Área temática: Tecnologia, Inteligência Artificial e Transformação Digital em Administração

Categoria: ENANGRAD Pleno

AVANÇANDO O PROCESSO DE REVISÃO DE LITERATURA: BASES ACADÊMICAS COM INTELIGÊNCIA ARTIFICIAL COMPARADAS AOS MÉTODOS TRADICIONAIS

Resumo

Este artigo examina como bases acadêmicas com inteligência artificial podem reconfigurar as etapas iniciais da revisão de literatura em comparação com métodos tradicionais de busca, triagem e organização manual. Com base em uma revisão conceitual focalizada, apoiada pelo uso do Scopus AI como ferramenta de descoberta e pela verificação manual dos artigos acadêmicos disponíveis, o estudo argumenta que essas bases podem contribuir para um ponto de partida mais estruturado ao apoiar busca semântica, triagem por relevância, mapeamento de citações, agrupamento temático e síntese preliminar. A evidência é mais forte para a redução de carga de trabalho e para o apoio à triagem em contextos de revisões estruturadas, enquanto afirmações sobre abrangência, qualidade da síntese e desempenho interdisciplinar exigem formulação cautelosa. O artigo contribui para a metodologia de pesquisa e para a Administração ao propor um quadro no qual a IA não substitui o julgamento científico, mas redistribui o esforço do pesquisador para validação, interpretação e síntese crítica.

Palavras-chave: inteligência artificial; bases acadêmicas; revisão de literatura; síntese de evidências; metodologia de pesquisa.

1. Introdução

A expansão da publicação acadêmica intensificou um desafio metodológico central para os pesquisadores: a quantidade de literatura que precisa ser localizada, filtrada, organizada e interpretada antes que um problema de pesquisa robusto possa ser formulado. Os processos tradicionais de revisão de literatura dependem de buscas por palavras-chave, operadores booleanos, filtros específicos de bases de dados, triagem manual de títulos e resumos, rastreamento de citações e leitura iterativa. Esses procedimentos continuam importantes porque oferecem transparência, controle e proximidade com as fontes originais. No entanto, tornam-se cada vez mais demorados e cognitivamente exigentes, especialmente em campos fragmentados, interdisciplinares e de rápida evolução.

Bases acadêmicas com inteligência artificial emergiram como ferramentas que podem apoiar a descoberta de literatura, a triagem por relevância, a busca semântica, o mapeamento de citações, o agrupamento temático, a extração de dados e a síntese preliminar. A questão central não é se essas ferramentas substituem os pesquisadores. A questão metodológica mais relevante é como elas alteram o ponto a partir do qual os pesquisadores iniciam o trabalho científico. Em vez de começar com um conjunto de resultados de busca pouco estruturado, os pesquisadores podem iniciar a partir de um mapa preliminar assistido por IA, composto por conceitos, referências candidatas, estudos relacionados e temas emergentes.

A pergunta de pesquisa que orienta este artigo é: como o uso de bases acadêmicas com inteligência artificial pode permitir que pesquisadores iniciem o trabalho científico em uma etapa mais avançada do processo de revisão de literatura, em comparação com métodos tradicionais de busca, triagem e organização manual da literatura?

Este artigo tem como objetivo examinar como bases acadêmicas com inteligência artificial reconfiguram as etapas iniciais dos processos de revisão de literatura ao permitir que pesquisadores

partam de um ponto inicial mais estruturado e avançado, ao mesmo tempo em que identifica as condições metodológicas necessárias para preservar rigor, transparência e análise crítica. A contribuição é dupla. Primeiro, o artigo esclarece a diferença metodológica entre o ponto de partida manual tradicional e o ponto de partida estruturado assistido por IA. Segundo, discute implicações para pesquisas em Administração, área na qual estudantes de graduação, pós-graduação e docentes enfrentam pressão crescente para produzir revisões de literatura oportunas, transparentes e teoricamente fundamentadas.

Na pesquisa em Administração, as revisões de literatura desempenham um papel importante na delimitação das fronteiras conceituais dos estudos, na justificação da relevância dos problemas de investigação e no posicionamento dos artigos em debates sobre organizações, inovação, estratégia, aprendizagem, gestão pública e transformação digital. No entanto, a ampliação contínua da produção científica torna as etapas iniciais de busca, triagem e organização da literatura cada vez mais exigentes em termos de tempo e esforço. Quando uma parte significativa desse esforço é dedicada à localização e filtragem de fontes, pode haver menor disponibilidade para atividades analíticas posteriores, como a comparação conceitual, a avaliação metodológica dos estudos e a construção do posicionamento teórico. Nesse contexto, as bases acadêmicas com inteligência artificial emergem como ferramentas relevantes para repensar a distribuição do esforço ao longo do processo de revisão da literatura.

Ao mesmo tempo, a incorporação de inteligência artificial à busca acadêmica levanta questões metodológicas importantes. Resumos, ranqueamentos, recomendações e agrupamentos gerados por IA podem apoiar a organização preliminar da literatura, mas também requerem verificação e interpretação crítica. Caso esses resultados sejam aceitos sem validação, há o risco de reduzir a transparência e a reprodutibilidade do processo de revisão. Assim, este artigo examina as bases acadêmicas com IA como ferramentas de apoio ao trabalho científico, considerando tanto seu potencial para qualificar o ponto de partida da revisão da literatura quanto suas limitações, incluindo ranqueamentos opacos, resumos imprecisos, cobertura incompleta e dependência excessiva de sinais automatizados de relevância.

A partir dessa problemática, o artigo investiga como o uso de bases acadêmicas com inteligência artificial pode permitir que pesquisadores iniciem o trabalho científico em uma etapa mais avançada do processo de revisão da literatura, em comparação com métodos tradicionais de busca e triagem manual.

Este artigo está organizado em cinco seções principais. Após esta introdução, a seção de Metodologia descreve a abordagem de revisão conceitual focalizada, o uso do Scopus AI como ferramenta de descoberta assistida por IA, os critérios de triagem e o procedimento analítico adotado para interpretar a literatura. A seção de Resultados apresenta os principais achados conceituais, incluindo o contraste entre métodos tradicionais manuais de revisão de literatura e pontos de partida estruturados assistidos por IA, bem como a comparação entre as duas abordagens. A seção de Discussão interpreta esses achados, desenvolve o quadro conceitual proposto e apresenta implicações práticas para o uso responsável em pesquisas em Administração. Por fim, a Conclusão responde à pergunta de pesquisa, resume as contribuições e limitações do artigo e sugere direções para futuras pesquisas empíricas.

2. Metodologia

Este artigo adota uma abordagem de revisão conceitual focalizada da literatura, de natureza interpretativa e conceitualmente orientada. A revisão não tem como objetivo realizar uma avaliação sistemática ou meta-analítica do desempenho das bases de dados acadêmicas com inteligência artificial em diferentes campos disciplinares. Em vez disso, procura organizar e interpretar a literatura sobre busca acadêmica assistida por IA, automação de revisões de literatura, triagem de relevância, mapeamento de citações, extração de dados, síntese preliminar e colaboração humano-IA. Esse desenho metodológico é adequado ao objetivo do artigo, uma vez que permite desenvolver um argumento conceitual sobre a transição de um ponto de partida predominantemente manual para um ponto de partida mais estruturado e assistido por IA no processo de revisão da literatura.

Scopus AI foi utilizado como ferramenta de apoio à descoberta inicial da literatura. A consulta foi realizada no dia 03 de junho de 2026 a partir da seguinte pergunta de investigação: *"How can the use*

of AI-powered academic databases enable researchers to begin scientific work at a more advanced stage of the literature review process compared with traditional methods of manual searching, screening, and organising literature?". A utilização dessa pergunta como consulta teve como objetivo identificar estudos relacionados ao uso de bases de dados acadêmicas com IA, automação de revisões de literatura, busca semântica, triagem assistida, mapeamento de citações, síntese preliminar e colaboração humano-IA.

A consulta gerou um relatório com 60 artigos, que constituíram o universo inicial de identificação. Esses registros foram inicialmente avaliados pelos investigadores com base no tipo de publicação, na qualidade editorial da fonte, na disponibilidade em acesso aberto e na relevância para a pergunta de investigação. Após essa triagem preliminar, os artigos elegíveis foram baixados em texto completo para análise. O Scopus AI foi utilizado apenas para apoiar a identificação inicial da literatura, não para substituir o julgamento analítico dos autores.

A lógica de busca foi orientada pela própria pergunta de investigação, centrada na comparação entre bases de dados acadêmicas com IA e métodos tradicionais de busca, triagem e organização manual da literatura. O escopo temático incluiu bases de dados acadêmicas com IA, métodos tradicionais de revisão da literatura, busca manual, triagem de relevância, busca semântica, análise de redes de citação, agrupamento temático, extração de dados, síntese preliminar, colaboração humano-IA, transparência, reprodutibilidade, viés, alucinações e rigor metodológico.

Os 60 artigos inicialmente identificados no relatório do Scopus AI foram triados manualmente pelos investigadores. A triagem considerou quatro critérios principais: tipo de publicação, qualidade editorial da fonte, disponibilidade em acesso aberto e relevância temática para a pergunta de investigação.

Foram incluídos estudos que apresentavam relevância direta para bases de dados acadêmicas com IA ou ferramentas de revisão da literatura assistidas por IA; conexão com processos de descoberta, triagem, mapeamento, extração ou síntese; comparação explícita ou implícita com métodos tradicionais de busca e triagem manual; contribuição para a discussão sobre eficiência, abrangência, transparência, rigor metodológico ou validação humana; e detalhe conceitual ou empírico suficiente para sustentar o argumento do artigo.

Foram excluídos artigos de conferência, publicações em revistas consideradas predatórias, estudos sem acesso aberto ao texto completo, fontes com relevância apenas periférica para a pergunta de investigação, trabalhos sem conexão clara com processos de revisão da literatura, estudos com detalhe conceitual ou empírico insuficiente e estudos redundantes em relação a fontes mais diretamente relevantes.

Como limitação, este artigo possui natureza conceitual e não apresenta mensuração empírica primária de tempo economizado, acurácia, produtividade ou qualidade comparativa entre métodos tradicionais e bases de dados acadêmicas com IA. O argumento desenvolvido requer validação empírica futura em diferentes disciplinas, línguas, bases de dados e configurações tecnológicas.

Tabela 1 - Procedimento metodológico

Etapa	Procedimento	Finalidade	Etapa de validação humana
Definição da pergunta de pesquisa	A pergunta de pesquisa foi definida antes da interpretação da literatura.	Delimitar o problema conceitual.	A pergunta orientou a seleção e a síntese.
Descoberta de literatura assistida por IA	O Scopus AI foi usado como ferramenta de descoberta e fonte de um conjunto inicial de referências.	Identificar temas e fontes relevantes.	Os resultados de IA foram tratados como provisórios.
Triagem manual	As referências foram triadas conforme sua relevância para o trabalho de revisão assistido por IA.	Reter fontes conectadas à pergunta de pesquisa.	Fontes periféricas e não sustentadas foram excluídas ou usadas com cautela.
Organização temática	As evidências foram agrupadas em torno de eficiência, descoberta, triagem, mapeamento,	Identificar padrões	Os temas foram comparados com

	riscos e validação humana.	conceituais.	o conteúdo dos artigos.
Síntese conceitual	A literatura foi interpretada por meio da distinção entre pontos de partida manuais e assistidos por IA.	Desenvolver o argumento do artigo.	As afirmações foram formuladas com linguagem cautelosa.
Validação de afirmações e limitações	As afirmações do Scopus AI foram comparadas com os artigos disponíveis, e a força da evidência foi classificada.	Evitar aceitação acrítica de afirmações geradas por IA.	Afirmações não sustentadas ou amplas foram revisadas.

Fonte: Elaborado pelos autores com base na revisão conceitual focalizada.

3. Resultados

Os resultados apresentados nesta seção decorrem da análise dos 23 artigos que compuseram o corpus final da revisão. A partir desse conjunto, foram identificados achados conceituais sobre como bases acadêmicas com inteligência artificial podem reconfigurar as etapas iniciais da revisão de literatura em comparação com métodos tradicionais de busca, triagem e organização manual. A análise foi organizada em torno de cinco dimensões: o ponto de partida manual tradicional; o ponto de partida estruturado assistido por IA; o potencial de eficiência e economia de tempo; a abrangência e o mapeamento do conhecimento; e os riscos metodológicos associados ao uso de sistemas automatizados. Assim, a seção não apresenta os resultados como uma oposição simples entre métodos tradicionais e ferramentas de IA, mas como uma comparação das condições em que a IA pode apoiar a estruturação inicial da revisão sem substituir a validação crítica do pesquisador.

3.1. Métodos tradicionais de revisão de literatura e o ponto de partida manual

O trabalho tradicional de revisão geralmente começa com buscas por palavras-chave, operadores booleanos, exploração manual de bases de dados, triagem de títulos e resumos, rastreamento de citações e organização manual de referências. Esse processo dá aos pesquisadores forte controle sobre a lógica de busca e torna a revisão mais transparente quando cadeias de busca, filtros, bases de dados e critérios de inclusão são documentados. No entanto, o ponto de partida tradicional costuma ser pouco estruturado: os pesquisadores precisam construir gradualmente o mapa do campo por meio de leitura, comparação e reorganização de referências. Em revisões sistemáticas, a etapa de triagem pode tornar-se especialmente trabalhosa porque grandes conjuntos de resultados exigem decisões repetidas de relevância (Feng et al., 2022). Avaliações de ferramentas também indicam que decisões manuais podem permanecer vulneráveis a variação quando os critérios de triagem são complexos ou ambíguos (Ruan et al., 2025).

3.2. Bases acadêmicas com IA e o ponto de partida estruturado

Bases acadêmicas com IA podem deslocar o ponto de partida do trabalho de revisão ao oferecer resultados de busca semântica, relevância ranqueada por IA, sugestões de literatura relacionada, redes de citação, agrupamentos temáticos, sinais de tendências, resumos preliminares e possíveis lacunas de conhecimento. Evidências de revisão sustentam a afirmação de que a IA pode auxiliar busca, triagem, sumarização e mapeamento, mas também mostram que essas funções devem ser tratadas como apoio, e não como síntese automática (Bolanos et al., 2024). Evidências de estudo de caso metodológico sugerem que a IA pode apoiar buscas de literatura orientadas por teoria quando o julgamento especializado de busca permanece ativo (Hunter et al., 2026). Evidências de um tema complexo nas ciências sociais mostram que sistemas de revisão de literatura com IA podem produzir resultados exploratórios úteis, mas esses resultados variam entre ferramentas e exigem interpretação (Moulaison-Sandy et al., 2025).

3.3. Potencial de eficiência e economia de tempo

A evidência mais forte diz respeito à eficiência na triagem e à redução da carga de trabalho. Evidências de triagem médica automatizada indicam que ferramentas de IA podem reduzir a carga de triagem enquanto mantêm desempenho útil sob condições específicas (Feng et al., 2022). Uma avaliação de revisão sobre cardiotoxicidade sustenta a afirmação mais específica de que a IA pode auxiliar a triagem textual em um contexto de revisão sistemática estruturada (Canfield et al., 2025).

Evidências comparativas sobre triagem automática da literatura mostram que recall e especificidade variam conforme a ferramenta, o que significa que a redução de carga de trabalho deve ser equilibrada com requisitos de validação (Ruan et al., 2025). Pesquisas em síntese de evidências ambientais indicam que a triagem baseada em GPT pode apoiar a priorização mais precoce de estudos relevantes, mas ainda exige verificação humana (Nykvist et al., 2025). Evidências sobre custo e carga de trabalho sugerem que a IA pode reduzir demandas de trabalho na síntese de evidências, mas apenas para tarefas e contextos nos quais a carga de trabalho foi efetivamente medida (Abogunrin et al., 2025).

3.4. Abrangência e mapeamento do conhecimento

Sistemas com IA podem ampliar a exploração ao identificar trabalhos semanticamente relacionados, conexões interdisciplinares, relações de citação e temas emergentes. Pesquisas sobre revisão de literatura indicam que a IA pode apoiar funções de expansão de busca e mapeamento quando os pesquisadores verificam os resultados com base no material-fonte (Bolanos et al., 2024). Um estudo de caso metodológico mostra que a IA pode ajudar pesquisadores a buscar de modo mais conceitual, em vez de depender apenas da correspondência exata de palavras-chave (Hunter et al., 2026). No entanto, a abrangência depende da cobertura da base de dados, das práticas de indexação, da cobertura linguística, dos metadados disponíveis e do desenho da ferramenta. Evidências de temas complexos nas ciências sociais indicam que sistemas de revisão de literatura com IA podem gerar resultados úteis, mas também apresentam affordances e limitações variáveis, especialmente quando os conceitos são ambíguos ou interdisciplinares (Moulaison-Sandy et al., 2025).

3.5. Riscos e limitações identificados na literatura

A literatura identifica várias limitações: alucinações, viés algorítmico, falta de transparência, baixa reprodutibilidade, dependência excessiva de resumos gerados por IA, dependência da literatura indexada, viés de língua inglesa e risco de reduzir o engajamento crítico com os artigos originais. A transparência é uma preocupação metodológica específica porque a busca mediada por IA pode ocultar critérios de ranqueamento, comportamento do modelo e mudanças entre versões da ferramenta (Sebastiao & Dias, 2025). A análise ética da publicação científica indica que divulgação e responsabilização são necessárias quando ferramentas assistidas por IA moldam a comunicação acadêmica (Veiga, 2025). O viés pode surgir de pressupostos de anotadores e de processos de treinamento em PLN (Gautam & Srinath, 2024). O viés também pode moldar a evolução do campo e a visibilidade em domínios adjacentes à Administração, como marketing analytics (Bacalhau et al., 2025). A literatura mais ampla sobre viés em IA reforça a necessidade de detecção, mitigação e salvaguardas éticas em aplicações reais de IA (Samala & Rawas, 2025).

3.6. Comparação entre métodos tradicionais e bases acadêmicas com IA

3.6.1. O ponto de partida tradicional é metodologicamente transparente, mas operacionalmente exigente

Procedimentos tradicionais de busca exigem que os pesquisadores definam vocabulário, traduzam conceitos em cadeias de busca, adaptem essas cadeias a diferentes bases de dados, removam duplicatas e organizem registros manualmente. Esse procedimento pode ser rigoroso quando bem documentado, mas frequentemente produz um conjunto amplo de resultados pouco ordenados, especialmente quando a triagem depende de decisões sucessivas de relevância em grandes conjuntos de registros (Feng et al., 2022). O pesquisador precisa construir relevância gradualmente, movendo-se de um conjunto amplo de recuperação para um corpus interpretativo menor, o que torna o processo transparente, porém operacionalmente exigente (Ruan et al., 2025).

Tabela 2 - Comparação entre métodos tradicionais e bases acadêmicas com IA

Dimensão	Métodos manuais tradicionais	Bases acadêmicas com IA	Vantagem potencial da IA	Risco metodológico	Salvaguarda necessária	Referências de apoio
Velocidade de busca	Busca manual por palavras-chave e operadores booleanos em bases de dados.	Busca semântica e sugestões ranqueadas por IA.	Orientação inicial mais rápida.	Ranqueamento opaco ou fontes ausentes.	Documentar consultas e comparar com buscas manuais.	Bolanos et al. (2024); Hunter et al. (2026)
Carga de triagem	Triagem manual de títulos e resumos.	Priorização por IA e aprendizagem ativa.	Redução de carga em revisões estruturadas.	Falsos negativos e falsos positivos.	Adjudicação humana e checagens de recall.	Feng et al. (2022); Canfield et al. (2025); Ruan et al. (2025)
Abrangência	Transparente, mas dependente da qualidade das cadeias de busca.	Pode identificar literatura relacionada e semanticamente semelhante.	Cobertura exploratória mais ampla.	Limites de cobertura da base e de idioma.	Usar múltiplas bases e preservar registros.	Hunter et al. (2026); Moulaison-Sandy et al. (2025)
Precisão e recall	Dependem da habilidade do revisor e do protocolo.	Alto recall é possível em algumas tarefas.	Detecção mais precoce de estudos relevantes.	Especificidade variável.	Validar com amostras e critérios de inclusão.	Ruan et al. (2025); Nykvist et al. (2025); Tahir et al. (2025)
Publicações influentes	Rastreamento de citações e ferramentas bibliométricas.	Redes de citação e sinais de impacto.	Mapeamento mais rápido de trabalhos centrais.	Métricas podem enfatizar trabalhos indexados ou populares.	Combinar métricas com leitura crítica.	Bacalhau et al. (2025); Bolanos et al. (2024)
Temas emergentes	Temas identificados por leitura e codificação.	Agrupamento e detecção de tendências.	Mapa temático preliminar.	Agrupamentos superficiais ou instáveis.	Revisar agrupamentos por meio da leitura.	Bolanos et al. (2024); Moulaison-Sandy et al. (2025)
Transparência	Alta quando as cadeias de busca são relatadas.	Frequentemente limitada por algoritmos proprietários.	Pode documentar resultados e prompts.	Modelos opacos.	Relatar prompts, datas, filtros e versões das ferramentas.	Sebastiao & Dias (2025); Veiga (2025)
Reprodutibilidade	O protocolo pode ser repetido.	Resultados podem mudar entre versões.	Exportações reutilizáveis podem apoiar o rastreamento.	Deriva de versão.	Arquivar resultados e registros bibliográficos.	Sebastiao & Dias (2025); Van Dijk et al. (2023)
Risco de viés	Viés humano, linguístico e de publicação.	Viés de dados de treinamento, anotação e ranqueamento.	Pode expor literatura adicional, mas também amplificar vieses.	Viés algorítmico e linguístico.	Realizar interpretação atenta a vieses.	Gautam & Srinath (2024); Bacalhau et al. (2025); Samala & Rawas (2025)
Papel da expertise humana	Central em todas as etapas.	Ainda central para validação e interpretação.	O esforço do pesquisador desloca-se para o julgamento.	Dependência excessiva de resumos.	Ler artigos originais e avaliar qualidade.	Jalui et al. (2026); Van Dijk et al. (2023); Malik & Terzidis (2025)
Qualidade da síntese	Construída por análise crítica.	Pode apoiar síntese preliminar.	Organização mais rápida de argumentos candidatos.	Pode gerar síntese superficial.	Usar resumos de IA apenas como rascunhos.	Chan (2025); Biju et al. (2025); Amini et al. (2026)

Fonte: Elaborado pelos autores com base na literatura revisada.

3.6.2. Bases acadêmicas com IA podem alterar a ordem em que os pesquisadores encontram a literatura

Em vez de receber primeiro uma lista plana de resultados ordenados por data, contagem de citações ou relevância por palavra-chave, os pesquisadores podem receber registros semanticamente relacionados, resumos gerados por IA, sugestões de tópicos, conceitos relacionados, links de citação e agrupamentos candidatos. A literatura sobre IA em revisões indica que essas funções podem apoiar busca, mapeamento e orientação inicial, mas devem ser tratadas como apoio ao trabalho do pesquisador, e não como síntese automática (Bolanos et al., 2024). Estudos metodológicos também sugerem que a busca assistida por IA pode favorecer uma exploração mais conceitual da literatura, desde que o julgamento especializado permaneça ativo (Hunter et al., 2026). Isso não significa que a revisão esteja completa. Significa que o trabalho cognitivo inicial de orientação pode ser parcialmente apoiado por estruturas geradas pelo sistema que, em seguida, precisam ser validadas (Moulaison-Sandy et al., 2025).

3.6.3. A base de evidências é desigual

A redução de carga de trabalho e o apoio à triagem são mais fortemente documentados do que a síntese temática ou a interpretação conceitual. Estudos sobre triagem automatizada e aprendizagem ativa fornecem evidências relativamente concretas sobre priorização, recall e carga de trabalho em revisões estruturadas (Feng et al., 2022; Ruan et al., 2025; Nykvist et al., 2025). Em contraste, afirmações de que a IA melhora a síntese conceitual, a interpretação interdisciplinar ou a identificação de lacunas de conhecimento dependem mais fortemente de raciocínio metodológico, estudos de caso e avaliações específicas de ferramentas (Bolanos et al., 2024; Hunter et al., 2026; Moulaison-Sandy et al., 2025). O artigo, portanto, trata as afirmações sobre triagem e descoberta como mais fortes do que as afirmações sobre qualidade da síntese final.

3.6.4. Status dos resumos gerados por IA

Resumos podem ser úteis para orientação, mas não devem ser usados como substitutos da leitura. Na escrita de revisões de literatura, o risco é que o pesquisador cite uma fonte com base em um resumo gerado por IA que simplifica, representa incorretamente ou generaliza excessivamente o artigo. A literatura sobre IA em revisões indica que ferramentas de sumarização podem apoiar a organização preliminar da literatura, mas seus resultados devem ser verificados nos textos originais (Bolanos et al., 2024). A literatura revisada sobre ética e transparência sugere que o uso responsável exige verificação das fontes, declaração da assistência de IA e distinção cuidadosa entre o que o artigo afirma e o que a ferramenta de IA infere (Hayashi, 2025; Veiga, 2025; Amini et al., 2026).

3.6.5. A comparação entre métodos tradicionais e assistidos por IA não deve ser formulada como oposição binária

Os métodos tradicionais não estão obsoletos, e as ferramentas assistidas por IA não são automaticamente superiores. A comparação mais produtiva é procedimental: métodos tradicionais são mais fortes em rastreabilidade explícita e controle do pesquisador, enquanto métodos assistidos por IA podem ser mais fortes em orientação inicial e redução de carga de trabalho. A literatura metodológica sustenta que a IA em revisões sistemáticas é promissora quando usada de modo apropriado, mas não como substituta da expertise do pesquisador (Van Dijk et al., 2023). Uma revisão de literatura rigorosa pode combinar ambos, usando IA para exploração e métodos tradicionais para verificação, reprodutibilidade e relato, em linha com propostas de fluxos híbridos de revisão (Malik & Terzidis, 2025; Biju et al., 2025).

3.6.6. Extração de dados e síntese preliminar

A literatura disponível sugere que ferramentas assistidas por IA podem apoiar a extração ou organização de informações dos estudos, mas essa evidência é menos robusta do que a evidência sobre triagem de títulos e resumos (Cassell et al., 2025; Bolanos et al., 2024). A extração exige interpretação de construtos, medidas, contextos e detalhes metodológicos, o que torna necessária a validação humana dos resultados produzidos por ferramentas automatizadas (Van Dijk et al., 2023; Malik & Terzidis, 2025). Para pesquisas em Administração, nas quais conceitos como inovação, capacidade, governança, aprendizagem e desempenho podem variar substancialmente entre tradições teóricas, a

extração automatizada deve ser tratada como uma camada preliminar que requer verificação conceitual pelo pesquisador (Chan, 2025; Tomczyk et al., 2026).

3.6.7. Reprodutibilidade

Revisões tradicionais de literatura podem ser reproduzidas quando bases de dados, cadeias de busca, filtros, datas e decisões de triagem são relatados. A descoberta assistida por IA acrescenta novos elementos que precisam ser documentados: prompts, nomes de ferramentas, datas de saída, registros exportados, resumos, critérios de ranqueamento quando disponíveis e procedimentos de validação. A literatura sobre transparência em IA destaca que a opacidade de sistemas algorítmicos pode dificultar a compreensão e a repetição dos processos que geram resultados (Sebastiao & Dias, 2025). Sem documentação desses elementos, o mesmo pesquisador ou outro pesquisador pode não conseguir reconstruir como um conjunto de referências ou temas foi gerado. Isso torna a documentação uma condição central para a revisão assistida por IA de forma responsável (Veiga, 2025; Amini et al., 2026).

4. Discussão

4.1. Começar mais adiante não significa pular o método

Os resultados deste artigo indicam que bases acadêmicas com IA podem deslocar o ponto inicial da revisão de literatura, oferecendo ao pesquisador uma organização preliminar de temas, referências e relações conceituais. No entanto, esse deslocamento não deve ser interpretado como uma autorização para reduzir o rigor metodológico. Ao contrário, quanto mais estruturado e persuasivo for o resultado produzido pela ferramenta, maior deve ser o cuidado do pesquisador em verificar como esse resultado foi produzido, quais fontes foram incluídas e quais possíveis lacunas permaneceram invisíveis. Assim, o "ponto de partida mais avançado" não elimina etapas como formulação da pergunta de pesquisa, definição de critérios de inclusão e exclusão, leitura dos textos originais e avaliação da qualidade das evidências.

Essa interpretação está alinhada à literatura que trata a IA como apoio ao processo de revisão, e não como substituto da interpretação acadêmica. Bolanos et al. (2024) mostram que ferramentas de IA podem apoiar busca, triagem e sumarização, mas ressaltam que esses recursos dependem de validação humana para produzir conhecimento confiável. Da mesma forma, a discussão sobre transparência indica que processos mediados por IA podem ser difíceis de inspecionar e reproduzir quando prompts, critérios de busca, versões das ferramentas e resultados gerados não são documentados (Sebastiao & Dias, 2025). Portanto, começar de um ponto mais estruturado significa ampliar a capacidade inicial de orientação do pesquisador, mas não reduzir sua responsabilidade metodológica.

4.2. Eficiência não equivale a rigor

A análise dos resultados também sugere que a principal contribuição empírica das ferramentas de IA está relacionada à eficiência, especialmente na redução da carga de triagem e na priorização de registros. Estudos de triagem automatizada indicam que ferramentas baseadas em IA podem reduzir o esforço manual em contextos específicos de revisão (Feng et al., 2022). Contudo, essa eficiência deve ser interpretada com cautela. A redução de tempo ou de carga operacional não garante, por si só, melhor qualidade acadêmica. Uma revisão pode ser mais rápida e, ainda assim, metodologicamente frágil se os resultados automatizados não forem verificados, documentados e interpretados criticamente.

A literatura reforça essa distinção entre desempenho operacional e rigor científico. Avaliações de ferramentas de triagem automática mostram que recall, especificidade, falsos positivos e falsos negativos variam conforme a ferramenta, o tema e o desenho da revisão (Ruan et al., 2025). Evidências comparativas em contextos clínicos também indicam que o desempenho da IA precisa ser avaliado em relação ao julgamento humano ou especializado, e não presumido como superior (Tahir et al., 2025). Assim, a eficiência oferecida por bases acadêmicas com IA deve ser entendida como uma condição que pode liberar tempo para leitura crítica, comparação teórica e síntese interpretativa, e não como evidência automática de rigor.

4.3. A mudança no papel do pesquisador

Os achados apontam para uma mudança importante no papel do pesquisador. Nos métodos tradicionais, grande parte do esforço inicial é dedicada à busca, filtragem e organização manual das referências. Com bases acadêmicas assistidas por IA, parte desse esforço pode ser deslocada para a avaliação crítica dos resultados produzidos pela ferramenta. O pesquisador deixa de atuar apenas como buscador manual e passa a exercer com mais intensidade o papel de curador, validador, intérprete e tomador de decisões metodológicas.

Essa mudança exige novas competências. A literatura sobre literacia crítica em IA argumenta que pesquisadores precisam compreender como resultados assistidos por IA são produzidos, quais pressupostos podem estar incorporados às ferramentas e como esses resultados devem ser avaliados antes de serem incorporados à revisão (Jalui et al., 2026). No campo da Administração, essa exigência é especialmente relevante porque a síntese do conhecimento envolve não apenas reunir fontes, mas construir relações entre conceitos, teorias, métodos e contextos organizacionais. Chan (2025) mostra que a síntese do conhecimento assistida por IA requer atenção à forma como pesquisadores constroem, avaliam e comunicam conhecimento, e não apenas à velocidade com que localizam referências. Dessa forma, a IA não diminui a importância do pesquisador; ela torna mais visível sua responsabilidade interpretativa.

4.4. Colaboração humano-IA como condição metodológica

A discussão dos resultados sugere que o uso mais adequado de bases acadêmicas com IA ocorre em fluxos híbridos de trabalho. Nesses fluxos, a IA contribui para descoberta, triagem, mapeamento e organização preliminar da literatura, enquanto o pesquisador permanece responsável por validar fontes, interpretar achados, avaliar qualidade metodológica e construir a síntese final. Essa abordagem evita tanto a rejeição completa das ferramentas quanto sua adoção acrítica.

A literatura sustenta essa posição. Van Dijk et al. (2023) argumentam que a IA em revisões sistemáticas é promissora quando usada adequadamente, mas não quando tratada como substituta da expertise em revisão. Avaliações do uso de GPT-4 como revisor adicional mostram que grandes modelos de linguagem podem contribuir para processos de revisão, mas continuam dependentes de implementação cuidadosa e avaliação por pesquisadores humanos (Landschaft et al., 2024). De modo semelhante, modelos de revisão híbrida atribuem ao pesquisador a responsabilidade por decisões de inclusão, interpretação, precisão das citações e construção do argumento final (Malik & Terzidis, 2025). Avaliações baseadas em rubricas também indicam que cadeias de ferramentas de IA devem ser avaliadas por critérios explícitos, e não adotadas como soluções de caixa-preta (Biju et al., 2025). Portanto, a colaboração humano-IA deve ser compreendida como uma condição metodológica para o uso responsável dessas bases.

4.5. Implicações para pesquisas em Administração

No campo da Administração, as implicações são particularmente relevantes porque as revisões de literatura frequentemente atravessam diferentes tradições teóricas, níveis de análise e áreas temáticas, como estratégia, inovação, marketing, gestão pública, aprendizagem e transformação digital. Essa pluralidade conceitual torna as bases acadêmicas com IA úteis para orientação inicial, identificação de conexões e organização preliminar do campo. No entanto, também aumenta o risco de interpretações superficiais, especialmente quando conceitos próximos são tratados como equivalentes ou quando resumos automatizados ocultam diferenças teóricas importantes.

A literatura de negócios e gestão sugere que a IA começa a transformar práticas de revisão sistemática da literatura, sobretudo ao modificar os modos de descoberta e organização de fontes (Tomczyk et al., 2026). Entretanto, evidências bibliométricas sobre viés de IA em marketing indicam que o mapeamento do campo também pode reproduzir ou amplificar vieses presentes nos dados, nos critérios de indexação e nas formas de visibilidade acadêmica (Bacalhau et al., 2025). Isso é importante para a Administração porque o campo depende fortemente de interpretação contextual e articulação conceitual. Trabalhos sobre uso ético de IA na escrita acadêmica reforçam que estudantes e pesquisadores precisam ser formados para documentar, verificar e declarar o uso dessas ferramentas (Amini et al., 2026). Assim, a contribuição das bases acadêmicas com IA para a Administração não

está apenas na produtividade, mas também na necessidade de desenvolver literacia metodológica e digital.

4.6. Diretrizes práticas para uso responsável

A partir da discussão dos resultados, as diretrizes práticas não devem ser entendidas como uma lista operacional isolada, mas como desdobramentos metodológicos da própria análise. A primeira implicação é que o pesquisador deve definir a pergunta de pesquisa antes de utilizar ferramentas com IA. Isso impede que a revisão seja conduzida por categorias sugeridas pela ferramenta, em vez de ser orientada pelo problema científico. A segunda implicação é que bases acadêmicas com IA devem ser usadas como apoio exploratório, e não como única estratégia de busca. A literatura ética sobre comunicação científica sustenta que a influência da IA no trabalho acadêmico precisa ser declarada e assumida com responsabilidade pelo autor (Hayashi, 2025).

Além disso, o pesquisador pode se beneficiar em documentar bases utilizadas, prompts, consultas, filtros, datas, cadeias de busca, exportações e procedimentos de validação. Essa documentação é importante porque a publicação acadêmica assistida por IA exige transparência sobre o papel da ferramenta na produção do conhecimento (Veiga, 2025). Também é necessário verificar todas as referências sugeridas por IA, ler os artigos originais antes de formular afirmações, comparar resultados assistidos por IA com buscas manuais e discutir limitações relacionadas à transparência, ao viés e à reprodutibilidade. Quadros éticos para escrita acadêmica enfatizam justamente a verificação das fontes e a responsabilidade humana sobre o conteúdo final (Amini et al., 2026). Dessa forma, o uso responsável de bases acadêmicas com IA depende menos da adoção da ferramenta em si e mais da capacidade do pesquisador de integrá-la a um processo metodológico transparente, verificável e criticamente orientado.

4.7. Quadro conceitual

O quadro proposto neste artigo contrasta dois percursos. O percurso tradicional vai da busca manual à triagem manual, à organização manual e à compreensão preliminar gradual. O percurso assistido por IA começa O quadro proposto neste artigo contrasta dois percursos. O percurso tradicional vai da busca manual à triagem manual, à organização manual e à compreensão preliminar gradual, processo que permanece importante por sua transparência e controle metodológico quando as estratégias de busca e seleção são bem documentadas (Van Dijk et al., 2023).

Figura 1 - Comparação dos percursos

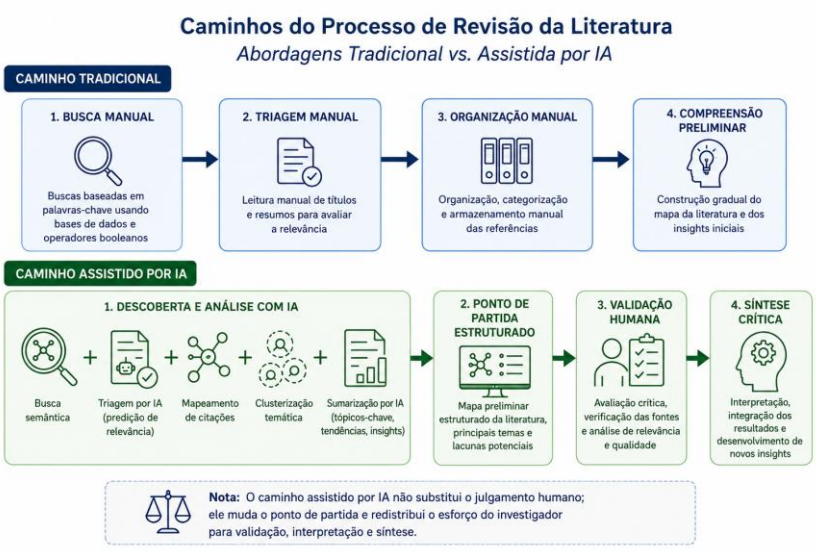

Fonte: Autores

O percurso assistido por IA começa com busca semântica, triagem por IA, mapeamento de citações, agrupamento e sumarização, produzindo um ponto de partida estruturado que deve, em seguida, passar por validação humana antes da síntese crítica (Bolanos et al., 2024; Hunter et al., 2026). A

contribuição da IA, portanto, não é a eliminação do método, mas a redistribuição do esforço do pesquisador para validação, interpretação e síntese, como sugerem abordagens híbridas de revisão assistida por IA (Malik & Terzidis, 2025).com busca semântica, triagem por IA, mapeamento de citações, agrupamento e sumarização, produzindo um ponto de partida estruturado que deve, em seguida, passar por validação humana antes da síntese crítica. A contribuição da IA, portanto, não é a eliminação do método, mas a redistribuição do esforço do pesquisador para validação, interpretação e síntese.

A noção de começar de um ponto mais avançado deve, portanto, ser compreendida com cuidado. Isso não significa que pesquisadores possam pular decisões metodológicas fundamentais. Significa, antes, que bases acadêmicas com IA podem fornecer uma organização inicial da literatura que anteriormente precisava ser construída manualmente, especialmente por meio de busca semântica, mapeamento e apoio à triagem (Bolanos et al., 2024; Hunter et al., 2026). Essa organização preliminar pode ajudar pesquisadores a identificar mais cedo possíveis agrupamentos, trabalhos influentes e debates adjacentes, mas evidências em tópicos complexos das ciências sociais mostram que esses resultados variam entre ferramentas e exigem interpretação crítica (Moulaison-Sandy et al., 2025). No entanto, o valor epistêmico dessa organização depende de os pesquisadores a interrogarem, em vez de simplesmente adotá-la.

Para a escrita em congressos e periódicos, essa distinção tem consequências práticas. Um manuscrito não deve afirmar que a IA tornou a revisão de literatura rigorosa. Deve afirmar como a IA foi usada, quais bases de dados ou ferramentas foram consultadas, quais resultados foram retidos, como as referências foram verificadas e como a busca tradicional ou a triagem manual complementou a descoberta assistida por IA. Esse nível de documentação é necessário porque processos de busca mediados por IA podem não ser reprodutíveis a menos que o pesquisador registre prompts, datas, filtros, exportações e etapas de validação, uma exigência coerente com a literatura sobre transparência e responsabilidade no uso de IA em pesquisa (Sebastiao & Dias, 2025; Veiga, 2025).

A discussão também indica que a literacia em IA deve fazer parte da formação em métodos de pesquisa em Administração. Estudantes devem aprender não apenas a usar ferramentas de IA, mas também a questionar seus resultados. Isso inclui verificar se as referências sugeridas existem, se o artigo citado de fato sustenta a afirmação, se a ferramenta privilegia fontes indexadas em língua inglesa e se os resumos ocultam desacordos teóricos. Essa necessidade está alinhada à literatura sobre literacia crítica em IA, que destaca a importância de compreender como os resultados assistidos por IA são produzidos e como devem ser avaliados antes de serem incorporados à revisão (Jalui et al., 2026). Nesse sentido, a literacia em IA é inseparável da literacia metodológica.

O quadro proposto também ajuda a esclarecer a relação entre eficiência e análise crítica. Se a IA reduz o tempo gasto em triagens repetitivas, o tempo economizado deve ser redirecionado para leitura mais aprofundada, comparação de pressupostos teóricos, avaliação de qualidade e síntese. A literatura sobre triagem automatizada sugere que a IA pode reduzir carga de trabalho em contextos específicos de revisão, mas esse ganho operacional não elimina a necessidade de validação humana (Feng et al., 2022; Ruan et al., 2025). Se o tempo economizado for usado apenas para acelerar a escrita sem verificação, o resultado pode ser uma produção mais rápida, porém academicamente mais frágil. O benefício metodológico das bases assistidas por IA depende, portanto, de como o pesquisador redistribui o esforço.

Em termos práticos, o fluxo híbrido de trabalho proposto aqui pode ser resumido em exploração, verificação e síntese. Na fase de exploração, bases acadêmicas com IA apoiam busca semântica, agrupamento e identificação de literatura relacionada (Bolanos et al., 2024; Hunter et al., 2026). Na fase de verificação, o pesquisador confere referências, lê artigos originais, aplica critérios de inclusão, compara resultados com buscas tradicionais e documenta decisões, procedimento coerente com recomendações de uso apropriado da IA em revisões sistemáticas (Van Dijk et al., 2023). Na fase de síntese, o pesquisador desenvolve o argumento conceitual, avalia limitações e conecta cada afirmação a evidências específicas. Somente a combinação dessas fases sustenta a afirmação defensável de que a IA ajudou o pesquisador a começar de um ponto mais avançado, como sugerem modelos híbridos de revisão assistida por IA (Malik & Terzidis, 2025; Biju et al., 2025).

Esse quadro também sugere uma forma diferente de avaliar bases acadêmicas com IA. Em vez de perguntar apenas se as ferramentas de IA são mais rápidas que a busca manual, os pesquisadores devem perguntar que tipo de trabalho metodológico está sendo acelerado, que tipo de julgamento acadêmico continua necessário e quais riscos são introduzidos pela ferramenta. Uma busca mais rápida é útil quando amplia a consciência do pesquisador sobre o campo, mas é problemática se estreita a atenção para fontes altamente visíveis ou incentiva citações superficiais. A avaliação do trabalho de revisão assistido por IA deve, portanto, incluir indicadores operacionais, como carga de trabalho e tempo, e indicadores epistêmicos, como relevância, transparência, adequação conceitual e qualidade da síntese (Ruan et al., 2025; Sebastiao & Dias, 2025).

O argumento também tem implicações para o modo como autores devem relatar o uso de IA em artigos de congresso. A seção de metodologia deve especificar se a IA foi utilizada para descoberta, triagem, sumarização, tradução, codificação ou auxílio à escrita. Também deve esclarecer quais resultados foram aceitos, rejeitados ou revisados manualmente. Essa prática de relato protege o leitor e o autor: torna o processo mais transparente, ajuda avaliadores a julgar o rigor metodológico e evita apresentar a descoberta mediada por IA como se fosse uma busca manual convencional. Nesse sentido, a declaração de uso de IA não é apenas uma formalidade ética; ela faz parte do método, pois a literatura sobre ética em comunicação científica enfatiza divulgação, responsabilidade e verificação das fontes no uso de IA (Hayashi, 2025; Veiga, 2025; Amini et al., 2026).

5. Conclusão

Este artigo examinou como bases acadêmicas com inteligência artificial podem permitir que pesquisadores iniciem o trabalho científico em uma etapa mais avançada do processo de revisão de literatura, em comparação com métodos tradicionais de busca, triagem e organização manual. A resposta à pergunta de pesquisa é condicional: essas ferramentas podem reconfigurar o ponto de partida da revisão ao transformar um conjunto inicial pouco estruturado de resultados em um mapa preliminar de temas, relações, referências e possíveis lacunas. Esse avanço, contudo, não resulta da substituição do pesquisador, mas da combinação entre recursos de descoberta assistida por IA, validação humana e controle metodológico.

A literatura analisada indica que a evidência é mais consistente para a redução da carga de trabalho na triagem, a priorização de registros e o apoio à organização inicial em contextos de revisões estruturadas. Em contrapartida, afirmações sobre abrangência, mapeamento interdisciplinar, extração de dados e qualidade da síntese exigem maior cautela, pois dependem do desenho da ferramenta, da cobertura das bases, da qualidade dos metadados, da transparência dos sistemas e da capacidade interpretativa do pesquisador. Assim, bases acadêmicas com IA devem ser compreendidas como apoios metodológicos auditáveis, e não como substitutas do julgamento científico.

A principal contribuição do artigo está em propor que o valor dessas bases não reside apenas na aceleração da busca, mas na reconfiguração das etapas iniciais da revisão de literatura. Ao oferecer busca semântica, sugestões de relevância, agrupamentos temáticos, mapeamento de citações e sínteses preliminares, essas ferramentas podem reduzir parte do esforço dedicado à recuperação e organização manual de referências. O benefício metodológico, entretanto, depende de que esse esforço seja redirecionado para leitura dos textos originais, avaliação crítica, comparação teórica, verificação das fontes e construção de uma síntese conceitual rigorosa.

Para a pesquisa em Administração, essa discussão é particularmente relevante porque o campo frequentemente lida com literaturas amplas, interdisciplinares e conceitualmente heterogêneas. Bases acadêmicas com IA podem apoiar estudantes, docentes e pesquisadores na orientação inicial em grandes corpos de literatura, mas seu uso requer literacia digital, literacia em IA e formação metodológica. Por essa razão, a utilização dessas ferramentas deve ser documentada nos procedimentos metodológicos, incluindo bases consultadas, prompts, filtros, datas, registros exportados, critérios de validação e limitações identificadas.

Pesquisas futuras podem comparar empiricamente fluxos de revisão de literatura baseados em métodos tradicionais, bases acadêmicas com IA e abordagens híbridas. Esses estudos devem considerar indicadores como tempo, recall, precisão, qualidade da síntese, transparência da documentação e

aprendizagem do usuário. Investigações em português, espanhol e outros contextos não anglófonos também são importantes, uma vez que a cobertura das bases de dados e o viés linguístico podem influenciar o que os sistemas de IA recuperam, organizam e resumem. A pesquisa em Administração pode contribuir para esse debate ao examinar como práticas de revisão assistidas por IA afetam teses, dissertações, formação em métodos de pesquisa e produção de artigos científicos.

6. Referências

Abogunrin, S., Muir, J. M., Zerbini, C., & Sarri, G. (2025). How much can we save by applying artificial intelligence in evidence synthesis? Results from a pragmatic review to quantify workload efficiencies and cost savings. https://doi.org/10.3389/fphar.2025.1454245

Amini, M., Lee, K.-F., Yiqiu, W., & Ravindran, L. (2026). Proposing a framework for ethical use of AI in academic writing based on a conceptual review: Implications for quality education. https://doi.org/10.1080/10494820.2025.2523382

Bacalhau, L. M., Pereira, M. C., & Neves, J. (2025). A bibliometric analysis of AI bias in marketing: Field evolution and future research agenda. https://doi.org/10.1057/s41270-025-00379-6

Biju, N., Sinha, A., Saini, S., & Das, S. (2025). Evaluating AI toolchains for systematic literature reviews using a rubric-based workflow approach. https://doi.org/10.1007/s44163-025-00628-8

Bolanos, F., Salatino, A., Osborne, F., & Motta, E. (2024). Artificial intelligence for literature reviews: Opportunities and challenges. https://doi.org/10.1007/s10462-024-10902-3

Canfield, S. E., Aziz, M. K., Omar, M. I., & Stenzl, A. (2025). Using artificial intelligence for text screening in a systematic review of cardiotoxicity. https://doi.org/10.1016/j.euros.2025.09.005

Chan, Y. (2025). Advancing knowledge synthesis in management learning: Literature review assisted by artificial intelligence. https://doi.org/10.1177/13505076251377550

Feng, Y., Liang, S., Zhang, Y., Chen, S., Wang, Q., Huang, T., Sun, F., Liu, X., Zhu, H., & Pan, H. (2022). Automated medical literature screening using artificial intelligence: A systematic review and meta-analysis. https://doi.org/10.1093/jamia/ocac066

Gautam, S., & Srinath, M. (2024). Blind spots and biases: Exploring the role of annotator cognitive biases in NLP. https://doi.org/10.18653/v1/2024.hcinlp-1.8

Hayashi, M. C. P. I. (2025). Ethics and artificial intelligence in scientific communication: Challenges for scientific journals. https://doi.org/10.5007/1518-2924.2025.e103497

Hunter, R., Booth, A., & Wood, L. (2026). Searching smarter, not harder: Leveraging AI to enhance literature searches for theory-driven reviews: A methodological case study. https://doi.org/10.21203/rs.3.rs-7924327/v1

Jalui, D., Tate, M., & Cranefield, J. (2026). Beyond the loop: A research agenda towards a framework for critical AI literacy in the AI-assisted literature review. https://doi.org/10.47989/ir31iconf64166

Landschaft, A., Antweiler, D., Mackay, S., & Allende-Cid, H. (2024). Implementation and evaluation of an additional GPT-4-based reviewer in PRISMA-based medical systematic literature reviews. https://doi.org/10.1016/j.ijmedinf.2024.105531

Malik, F. S., & Terzidis, O. (2025). A hybrid framework for creating artificial intelligence-augmented systematic literature reviews. https://doi.org/10.1007/s11301-025-00522-8

Moulaison-Sandy, H., Castano-Munoz, W., Ridenour, L., & Adkins, D. (2025). AI literature review systems: An analysis of performance, affordances, and outputs for a complex topic in the social sciences. https://doi.org/10.47989/ir30iconf46906

Nykvist, B., Macura, B., Xylia, M., & Olsson, E. (2025). Testing the utility of GPT for title and abstract screening in environmental systematic evidence synthesis. https://doi.org/10.1186/s13750-025-00360-x

Ruan, M., Fan, J., Liu, M., & Zhang, C. (2025). Artificial intelligence for the science of evidence synthesis: How good are AI-powered tools for automatic literature screening? https://doi.org/10.1186/s12874-025-02644-9

Samala, A. D., & Rawas, S. (2025). Bias in artificial intelligence: Smart solutions for detection, mitigation, and ethical strategies in real-world applications. https://doi.org/10.11591/ijai.v14.i1.pp32-43

Sebastiao, S. P., & Dias, D. F.-M. (2025). AI transparency: A conceptual, normative, and practical frame analysis. https://doi.org/10.17645/mac.9419

Tahir, H. N., Ullah, N., Tahir, M., & Ali, Y. (2025). Artificial intelligence versus manual screening for the detection of diabetic retinopathy: A comparative systematic review and meta-analysis. https://doi.org/10.3389/fmed.2025.1519768

Tomczyk, P., Bruggemann, P., & Vrontis, D. (2026). AI meets academia: Transforming systematic literature reviews. https://doi.org/10.1108/EMJB-03-2024-0055

Van Dijk, S. H. B., Brusse-Keizer, M. G. J., Bucsán, C. C., & Lenferink, A. (2023). Artificial intelligence in systematic reviews: Promising when appropriately used. https://doi.org/10.1136/bmjopen-2023-072254

Veiga, A. D. (2025). Ethical guidelines for the use of generative artificial intelligence and artificial intelligence-assisted tools in scholarly publishing: A thematic analysis. https://doi.org/10.6087/kcse.352