM, gerando um *corpus* final de vinte respostas com duzentas referências. Após tabelamento, elas foram codificadas segundo as categorias da análise de conteúdo categorial.

O livro de códigos foi elaborado visando cobrir os critérios de acurácia, nacionalidade e pertinência da forma mais simples possível (TAB. 1), com base metodológica em Sampaio e Licarião (2021). A verificação das referências foi focada em título e autor(a), deixando de lado editora, edição e o próprio formato ABNT. A pertinência foi definida a partir da bibliografia de livros e artigos voltados para mapeamento do campo. A nacionalidade dos autores levou em conta nomes que não existiam, considerando a cidade citada na referência– escolha feita para possibilitar a comparação de acurácia entre autorias dentro e fora do Brasil.

TABELA 1  
Livro de códigos

| Categoria              | Códigos                               | Instruções de codificação                                                                                                                                                                             |
|------------------------|---------------------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|
| <b>Ref</b>             | Código de identificação da referência | Codificação gerada a partir do prompt utilizado, resposta original que contém a referência e número ordinal da referência dentro desta resposta (ex: Prompt A, resposta 3, referência #10: Ref 3A10.) |
| <b>Título do Texto</b> | Inexistente                           | Título não foi encontrado no Google / Google Scholar                                                                                                                                                  |
|                        | Incompleto                            | Título encontrado, mas com erro minoritário (ex: subtítulo)                                                                                                                                           |
|                        | Completo                              | Título encontrado <i>ipsis literis</i>                                                                                                                                                                |
| <b>Autor/a</b>         | Inexistente                           | Nome não encontrado no Google / Google Scholar                                                                                                                                                        |
|                        | Incompleto                            | Nome e/ou sobrenome com erro, mas reconhecível como pessoa acadêmica da área e/ou autor do texto ou lista de autores incompleta/com erros                                                             |
|                        | Completo                              | Autor existe e nome e sobrenome estão corretos                                                                                                                                                        |

|                                                                           |                            |                                                                                                                                                             |
|---------------------------------------------------------------------------|----------------------------|-------------------------------------------------------------------------------------------------------------------------------------------------------------|
| Referência<br>(Considera o par autor e texto)                             | Inexistente                | Texto ou autor não existem                                                                                                                                  |
|                                                                           | Autor não escreveu o texto | Texto e autor existem, mas não foi a pessoa que escreveu o texto em questão                                                                                 |
|                                                                           | Parcial                    | Autor e/ou título com falha, mas reconhecíveis                                                                                                              |
|                                                                           | Totalmente correta         | Autor e título <i>ipsis literis</i>                                                                                                                         |
| Nacionalidade da pessoa autora                                            | Brasileiro                 | Autor que existe, com nacionalidade brasileira verificada no Google, ou autor inexistente, categorizado pela cidade brasileira citada na referência         |
|                                                                           | Internacional              | Autor que existe, com nacionalidade de fora do Brasil verificada no Google, ou autor inexistente, categorizado pela cidade estrangeira citada na referência |
| Pertinência de referência para o campo de métodos digitais na comunicação | Pertinente                 | Definido de acordo com a bibliografia dos seguintes trabalhos:<br>Vimiero A. e Bargas J. (2019)<br>Omena, Jana (2019)<br>Angeluci, Alan (2025)              |
|                                                                           | Não pertinente             |                                                                                                                                                             |
|                                                                           | Referência Inexistente     |                                                                                                                                                             |

FONTE – Elaboração própria

## 4. Resultados

A partir das análises<sup>8</sup>, constatou-se que referências falsas (alucinações) não são tão frequentes a depender do modelo. Das 200 referências coletadas, 91% estavam corretas de forma total ou parcial, e apenas 7,5% eram tinham autor ou título inexistente. A taxa de acurácia teve variação entre os diferentes modelos, com destaque positivo para DeepSeek (98% de referências totalmente corretas) e negativo para Gemini (14% de referências inexistentes) (TAB. 2). Ao examinar separadamente os componentes autor e título da referência, nota-se que a taxa de erro se concentra em títulos falso, e não autores (TAB. 3).

TABELA 2  
Acurácia de referências bibliográficas

|          | Correta | Parcial | Autor não escreveu o texto | Texto ou autor inexistente |
|----------|---------|---------|----------------------------|----------------------------|
| Total    | 85%     | 6%      | 1,5%                       | 7,5%                       |
| ChatGPT  | 80%     | 8%      | 2%                         | 10%                        |
| DeepSeek | 98%     | 0%      | 0%                         | 2%                         |
| Gemini   | 80%     | 6%      | 0%                         | 14%                        |
| Mistral  | 82%     | 10%     | 4%                         | 4%                         |

<sup>8</sup> Tabela de resultados disponível em:  
[[https://docs.google.com/spreadsheets/d/1Be9fKgRtTfCUXZLu1SjgEKPXg4rY\\_vE\\_kgfxSG-3yBA/edit?usp=sharing](https://docs.google.com/spreadsheets/d/1Be9fKgRtTfCUXZLu1SjgEKPXg4rY_vE_kgfxSG-3yBA/edit?usp=sharing)]

FONTE – Elaboração própria

TABELA 3

Acurácia de nome de autor(a) e título do texto, separadamente

|        | Completo | Incompleto | Inexistente |
|--------|----------|------------|-------------|
| Autor  | 91,5%    | 4,5%       | 4,0%        |
| Título | 90%      | 2,5%       | 7,5%        |

FONTE – Elaboração própria

A lista de referências teve bastante repetições. Considerando trabalhos colaborativos como entradas únicas, houve 65 autorias distintas. Richard Rogers foi o mais citado, seguido por Lev Manovich e Noortje Marres (FIG. 1). Apenas quatro autorias brasileiras aparecem no ranking de mais citados, sendo elas Raquel Recuero, Fabrício D’Andréa (pelo sobrenome e textos indicados, reconhecido como o autor Carlos D’Andréa), a colaboração de Suely Fragoso, Raquel Recuero e Adriana Amaral, e a colaboração de André Lemos com Pierre Lévy.



FIGURA 1 – Ranking de autores citados mais de uma vez

FONTE – Elaboração própria

Como denota o ranking, a maioria das referências foi internacional: no total, 90% da autoria dos textos era de fora do país, e apenas 10,5% brasileiras. Os dados brasileiros, portanto,

são bastante reduzidos, com 21 entradas e mais da metade sendo referências repetidas. É uma amostra que limita comparações, porém chama a atenção pelo índice de erro muito maior do que a média geral: 33,3% de referências inexistentes, versus apenas 7,5% no total (TAB. 4). Os erros parciais também se destacam, sendo mais do que o dobro dos números gerais, 14,3% versus 6% (todos referentes ao nome Fabrício D’Andréa em lugar de Carlos D’Andréa).

TABELA 4  
Acurácia de referência, considerando nacionalidade

|               | Correta | Parcial | Autor não escreveu o texto | Inexistente |
|---------------|---------|---------|----------------------------|-------------|
| Total         | 85%     | 6%      | 1,5%                       | 7,5%        |
| Brasileiro    | 52,4%   | 14,3%   | 0%                         | 33,3%       |
| Internacional | 88,8%   | 5%      | 1,7%                       | 4,5%        |

FONTE – Elaboração própria

É interessante pontuar que o modelo que mais citou referências brasileiras também é o que teve a maior taxa de inexistentes: Gemini, da Google. Eliminando brasileiros, sua taxa permaneceu maior do que os outros concorrentes, mas a dispersão dos resultados entre LLMs cai visivelmente (inexistentes variavam de 2% a 14%, e filtrando apenas para referências internacionais passam a variar entre 0 e 9%).

Para além da acurácia e nacionalidade de referências, também se verificou a pertinência pro campo. A categoria é menos objetiva que as anteriores, baseada na bibliografia de trabalhos que mapeiam métodos digitais como Omena (2019), Vimiero e Bargas (2019) e Angeluci (2025), mas segue sendo uma construção interessante para comparação. No geral, 71% das referências foram consideradas pertinentes, tendo como destaque positivo Mistral (82% de pertinência) e negativo o ChatGPT (apenas 64% de pertinência) (FIG. 2).




FIGURA 2 – Pertinência da referência para o campo de métodos digitais  
FONTE – Elaboração própria

## 5. Considerações Finais

Inteligência artificial surge em um contexto plataformizado. Algoritmos carregam culturas de ranking próprias, com mais de uma década de tensão entre usuário, complementador e plataforma, e uma ilegibilidade intrínseca. Questionar sobre os impactos de IA na ciência é reconhecer que as culturas epistêmicas vigentes já são fortemente influenciadas pelas práticas de *machine learning*, buscando compreender como a natureza generativa de *chatbots* traz similaridades e particularidades próprias. É inegável que modelos de linguagem trazem embutidas visões de mundo – como o “olhar do silício” de Kercher et al. (2024), ou a heteronormatividade descrita por Gillespie (2024). No presente trabalho, constatou-se mais um possível viés: ao serem testados para a construção de referencial acadêmico, LLMs tiveram menos acurácia para nomes brasileiros. Para futuros desenvolvimentos deste trabalho, o *corpus* deverá ser expandido com mais referências geradas por IA e variações de prompt, buscando nomes brasileiros e explorando as flutuações de acurácia e pertinência para o campo.

## Referências

- ALVARADO, Ramón. **AI as an epistemic technology**. Science and Engineering Ethics, v. 29, n. 5, p. 32, 2023.
- ANGELUCI, Alan; **Mapping research groups and labs developing digital methods across five Brazilian Regions: North, Northeast, Central-West, Southeast, South**. ECA USP, Janeiro de 2025. Disponível em: [ [https://github.com/jannajoceli/digital-methods-brazil/blob/main/Slides/3.%20Mapping%20DM%20across%20br5regions%20\(Angeluci\).pdf](https://github.com/jannajoceli/digital-methods-brazil/blob/main/Slides/3.%20Mapping%20DM%20across%20br5regions%20(Angeluci).pdf)]
- BENDER, E. et al. **On the Dangers of Stochastic Parrots: Can Language Models Be Too big?** Association for Computing Machinery, FAccT '21, 2021. Disponível em < <https://dl.acm.org/doi/10.1145/3442188.3445922>>.
- BREVINI, Benedetta. **Black boxes, not green: Mythologizing artificial intelligence and omitting the environment**. Big Data & Society, Volume 7, Issue 2, July 2020
- BUCHER, Taina. **Want to be on the top? Algorithmic power and the threat of invisibility on Facebook**. New Media and Society 14(7): 1164–1180, 2012
- BURREL, Jenna. **How the machine ‘thinks’: Understanding opacity in machine learning algorithms**. Big Data & Society, Volume 3, Issue 1, June 2016
- CRAWFORD, Kate. **Can an Algorithm be Agonistic? Ten Scenes from Life in Calculated Publics**. Science, Techonoly, & Human Values, 2016. Vol 41(1) 77-92
- CETIC. **TIC Domicílios 2025 – Coletiva de Imprensa**. Cetic.BR, 9 de dezembro de 2025. Disponível em: [ [https://cetic.br/media/analises/tic\\_domicilios\\_2025\\_principais\\_resultados.pdf](https://cetic.br/media/analises/tic_domicilios_2025_principais_resultados.pdf)] Acessado em 10 de fevereiro de 2026
- CETINA, Karin Knorr. **Epistemic cultures: How the sciences make knowledge**. Cambridge: Harvard University Press, 1999
- CRAWFORD, Kate. **Atlas of AI: Power Politics, and the Planetary Costs of Artificial Intelligence**. New Haven: Yale University Press, 2021
- EDMONDS, Lauren. **3 years old, 800 million users, 29,000 prompts a second: CHatGPT’s metoric rise, by the numbers**. Business Insider, 1 de dezembro de 2025. Disponível em: [ <https://www.businessinsider.com/chatgpt-by-the-numbers-2025-11>] Acessado em 11 de fevereiro de 2026
- FURTADO, I., D’ANDRÉA, C. **Assembleias métricas da produção científica: um estudo sobre as práticas de publicação, metrificação e circulação na plataforma Academia.edu**. Liinc em Revista, Rio de Janeiro Vol. 20, Ed. 1, 2024
- GILLESPIE, Tarleton. **A Relevância dos Algoritmos**. Revista Parágrafo v. 6, n. 1, p. 95-121, jan./abr. 2018
- GILLESPIE, Tarleton. **Generative AI and the politics of visibility**. Big Data & Society, Volume 11, Issue 2, June 2024
- JAZWINSKA, K. e CHANDRASEKAR, A. **AI Search Has A Citation Problem**. Columbia Journalism Review, Nova York, mar. 2025. Disponível em: < [https://www.cjr.org/tow\\_center/we-compared-eight-ai-search-engines-theyre-all-bad-at-citing-news.php](https://www.cjr.org/tow_center/we-compared-eight-ai-search-engines-theyre-all-bad-at-citing-news.php)>. Acesso em: 31 de agosto de 2025.
- KALAI, A et al. **Why Language Models Hallucinate**, Set.2025. Disponível em < <https://arxiv.org/pdf/2509.04664>>. Acesso em: 11 de novembro de 2025

KERCHE, F., ZOOK, M., GRAHAM, M. **The silicon gaze: A typology of biases and inequality in LLMs through the lens of place.** Platform & Society Volume 3, 2026

KLEE, Miles. **AI is inventing academic papers that don't exist – and they're being cited in real journals.** Rolling Stone, 13 de dezembro de 2025. Disponível em: <https://www.rollingstone.com/culture/culture-features/ai-chatbot-journal-research-fake-citations-1235485484/> Acessado em 13 de Janeiro de 2026

LABATE, Alice. **Quais os chatbots de IA mais usados no mundo? Veja ranking que os serviços mais populares.** Estadão, 2 de outubro de 2025. Disponível em: [https://www.estadao.com.br/link/cultura-digital/chatgpt-lidera-lista-de-chatbots-mais-usados-no-mundo-veja-ranking-de-ias-nprei/?srsltid=AfmBOoqTqux7PLT3mb9T6TPSvTeBkpEwOg5YWtZ7Mc\\_y3IQIfdTLUIJo](https://www.estadao.com.br/link/cultura-digital/chatgpt-lidera-lista-de-chatbots-mais-usados-no-mundo-veja-ranking-de-ias-nprei/?srsltid=AfmBOoqTqux7PLT3mb9T6TPSvTeBkpEwOg5YWtZ7Mc_y3IQIfdTLUIJo). Acessado em 11 de fevereiro de 2026

MENDONÇA, J., ALMEIDA, R. e ORRICO, A. **Ao menos 770 publicações acadêmicas usaram IA sem sinalizar.** Núcleo, 15 de Agosto de 2025. Disponível em: <https://nucleo.jor.br/reportagem/2025-08-15-ia-educacao-superior-publicacoes-academicas/> ] Acessado em 13 de Janeiro de 2026

NETO, V. e CHIARINI, T. **The Platformization of Science: Towards a Scientific Digital Platform Taxonomy.** Minerva 61:1-29, 2023. Disponível em < <https://link.springer.com/content/pdf/10.1007/s11024-022-09477-6.pdf> >

NOBLE, Safiya. **Algorithms of Oppression: How Search Engines Reinforce Racism.** New York: NYU Press, 2018

OMENA, Jana. **Métodos Digitais: Teoria-Prática-Crítica.** Lisboa: ICNOVA, 2019

PEREZ, E. et al. **Discovering Language Model Behaviors with Model-Written Evaluations.** Arxiv (Cornell University), arXiv:2212.09251, 2022. Disponível em <<https://arxiv.org/abs/2212.09251>>

POELL, T., NIEBORG, D., VAN DIJCK, J. **Plataformização.** Revista fronteiras – estudos midiáticos 22(1):2-10 janeiro/abril 2020. Unisinos – doi: 10.4013/fem.2020.221.01

RÉGIS, Fátima. **Nós, ciborgues: tecnologias de comunicação e subjetividade humano-máquina.** Curitiba: PUCPRESS, 2023

RIEDER, B., MATAMOROS-FERNÁNDEZ, A., COROMINA, O. **From ranking algorithms to 'ranking cultures': Investigating the modulation of visibility in YouTube search results.** CONVERGENCE, Volume 24, Issue 1, February 2018, Pages 50-68.

SANDVIG, C., HAMILTON, K. KARAHALIOS, K. LANGBORT, C. **Auditing Algorithms: Research Methods for Detecting Discrimination on Internet Platforms.** Paper presented to "Data and Discrimination: Converting Critical Concerns into Productive Inquiry," a preconference at the 64th Annual Meeting of the International Communication Association. May 22, 2014; Seattle, WA, USA.

SAMPAIO, R., LYCARIÃO, D. **Análise de conteúdo categorial: manual de aplicação.** Brasília: Enap, 2021

VAN DIJCK, J; POELL, T; WAAL, M. **The Platform Society: public values in a connective world.** Londres: Oxford Press, 2018.

VIMIERO, A. BARGAS, J. **O uso de dados e métodos digitais nas pesquisas em comunicação.** Revista Famecos, 2019