


Graphical Abstract



USO DA IA NA METODOLOGIA CIENTÍFICA

Camila R. Pereira

Departamento de Química, Instituto de Química, Universidade de São Paulo (USP), São

Paulo - SP, Brasil

e-mail: crpereira@usp.br

USE OF AI IN SCIENTIFIC METHODOLOGY

Abstract: Research in Artificial Intelligence (AI) began with John McCarthy in 1956 and evolved through systems such as the Logic Theorist in the 1950s and expert systems in the 1980s. Since 2006, deep neural networks have propelled Deep Learning, automating the analysis of large scientific databases with natural language processing and machine learning.

AI automates the analysis of scientific literature and enables the extraction of insights from large datasets using natural language processing and machine learning. AI has been transforming scientific methodology, impacting various fields. Traditional tools for Systematic Literature Review (SLR) face usability and cost issues, while new AI tools, such as large language models (LLMs) and OpenAI API, promise to facilitate literature reviews and academic production. Ethical challenges include transparency and accountability in the use of AI, with obstacles such as lack of skills, funding, and data access. Objectively, AI is transforming academic research by automating complex tasks. These tools facilitate natural language queries, enhance efficiency in literature review, and assist in the generation and refinement of academic documents, but require a responsible approach to overcome technical and ethical challenges.

Keywords: artificial intelligence; scientific methodology; systematic literature review; large language models.

INTRODUÇÃO

A pesquisa moderna em Inteligência Artificial (IA) teve seu início com John McCarthy, que cunhou o termo "inteligência artificial" em 1956 no Dartmouth College. Os primeiros avanços foram marcados pelo Logic Theorist, desenvolvido por Newell, Simon e Shaw. Embora o otimismo inicial tenha sido seguido por desafios técnicos e financeiros, a década de 1980 trouxe um ressurgimento com a criação de sistemas especialistas, como XCON e MYCIN. Em 2006, Geoffrey Hinton e seus colegas avançaram nas redes neurais profundas, reacendendo o interesse pela IA. O Deep Learning, uma subárea do Machine Learning, tem sido fundamental, superando habilidades humanas em tarefas como visão computacional e processamento de linguagem natural, e sendo aplicado em diversas áreas.¹

Atualmente, os pesquisadores enfrentam o desafio da abundância de publicações acadêmicas, o que dificulta a extração de conhecimento e a tomada de decisões informadas. A IA tem se mostrado crucial na automação da identificação, classificação e análise da literatura científica. Seus algoritmos possibilitam o processamento eficiente de dados, reconhecimento de padrões e extração de conhecimento. Com o uso da IA, os pesquisadores conseguem explorar métricas de publicação em larga escala, identificar tendências de pesquisa e rastrear a influência e o impacto das produções científicas.² Além disso, por meio de algoritmos de processamento de linguagem natural e técnicas de aprendizado profundo, a IA extrai informações-chave de artigos científicos, proporcionando uma compreensão abrangente das tendências de pesquisa, colaborações e impactos em domínios específicos. Ela também permite a análise de bases de dados bibliográficas e de citações em larga escala, como Web of Science e Scopus, facilitando a descoberta de padrões e relações entre produções científicas. Assim, a IA desempenha um papel cada vez mais significativo na metodologia científica, promovendo mudanças e impactos notáveis.²

Fundamentação teórica

A Revisão Sistemática da Literatura (RSL), ou Systematic Literature Review (SLR, em inglês), é uma metodologia rigorosa e organizada que visa avaliar e integrar pesquisas anteriores sobre um tópico específico. Seu objetivo principal é identificar e avaliar de forma meticulosa toda a literatura relevante relacionada a uma questão de pesquisa, minimizando o viés. Tradicionalmente, esse processo é predominantemente manual e pode ser demorado, dificultando a repetição e a escalabilidade das revisões.²

A mineração de texto, que combina técnicas de Processamento de Linguagem Natural (PLN) com métodos de mineração de dados, tem se destacado como uma abordagem eficaz para analisar grandes volumes de texto. Ela é especialmente útil na inferência de conhecimento implícito e na exploração de aspectos semânticos. Em um estágio subsequente, algoritmos de aprendizado de máquina (Machine Learning) são utilizados para avaliar os artigos candidatos com base em suas características, determinando sua relevância para a RSL. Três paradigmas principais de aprendizado de máquina são explorados: aprendizado supervisionado, aprendizado ativo e aprendizado por reforço. No aprendizado supervisionado, um conjunto de dados rotulados é usado para treinar o modelo de decisão. Já no aprendizado ativo, a disponibilidade de dados rotulados não é assumida, mas sim a possibilidade de rotulá-los com um custo. O aprendizado por reforço, por sua vez, avalia as recompensas obtidas a partir de decisões tomadas com base nos dados disponíveis.³

Técnicas de aprendizado supervisionado para seleção de artigos

Métodos supervisionados têm sido amplamente explorados na seleção de artigos, utilizando revisões sistemáticas já existentes para criar conjuntos de dados rotulados e treinar classificadores. Um estudo pioneiro combinou mineração de texto com redes neurais, utilizando o algoritmo de perceptron para treinar um classificador capaz de distinguir entre artigos relevantes e não relevantes, com base em uma representação de "bag of words" (BoW) extraída do título e resumo dos artigos.⁴

Comparações de desempenho entre Máquinas de Vetor de Suporte (SVM) e Regressão Logística com diferentes conjuntos de características, como a técnica TF-IDF para ponderação das palavras, e Modelagem de Tópicos Latentes para a extração de 300 tópicos, foram realizadas para avaliar a eficácia desses métodos em relação à triagem humana. O estudo observou que o desempenho das máquinas pode variar conforme o conjunto de dados e o tipo de representação utilizada, com Máquinas de Vetor de Suporte superando outras técnicas em muitas situações.^{5,6} Além disso, técnicas como o Naive Bayes também têm sido aplicadas para automatizar a seleção de artigos. Uma variação do Complement Naive Bayes (CNB), denominada FCNB/WE (Factorized Complement Naive Bayes/Weight Engineering), combina uma versão modificada do CNB com engenharia de recursos, atribuindo diferentes pesos aos termos extraídos dos artigos.⁷⁻⁹

Técnicas de aprendizado ativo para seleção de artigos

Embora a maioria dos métodos de classificação mencionados acima opere sob uma estratégia supervisionada, técnicas de aprendizado ativo também têm sido exploradas. No aprendizado ativo, o modelo prioriza artigos que são mais incertos ou mais propensos a serem relevantes, de modo a reduzir o esforço de anotação manual. Ferramentas como Abstrackr, FASTREAD e FAST2 utilizam a abordagem de aprendizado ativo, com o classificador subjacente sendo frequentemente baseado em Máquinas de Vetor de Suporte.¹⁰⁻¹² Essas ferramentas permitem que revisores humanos interajam com o sistema, rotulando artigos como relevantes, irrelevantes ou incertos, com base em um conjunto inicial de artigos. O retorno dos revisores é então utilizado para treinar o modelo, melhorando sua precisão ao longo do processo. O FAST2, por exemplo, implementa estratégias aprimoradas para identificar o primeiro artigo relevante e estima quando o aprendizado deve ser interrompido.¹⁰⁻¹²

Outros métodos de apoio à seleção de artigos

A fim de tornar o processo mais interativo e iterativo, algumas abordagens de aprendizado semi-supervisionado têm sido propostas, como a combinação de aprendizado ativo com aprendizado por reforço. No aprendizado por reforço, os classificadores são treinados para explorar artigos menos óbvios, mas que podem ser relevantes, ajudando a evitar viés local. Métodos de prospecção de texto e visualização interativa têm sido incorporados para ajudar na construção de "mapas de documentos", que mostram as relações entre os artigos com base na similaridade de conteúdo. Outras abordagens, como o SCAS (Systematic Citation-based Article Selection), utilizam informações de citação e conteúdo para categorizar artigos em classes, como "incluídos", "excluídos" ou "a serem revisados".¹³

Ferramentas e Classificadores Empregados

Diversas ferramentas têm sido desenvolvidas para ajudar na categorização e triagem de artigos, muitas das quais fazem uso de algoritmos de aprendizado de máquina. Entre essas ferramentas estão ASReview, Litsuggest, SWIFT-Review, EPPIReviewer e Covidence, todas com classificadores como Máquinas de Vetor de Suporte, Regressão Logística e Redes Neurais. Essas ferramentas estão sendo cada vez mais utilizadas em processos de RSL, ajudando a acelerar a triagem e classificação de artigos.¹⁸⁻²⁶

Integração de Modelos Linguísticos de Grande Escala (LLMs)

A aplicação de Modelos Linguísticos de Grande Escala (LLMs), como o GPT-4 da OpenAI, tem se destacado no campo do Processamento de Linguagem Natural (PLN), especialmente em tarefas como classificação e extração de informações de documentos. No entanto, sua integração em ferramentas de Revisão Sistemática da Literatura (RSL) ainda enfrenta desafios significativos. Entre os principais obstáculos, destacam-se a ineficácia em áreas especializadas, a geração de informações imprecisas (alucinações) e a falta de transparência nos processos de decisão dos modelos.²⁷⁻³¹ Uma abordagem promissora para

superar essas limitações é a integração dos LLMs com bases de conhecimento específicas. Isso permitiria fornecer informações verificáveis, aumentando a precisão dos resultados. Além disso, há uma demanda crescente por maior interpretabilidade nos classificadores de artigos, para garantir que os critérios utilizados para selecionar artigos relevantes sejam transparentes.³²⁻³⁴

Embora as ferramentas de IA para RSL tenham avançado consideravelmente, ainda existem limitações em termos de usabilidade, confiabilidade e integração com outras plataformas. Muitos pesquisadores continuam a utilizar métodos manuais, como softwares de planilhas (por exemplo, Microsoft Excel) ou ferramentas de gestão de referências (Zotero, Mendeley). Além disso, a curva de aprendizado e as barreiras financeiras dificultam a adoção em larga escala dessas ferramentas.³⁵⁻³⁸

Com o avanço das tecnologias de IA, espera-se que novas ferramentas baseadas em LLMs sejam integradas ao processo de RSL, melhorando tanto a precisão quanto a eficiência das revisões. A evolução das interfaces e a incorporação de técnicas de explicabilidade, como Cadeia de Pensamento e Árvore de Pensamentos, são áreas promissoras para aumentar a transparência e confiabilidade dos modelos.^{39,40}

Desafios e Limitações no Uso de Ferramentas de RSL

Estudos recentes apontam que as limitações no uso dessas ferramentas estão frequentemente relacionadas à usabilidade e a fatores adicionais, como:

- Curva de aprendizado acentuada: Muitos pesquisadores não estão familiarizados com todas as funcionalidades dessas ferramentas;
- Desalinhamento com os requisitos dos usuários: Muitas ferramentas não seguem os protocolos de Revisão Sistemática da Literatura, além de terem compatibilidade limitada com outros softwares;
- Desconfiança na confiabilidade e nos mecanismos dessas ferramentas, resultando em hesitação na sua adoção;

- Barreiras financeiras: O custo de licenciamento, bem como restrições para versões de teste, são obstáculos consideráveis.

Há uma lacuna significativa na literatura sobre a usabilidade dessas ferramentas, com poucos estudos abordando este tema de forma aprofundada.⁴¹⁻⁴⁷

Estruturas e Tecnologias: RAG e LLMs

Os sistemas de RSL geralmente utilizam LLMs, frequentemente através da API OpenAI, complementados por estruturas como a Retriever-Augmented Generation (RAG). Essa estrutura permite que os modelos consultem coleções de documentos e integrem essas informações ao seu contexto, tornando-os mais precisos e confiáveis ao dependerem de fontes verificáveis. A estrutura RAG ajuda a reduzir as imprecisões e as alucinações, garantindo maior fidelidade aos resultados.⁴⁸ Esses sistemas podem ser classificados em duas categorias principais: mecanismos de busca e assistentes de redação.

Ferramentas de mecanismo de busca

As ferramentas de busca permitem que os usuários formulem consultas em linguagem natural, gerando uma lista de artigos de pesquisa relevantes, muitas vezes acompanhados de resumos. Algumas dessas ferramentas oferecem funcionalidades adicionais de pesquisa, como a capacidade de extrair informações com base em categorias predefinidas, o que pode ser útil para a revisão de literatura. Exemplos dessas ferramentas incluem:

- Scite: Permite busca por palavras-chave em títulos e resumos, além de realizar buscas dentro de “declarações de citação” (segmentos de texto com citações).
- Scispace e Elicit: Essas ferramentas extraem automaticamente informações com base em categorias específicas, como a identificação de referências a "tecnologias" em um artigo. No entanto, a qualidade dos resultados pode variar.^{50,51}

Essas ferramentas utilizam diferentes bases de dados, como o Semantic Scholar (usado por Elicit, Consensus e Perplexidade) e uma gama mais ampla de editoras, como Wiley, Sage, e Europe PMC (utilizadas pelo Scite). Embora os detalhes técnicos de implementação não sejam completamente revelados, muitas dessas ferramentas fazem uso da API OpenAI, integrando a tecnologia de LLM com a estrutura RAG para aumentar a eficácia das buscas.

Ferramentas do Assistente de Escrita

Essas ferramentas permitem que o usuário forneça uma descrição do texto desejado, e a IA gera um modelo que pode ser refinado iterativamente. Algumas ferramentas interativas, como Jenni.ai, permitem que o usuário edite o texto gerado em tempo real, enquanto Textero.ai oferece recursos adicionais, como a geração de referências e a formatação de citações. Outros exemplos incluem Silatus, que oferece diferentes modos de geração de conteúdo (respostas a perguntas, relatórios de pesquisa, postagens em blogs e redes sociais). O usuário pode também optar por integrar referências pertinentes ao texto gerado. Embora essas ferramentas sejam úteis, a qualidade do conteúdo gerado varia e, atualmente, elas são mais adequadas para tarefas mais simples, como redação de ensaios, do que para pesquisadores que necessitam de revisão literária aprofundada. Contudo, à medida que a tecnologia evolui, espera-se que essas ferramentas se tornem mais robustas, sendo capazes de automatizar até tarefas complexas, como a criação de revisões completas da literatura.

Considerações Éticas e Desafios na Pesquisa com IA

Com o crescente uso de IA na pesquisa científica, surgem preocupações éticas, especialmente em relação à transparência, parcialidade e responsabilidade dos algoritmos utilizados. A capacidade da IA de aprender e até gerar conhecimento desafia os paradigmas tradicionais de autoria científica e credibilidade.⁵²

A integridade na pesquisa com IA não é apenas uma questão acadêmica, mas tem implicações práticas significativas. Decisões baseadas em modelos tendenciosos podem levar

a conclusões errôneas, desperdício de recursos e até prejudicar a sociedade. Além disso, a confiança pública na ciência depende da adesão a princípios éticos rigorosos, garantindo que a pesquisa seja conduzida de maneira transparente e responsável.⁵³ Nesse contexto, é fundamental que pesquisadores, desenvolvedores e reguladores colaborem para estabelecer diretrizes e padrões éticos claros, promovendo um uso responsável da IA na pesquisa científica. Isso inclui a criação de algoritmos transparentes e auditáveis, revisões éticas rigorosas e um diálogo contínuo entre as comunidades científicas e a sociedade.

As orientações das editoras sobre o uso da Inteligência Artificial (IA) variam, mas algumas diretrizes essenciais surgem da análise das políticas editoriais. A Elsevier permite o uso de IA, desde que os autores a mencionem e não a utilizem para substituir tarefas intelectuais necessárias, como redigir a introdução ou as conclusões.⁵⁴ A Taylor & Francis apoia o uso de IA, exigindo uma divulgação detalhada de sua utilização e responsabilizando os autores pela originalidade e veracidade das informações.⁵⁵ A Wiley adota uma postura crítica, mas permite o uso de IA, desde que não seja listada como coautora e seja utilizada de forma ética.⁵⁶ A SAGE valoriza o uso transparente e detalhado da IA, enfatizando a responsabilidade dos autores pela integridade das informações.⁵⁷ A Springer Nature adota uma abordagem cautelosa, exigindo uma descrição do uso da IA e não permitindo seu uso para imagens em geral, exceto em casos específicos relacionados à demonstração da tecnologia de IA. Por fim, a⁵⁸ Cambridge University Press não considera a IA como coautora e destaca que seu uso não deve violar as políticas de plágio, com os autores mantendo a responsabilidade pela precisão e originalidade. Embora cada revista tenha políticas editoriais específicas, há um consenso de que a IA não deve ser coautora e seu uso deve ser claramente declarado e ético, alinhado com as práticas de pesquisa.⁵⁹

Adoção de IA pelos Cientistas

A adoção de IA no meio científico ainda enfrenta barreiras consideráveis. Uma pesquisa realizada pela Nature com mais de 1.600 pesquisadores revelou que as principais

dificuldades incluem a falta de habilidades (80%), a ausência de recursos de treinamento (70%) e financiamento insuficiente (50%). Além disso, muitos cientistas ainda não percebem o valor da IA em suas pesquisas, o que contribui para uma resistência ao uso dessa tecnologia.^{59,60} No entanto, a colaboração interdisciplinar entre cientistas da computação e outras áreas tem se mostrado eficaz, especialmente em projetos que geram citações relevantes. Embora essa abordagem seja útil, nem todos os pesquisadores têm a oportunidade ou os recursos para adotar essa estratégia.

CONCLUSÃO

O uso da Inteligência Artificial na pesquisa científica é uma jornada contínua e multifacetada, repleta de avanços notáveis e desafios significativos. Desde os primórdios da IA, com pioneiros como John McCarthy, até os recentes desenvolvimentos em redes neurais profundas, a IA tem assumido um papel cada vez mais crucial na metodologia científica. Ao longo do tempo, destacou-se em diversas áreas, desde a análise de grandes volumes de dados até a automação de tarefas em Revisões Sistemáticas da Literatura. No entanto, a integração da IA na pesquisa não é isenta de preocupações éticas e desafios práticos. Questões como transparência, interpretabilidade e responsabilidade se tornam cada vez mais urgentes à medida que os algoritmos se tornam mais complexos e fundamentais ao processo científico. Assim, o desenvolvimento de diretrizes claras e padrões éticos é imperativo para assegurar o uso responsável da IA, alinhado aos princípios fundamentais da pesquisa. Além disso, o acesso equitativo à tecnologia e o desenvolvimento de habilidades em IA emergem como fatores críticos que influenciam sua adoção na comunidade científica. É essencial abordar essas lacunas de habilidades e recursos para garantir que todos os cientistas possam aproveitar o potencial da IA em suas pesquisas.

Em última análise, a integridade e a ética devem permanecer no centro de todas as iniciativas envolvendo IA na pesquisa científica. Somente por meio de uma abordagem

responsável e colaborativa podemos alcançar o verdadeiro potencial da IA para impulsionar o progresso científico de maneira ética e sustentável.

AGRADECIMENTOS

Meus sinceros agradecimentos são para a minha orientadora Vera R. L. Constantino, e aos professores, Ataulpa A. C. Braga, Denise F. S. Petri e Paulo R. H. Moreno por todo conhecimento compartilhado.

REFERÊNCIAS

1. Xu, Y.; et al. *The Innovation* (2021), <https://doi.org/10.1016/j.xinn.2021.100179>
2. Saeidnia, H. R.; Hosseini, E.; Abdoli, S.; Ausloos, M.; *Library Hi Tech* (2024), <https://doi.org/10.48550/arXiv.2403.18838>
3. Torre-López, A.J.; Ramírez, A.; Romero, J. R.; *Computing* (2023), <https://doi.org/10.1007/s00607-023-01181-x>
4. Cohen, A. M.; Hersh, W. R.; Peterson, K.; Yen, P. Y.; *J. Am. Med. Inform. Assoc.* (2006), doi: 10.1197/jamia.M1929
5. Bannach-Brown, A.; Przybyła, P.; Thomas, J.; Rice, A. S. C.; Ananiadou, S.; Liao, J.; et al.; *Syst Rev* (2019), doi: [10.1186/s13643-019-0942-7](https://doi.org/10.1186/s13643-019-0942-7)
6. Thomas, J.; McDonald, S.; Noel-Storr, A.; Shemilt, I.; Elliott, J.; Mavergames, C.; Marshall, I. J.; *J. Clin. Epidemiol.* (2021), doi: [10.1016/j.jclinepi.2020.11.003](https://doi.org/10.1016/j.jclinepi.2020.11.003)
7. Matwin, S.; Kouznetsov, A.; Inkpen, D.; Frunza, O.; O'Brien, P.; *J. Am. Med. Inform. Assoc.* (2010), doi: [10.1136/jamia.2010.004325](https://doi.org/10.1136/jamia.2010.004325)
8. Frunza, O.; Inkpen, D.; Matwin, S.; *Proceedings of the 23rd International Conference on Computational Linguistics*, 2010.

9. Adeva, J. J. G.; et al.; *Expert Syst Appl* (2014),
<https://doi.org/10.1016/j.eswa.2013.08.047>
10. Wallace, B. C.; Small, K.; Brodley, C. E.; Lau, J.; Trikalinos, T. A.; *Proceedings of the 2nd ACM SIGHIT International Health Informatics Symposium* (2012).
11. Yu, Z.; Kraft, N. A.; Menzies, T.; *Empir Software Eng* (2018), <https://doi.org/10.1007/s10664-017-9587-0>
12. Yu, Z.; Menzies, T.; *Expert Syst Appl* (2019),
<https://doi.org/10.1016/j.eswa.2018.11.021> [Get rights and content](#)
13. Ros, R.; Bjarnason, E.; Runeson, P.; *Proceedings of the 21st International Conference on Evaluation and Assessment in Software Engineering*, 2017.
14. Felizardo, K. R.; Andery, G. F.; Paulovich, F. V.; Minghim, R.; Maldonado, J. C.; *Inf. Softw. Technol.* (2012), <https://doi.org/10.1016/j.infsof.2012.04.003>
15. Alencar, A. B.; de Oliveira, M. C. F.; Paulovich, F. V.; *WIRES Data Mining Knowl. Discov.* (2012), <https://doi.org/10.1002/widm.1071>
16. Octaviano, F. R.; Felizardo, K. R.; Maldonado, J. C.; Fabbri, S. C. P. F.; *Empir Software Eng* (2015), <https://doi.org/10.1007/s10664-014-9342-8>
17. Langlois, A.; Nie, J. Y.; Thomas, J.; Hong, Q. N.; Pluye, P.; *Res. Synth. Methods* (2018), doi: [10.1002/jrsm.1317](https://doi.org/10.1002/jrsm.1317)
18. Bolanos, F.; Salatino, A.; Osborne, F.; Motta, E.; *Artif Intell Rev* (2024),
<https://doi.org/10.1007/s10462-024-10902-3>
19. Schmidt, L.; Olorisade, B. K.; McGuinness, L. A.; Thomas, J.; Higgins, J. P.; *F1000Res* (2021), doi: [10.12688/f1000research.51117.2](https://doi.org/10.12688/f1000research.51117.2)
20. Marshall, I. J.; Noel-Storr, A.; Kuiper, J.; Thomas, J.; Wallace, B. C.; *Res. Synth. Methods* (2018), doi: [10.1002/jrsm.1287](https://doi.org/10.1002/jrsm.1287)
21. Wu, R.; Stauber, V.; Botev, V.; Elosua, J.; Brede, A.; Ritola, M.; Marinov, K.; *Proceedings of the Eleventh International Conference on Language Resources and Evaluation (LREC 2018)*; Paris, France, 2018.

22. Cheng, S.; et al.; *Conserv. Biol.* (2018), doi: [10.1111/cobi.13117](https://doi.org/10.1111/cobi.13117)
23. Higgins, J. P. T.; Thomas, J.; Chandler, J.; Cumpston, M.; Li, T.; Page, M. J.; Welch, V. A. (eds.). *Cochrane Handbook for Systematic Reviews of Interventions*, 2nd ed., John Wiley & Sons: Chichester, UK, 2019.
24. Craig, D.; Rice, S. *NHS Economic Evaluation Database Handbook*; Centre for Reviews and Dissemination: York, 2007.
25. La Toile, Q.; *Database of abstracts of reviews of effects (DARE)*. Douleurs 2004, 5.
26. Onan, A.; Korukoğlu, S.; Bulut, H.; *Expert Syst Appl* (2016), <https://doi.org/10.1016/j.eswa.2016.03.045>
27. Min, B.; et al.; *ACM Comput. Surv.* (2023), <https://doi.org/10.48550/arXiv.2111.01243>
28. Dunn, A.; et al.; *arXiv* (2022), <https://doi.org/10.48550/arXiv.2212.05238>
29. Xu, D.; et al.; *arXiv* (2023), <https://doi.org/10.48550/arXiv.2312.17617>
30. Ji, Z.; et al.; *ACM Comput. Surv.* (2023), <https://doi.org/10.48550/arXiv.2202.03629>
31. Meloni, A.; et al.; *IEEE Access* (2023), doi: 10.1109/ACCESS.2023.3253388
32. Vladika, J.; Matthes, F. *arXiv* (2023), <https://doi.org/10.48550/arXiv.2305.16859>.
33. Lawrence, J.; Reed, C. *Comput. Linguist.* (2020), doi: [10.1162/coli_a_00364](https://doi.org/10.1162/coli_a_00364).
34. Linardatos, P.; Papastefanopoulos, V.; Kotsiantis, S. *Entropy* (2020), <https://doi.org/10.3390/e23010018>.
35. Wei, J.; et al.; *arXiv* (2023), <https://doi.org/10.48550/arXiv.2201.11903>.
36. Yao, S.; et al.; *arXiv* (2023), <https://doi.org/10.48550/arXiv.2305.10601>.
37. Long, J.; *arXiv* (2023), <https://doi.org/10.48550/arXiv.2305.08291>.
38. Besta, M.; et al.; *arXiv* (2023), <https://doi.org/10.48550/arXiv.2308.09687>.
39. Marshall, C.; Kitchenham, B.; Brereton, P.; *e-Informatica Softw Eng J* (2018), doi: [10.5277/e-Inf180104](https://doi.org/10.5277/e-Inf180104)

-
40. Marshall, C.; et al.; *Proceedings of the 19th International Conference on Evaluation and Assessment in Software Engineering* (2015), <https://doi.org/10.1145/2745802.2745827>.
41. Van Altena, A.; Spijker, R.; Olabarriaga, S.; *Res. Synth. Methods* (2019), doi: [10.1002/jrsm.1335](https://doi.org/10.1002/jrsm.1335).
42. Scott, A. M.; et al.; *J. Clin. Epidemiol.* (2021), doi: [10.1016/j.jclinepi.2021.06.030](https://doi.org/10.1016/j.jclinepi.2021.06.030).
43. Thomas, J.; *BMJ Evid Based Med* (2013), doi: [10.13172/2053-2636-1-2-1109](https://doi.org/10.13172/2053-2636-1-2-1109).
44. Arno, A.; et al.; *Syst. Rev.* (2021), <https://doi.org/10.1186/s13643-020-01569-2>.
45. O'Connor, A. M.; et al.; *Syst. Rev.* (2019), <https://doi.org/10.1186/s13643-019-1062-0>.
46. Haddaway, N. R.; et al.; *Syst. Rev.* (2020), <https://doi.org/10.1002/cl2.1129>
47. Dell, N. A.; et al.; *J. Soc. Social Work Res.* (2021), doi: [10.1086/713525](https://doi.org/10.1086/713525).
48. Lewis, P.; et al.; *arXiv* (2020), <https://doi.org/10.48550/arXiv.2005.11401>.
49. Ji, Z.; et al.; *arXiv* (2023), <https://doi.org/10.48550/arXiv.2202.03629>.
50. Nicholson, J. M.; et al.; *Quant. Sci. Stud.* (2021), doi: 10.1162/qss_a_00146.
51. Ding, Y.; et al.; *J. Assoc. Inf. Sci. Technol.* (2014), <https://doi.org/10.1002/asi.23256>.
52. Limongi, R.; *Future Studies Research Journal: Trends and Strategies* (2024), <https://doi.org/10.24023/FutureJournal/2175-5825/2024.v16i1.845>.
53. Williams, N. H.; *Artificial Intelligence and Algorithmic Bias* (2024), doi: 10.1007/978-3-031-48262-5.
54. <https://www.elsevier.com/about/policies-and-standards/the-use-of-generative-ai-and-ai-assisted-technologies-in-writing-for-elsevier>, acessada em junho 2024.
55. <https://newsroom.taylorandfrancisgroup.com/taylor-francis-clarifies-the-responsible-use-of-ai-tools-in-academic-content-creation/>, acessada em junho 2024.
56. <https://authorservices.wiley.com/ethics-guidelines/index.html>, acessada em junho 2024.

57. <https://learningresources.sagepub.com/author-guidelines-on-using-generative-ai-and-large-language-models>, acessada em junho 2024.
58. <https://www.nature.com/nature-portfolio/editorial-policies/ai>, acessada em junho 2024.
59. <https://www.cambridge.org/core/services/authors/publishing-ethics/research-publishing-ethics-guidelines-for-journals/authorship-and-contributorship>, acessada em junho 2024.
60. Van Noorden, R.; Perkel, J. M.; *Nature* (2023), doi: 10.1038/d41586-023-02980-0.
61. Hwang, G. J.; Fu, Q. K.; *Interact. Learn. Environ.* (2018), <https://doi.org/10.1080/10494820.2018.1486861>.