

**LIMITAÇÕES, FIABILIDADE
E CONFIANÇA NA
INTELIGÊNCIA ARTIFICIAL
GENERATIVA NO
TRABALHO DE
CONHECIMENTO APLICADO
AO LICENCIAMENTO
AMBIENTAL: UMA REVISÃO
CRÍTICA DA LITERATURA**

**LIMITATIONS, RELIABILITY AND TRUST IN GENERATIVE ARTIFICIAL
INTELLIGENCE IN KNOWLEDGE WORK APPLIED TO ENVIRONMENTAL
LICENSING: A CRITICAL LITERATURE REVIEW**

Engenharias • 20/10/2026

REGISTRO DOI: [10.70773/revistatopicos/792376643](https://doi.org/10.70773/revistatopicos/792376643)

Ana Paula Coelho Clauberg¹

Felipe Cavaleiro Carneiro²

Valter Antonio Becegato³

Marcelle Coelho Clauberg

RESUMO

A difusão de modelos de linguagem de grande escala (LLMs) tem alcançado o licenciamento ambiental e a avaliação de impacto ambiental (AIA), prometendo ganhos de produtividade em tarefas de leitura, síntese e redação. Esta revisão crítica analisa limitações, fiabilidade e confiança no uso de inteligência artificial generativa (IAG) no trabalho de conhecimento, com aplicação explícita ao licenciamento. Articulam-se o conceito de fronteira tecnológica irregular, o fenómeno *Lost in the Middle* em documentos longos, o viés de automação e a armadilha da confiança, a taxonomia de alucinações intrínsecas e extrínsecas e a literatura específica de inteligência artificial (IA) em AIA. Conclui-se que os ganhos são condicionais à natureza da tarefa e que a responsabilidade decisória deve permanecer humana, com protocolos de *disclosure*, auditoria e alinhamento ao princípio da precaução.

Palavras-chave: inteligência artificial generativa, *large language models*; licenciamento ambiental; avaliação de impacto ambiental.

ABSTRACT

The spread of large language models (LLMs) has reached environmental licensing and environmental impact assessment (EIA), promising productivity gains in reading, synthesis and drafting tasks. This critical review examines limitations, reliability and trust in generative artificial intelligence (GenAI) for knowledge work, with explicit application to licensing. It articulates the jagged technological frontier, the *Lost in the Middle* phenomenon in long documents, automation bias and the trust trap, the taxonomy of intrinsic and extrinsic hallucinations, and EIA-specific artificial intelligence (AI) literature. It concludes that benefits depend on task type and that decision responsibility must remain human, with disclosure, audit and alignment with the precautionary principle.

Keywords: generative artificial intelligence; large language models; environmental licensing; environmental impact assessment.

1. INTRODUÇÃO

A difusão acelerada de sistemas de inteligência artificial (IA) generativa (IAG), em especial os *large language models* (LLMs), a exemplo do ChatGPT e de modelos correlatos, tem reconfigurado práticas de trabalho em domínios que dependem intensivamente de leitura, escrita, síntese e julgamento técnico. No campo ambiental, essa reconfiguração alcança etapas do licenciamento, da avaliação de impacto ambiental e estudo de impacto ambiental (AIA/EIA), inclusive a triagem (*screening*), a revisão de literatura e de documentos, a redação de sumários, a organização de *baselines* e, de forma ainda experimental, o apoio a decisões (Bond; Dusík, 2025; Cilliers *et al.*, 2025; Forghaniallahabadi, 2025; Hung; Kumar; Fischer, 2026). A própria produção científica sobre inteligência artificial e avaliação de impacto ambiental expandiu-se de forma expressiva a partir de 2023–2024, coincidindo com a popularização dos LLMs de uso geral, conforme o estado da arte sistematizado por Bond e Dusík (2025).

O problema que motiva esta revisão não é a inexistência de ganhos potenciais de produtividade, mas a assimetria entre a facilidade de uso dessas ferramentas e suas vulnerabilidades estruturais. Interfaces conversacionais e textos fluentes reduzem barreiras de entrada e, ao mesmo tempo, mascaram limites de recuperação de informação em documentos longos (Liu *et al.*, 2024), propensão a alucinações em geração de linguagem natural (Ji *et al.*, 2023), vieses de automação sob carga cognitiva elevada (Lyell; Coiera, 2017; Bittencourt, 2025) e desempenho irregular conforme a natureza da

tarefa (Dell'Acqua *et al.*, 2026). Em ambientes regulatórios, erros de omissão, invenção de fundamentação ou leitura parcial de processos podem afetar a legitimidade de decisões e a proteção ambiental, o que confere à assimetria contornos de risco institucional (Isep, 2025; Bingham *et al.*, 2025; Salib; Garcia, 2021; Fast; Fitzpatrick; Dilay, 2025).

No Brasil, o licenciamento ambiental articula bases normativas da Política Nacional do Meio Ambiente, competências federativas e uma cultura decisória em que a incerteza científica e o princípio da precaução ocupam lugar central (Salib; Garcia, 2021). A introdução de IA generativa nesses fluxos ocorre, com frequência, de maneira *ad hoc*, sem protocolos consolidados de *disclosure*, auditoria e competência específica, ainda que documentos internacionais de boas práticas já apontem *guardrails* mínimos (Isep, 2025). No plano nacional, Fertig, Fertig e Souza (2018) apresentaram análise preliminar do uso de IA no auxílio a processos de licenciamento; mais recentemente, Da Silva *et al.* (2025) discutem a IA como mediadora em “ecologias de decisão” no planejamento urbano e no licenciamento, e Hermann (2025) e Zuin e Goergen (2025) levantam inquietações éticas sobre opacidade e formação.

O objetivo deste artigo é realizar uma revisão crítica da literatura sobre limitações, fiabilidade e confiança no uso de IA generativa no trabalho de conhecimento, com aplicação explícita ao licenciamento ambiental e à AIA, fundamentada em dezoito trabalhos consultados, entre eles artigos científicos, revisões e orientações profissionais.

Busca-se: (i) articular evidências gerais sobre desempenho de LLMs e vieses humanos de uso; (ii) integrar a literatura específica de IA em impacto ambiental e licenciamento; e (iii) derivar diretrizes de uso crítico e responsável, com atenção ao contexto brasileiro. A

relevância reside em oferecer um quadro conceitual e normativo para a pesquisa e a prática, evitando tanto o determinismo tecnológico quanto a rejeição simplista de ferramentas que, sob supervisão adequada, podem apoiar etapas específicas do processo.

A revisão organiza-se da seguinte forma: na seção 2, discutem-se a fronteira tecnológica irregular e o desempenho da IA no trabalho de conhecimento, com base em Dell’Acqua *et al.* (2026); na seção 3, analisa-se o fenômeno *Lost in the Middle* (Liu *et al.*, 2024); na seção 4, são abordados os conceitos de *automation bias* e de armadilha da confiança (Lyell; Coiera, 2017; Bittencourt, 2025; Zuin; Goergen, 2025); na seção 5, apresenta-se a taxonomia de alucinações (Ji *et al.*, 2023) e discutem-se seus impactos no licenciamento ambiental; na seção 6, sintetizam-se as evidências da literatura sobre IA aplicada à AIA e ao licenciamento ambiental; na seção 7, são propostas diretrizes práticas para seu uso crítico e responsável; e, na seção 8, apresentam-se as considerações finais e as lacunas de pesquisa.

2. A FRONTEIRA TECNOLÓGICA IRREGULAR E O DESEMPENHO DA IA NO TRABALHO DE CONHECIMENTO

2.1. O Conceito de *Jagged Technological Frontier*

Dell’Acqua *et al.* (2026), no estudo experimental publicado como *Working Paper* da Harvard Business School e subsequentemente na *Organization Science*, introduzem o conceito de fronteira tecnológica irregular (*jagged technological frontier*) para descrever o fato de que as capacidades da IA generativa não se distribuem de modo uniforme ao longo do espectro de tarefas do trabalho de conhecimento. Em vez de um limiar linear, observa-se um contorno irregular: algumas tarefas situam-se dentro da fronteira atual de

competência do modelo, em que o uso da ferramenta tende a melhorar velocidade e qualidade, enquanto outras situam-se fora da fronteira, em que o uso pode degradar o desempenho humano, inclusive de profissionais experientes.

A irregularidade importa metodológica e normativamente. Metodologicamente, impede generalizações a partir de casos de sucesso isolados para o conjunto da prática profissional. Normativamente, impõe o mapeamento prévio de quais etapas de um processo, no caso, o licenciamento ambiental, são candidatas legítimas a apoio por LLM e quais permanecem irredutivelmente humanas ou exigem verificação reforçada, em linha com a *Advice Note* da ISEP (2025) e com os *Principles for Use of AI in IA* da International Association for Impact Assessment (IAIA) (Bingham *et al.*, 2025).

2.2. Evidências Experimentais: Ganhos e Perdas

No experimento de campo com profissionais de consultoria (*Boston Consulting Group*), Dell'Acqua *et al.* (2026) avaliaram o impacto de modelos do tipo GPT-4 sobre produtividade e qualidade em tarefas realistas de trabalho de conhecimento. Os resultados, amplamente discutidos na literatura de impacto ambiental (Bond; Dusík, 2025; Fast; Fitzpatrick; Dilay, 2025), apontam um padrão dual: dentro da fronteira, o uso de IA associou-se a ganhos expressivos de velocidade e a melhorias de qualidade, inclusive com redução de desigualdades de desempenho entre profissionais de níveis distintos. Fora da fronteira, quando a tarefa exigia julgamento complexo, integração contextual ou raciocínio não bem capturado pelos padrões estatísticos do modelo, observou-se queda de desempenho de cerca de 19% em cenários reportados do estudo.

Esses achados demonstram que o mesmo sistema pode amplificar o desempenho em uma tarefa e induzir ao erro em outra. A variável crítica deixa de ser apenas usar ou não usar IA e passa a ser: em que tarefa, com que *prompt*, com que supervisão e com que postura de trabalho (Dell’Acqua *et al.*, 2026; Bond *et al.*, 2024; Cilliers *et al.*, 2025).

Esse padrão dual sugere que a IA generativa funciona, com frequência, como amplificador de rotinas já bem estruturadas e como perturbador de rotinas mal especificadas. Quando a tarefa admite decomposição, critérios relativamente estáveis e verificação barata do resultado, o modelo tende a acelerar o ciclo de produção. Quando a tarefa exige integração de premissas implícitas, conhecimento de contexto local ou arbitragem de valores em conflito, a fluência do *output* pode ocultar a inadequação do raciocínio subjacente. O erro fora da fronteira pode vir como texto plausível e profissionalmente aceitável na aparência, o que eleva o custo de detecção (Ji *et al.*, 2023; Lyell; Coiera, 2017).

Para o licenciamento ambiental, a implicação metodológica é que avaliações de eficácia da IA baseadas apenas em tempo economizado ou em satisfação subjetiva do usuário são insuficientes. Métricas de qualidade devem incluir taxa de omissão de informações materialmente relevantes, taxa de invenção de fundamentos, fidelidade a fontes e estabilidade do resultado sob pequenas variações de *prompt*, dimensões essas ainda pouco padronizadas na prática de órgãos e consultorias (Bond; Dusík, 2025; Hung; Kumar; Fischer, 2026; Isep, 2025).

2.3. Posturas de Trabalho: “Centauro” e “Ciborgue”

A literatura sobre colaboração humano-IA no trabalho de conhecimento, em diálogo com os achados de Dell'Acqua *et al.* (2026), distingue, de modo heurístico, duas posturas de integração: Centauro e Ciborgue. A primeira é entendida como divisão sequencial e deliberada de trabalho entre humano e máquina, na qual o profissional define o problema, seleciona o que delegar, examina o *output* e reassume o julgamento. A IA opera em trechos delimitados (por exemplo, reescrever um parágrafo descritivo, listar seções, gerar rascunho de *checklist*), sob controle humano contínuo. A segunda consiste na integração densa e fluida, em que o processo de pensar e escrever se entrelaça com a ferramenta de forma quase contínua, com *prompts* sucessivos, aceitação rápida de sugestões e *feedback* conversacional que molda o raciocínio em tempo real.

Ambas as posturas podem ser produtivas, desde que empregadas dentro da fronteira. O risco cresce quando a postura de Ciborgue é aplicada fora da fronteira: a fluência do modelo e a sensação de co-construção dificultam a detecção de erros e reforçam a descarga cognitiva (Lyell; Coiera, 2017; Bittencourt, 2025; Zuin; Goergen, 2025). A postura de Centauro, por exigir momentos explícitos de inspeção e reapropriação do resultado, alinha-se melhor aos princípios de *utility not reliance* da ISEP (2025) e de *oversight* profissional da IAIA (Bingham *et al.*, 2025).

Em contextos regulatórios, a integridade do processo depende de preservar pontos de freio humanos, em especial quando a tarefa envolve significância de impactos, incerteza científica e consequências jurídicas (Salib; Garcia, 2021; Bond; Dusík, 2025).

Há, ainda, uma dimensão formativa. A postura Ciborgue, se generalizada em equipes juniores, pode reduzir oportunidades de

desenvolver o senso crítico necessário à auditoria futura, preocupação explicitada pela ISEP (2025) ao alertar contra a substituição precoce de tarefas de início de carreira. A postura de Centauro, ao contrário, pode ser desenhada como pedagogia do ofício, em que o profissional em formação executa trechos com apoio da ferramenta, mas é avaliado pela qualidade da verificação e pela capacidade de justificar o que aceitou ou rejeitou (Hermann, 2025; Isep, 2025).

2.4. Ponte com o Licenciamento Ambiental: Dentro e Fora da Fronteira

Transpondo a fronteira irregular (Dell'Acqua *et al.*, 2026) para o ciclo de licenciamento e AIA, e à luz das evidências e orientações consultadas (Cilliers *et al.*, 2025; Isep, 2025; Bingham *et al.*, 2025; Salib; Garcia, 2021), é possível esboçar, de forma provisória e sujeita a validação empírica local, um mapa de tarefas de dentro e fora da fronteira.

Tarefas com tendência a situar-se dentro da fronteira incluem a organização e formatação de documentos; a elaboração de rascunhos de seções descritivas de empreendimento (com base em dados fornecidos pelo humano); o apoio a sumários não técnicos (NTS), revisões linguísticas e versões multilíngues (Isep, 2025); a busca e triagem inicial de trechos em bases; o apoio a *screening* quando regras textuais e limiares estão bem codificados no *prompt* e há iteração contextual (Cilliers *et al.*, 2025); e a sistematização de *checklists* e matriz de conformidade preliminar (Hung; Kumar; Fischer, 2026).

As tarefas com tendência a situar-se fora da fronteira, e portanto de alto risco, incluem análise de significância de impactos e ponderação de *trade-offs* socioambientais (Bond; Dusík, 2025); aplicação do princípio da precaução e juízos sob incerteza científica (Salib; Garcia, 2021); valoração de impactos cumulativos e sinérgicos em territórios complexos; interpretação de conhecimentos locais, indígenas e tácitos pouco digitalizados (Bingham *et al.*, 2025); decisões de deferimento/indeferimento e condicionantes de mérito; verificação de conformidade legal sem confrontação com fontes oficiais (Ji *et al.*, 2023; Isep, 2025); e inferências causais e prognósticos não lastreados em dados de *baseline* confiáveis (Forghaniallahabadi, 2025).

A mensagem para o licenciamento é clara: produtividade em tarefas periféricas não autoriza automação de juízos nucleares. O erro mais grave não é usar LLM para rascunhar um parágrafo, mas sim tratar o *output* fluente como se fosse parecer técnico ou decisão substantiva (Isep, 2025; Bond; Dusík, 2025; Bingham *et al.*, 2025).

3. O ENVIO DE DOCUMENTOS EXTENSOS E O FENÔMENO *LOST IN THE MIDDLE*

3.1. A Curva em U da Precisão em Contextos Longos e os Riscos Concretos no Licenciamento Ambiental

Liu *et al.* (2024), no artigo *Lost in the Middle: How Language Models Use Long Contexts*, demonstram que modelos de linguagem, mesmo quando anunciados como capazes de processar janelas de contexto longas, exibem desempenho não uniforme na recuperação e uso de informação posicionada em diferentes partes do *input*. O padrão característico é uma curva em U: a precisão tende a ser

maior quando a informação relevante está no início ou no fim do contexto fornecido, e a degradar-se de forma acentuada quando a informação crítica se localiza no meio.

Esse achado contraria a pressuposição de que “inserir o EIA inteiro no *chat*” equivale a assegurar que “o modelo leu e compreendeu o processo”. A revisão de Hung, Kumar e Fischer (2026) sobre o uso de processamento de linguagem natural (NLP) na avaliação de impacto reforça preocupações correlatas quanto à acurácia e ao emprego de *prompts* em aplicações textuais de IA.

Processos de licenciamento e estudos ambientais são, tipicamente, artefatos documentais longos e heterogêneos, como os Estudos Prévios de Impacto Ambiental, acompanhados do respectivo Relatório de Impacto Ambiental (EIA/RIMA), Relatórios de Controle Ambiental (RCA), planos de condicionantes, atas de audiência, ofícios, laudos de monitoramento, anexos cartográficos, planilhas, entre outros (Isep, 2025; Forghaniallahabadi, 2025). Neles, informações decisivas raramente se concentram apenas na introdução ou na conclusão. Condicionantes específicas, exceções legais, resultados de campanhas de monitoramento, ressalvas de incerteza e compromissos de mitigação frequentemente aparecem em seções intermediárias, apêndices ou volumes técnicos. Se um analista ou consultor submete volumes extensos a um LLM e confia no resumo ou na extração gerada, os riscos incluem omissão de condicionantes situadas em posição central do parecer ou da licença; perda de dados de monitoramento que alteram o prognóstico de impacto; desconsideração de exceções, salvaguardas ou condicionantes temporais redigidas em cláusulas intermediárias; sínteses enviesadas que reforçam a narrativa do início/fim do documento em detrimento de achados técnicos centrais; e falsa

sensação de cobertura integral quando a informação crucial pode ter sido subutilizada (Liu *et al.*, 2024; Isep, 2025; Ji *et al.*, 2023).

Esses riscos combinam-se com a fronteira irregular: resumir um trecho bem delimitado pode estar dentro da fronteira, enquanto pretender dominar um EIA de centenas de páginas em um único *prompt* tende a situar-se fora, por limitação estrutural de uso de contexto longo (Liu *et al.*, 2024; Dell’Acqua *et al.*, 2026).

A literatura de NLP e as orientações profissionais consultadas convergem para estratégias de mitigação: dividir documentos em blocos temáticos (*chunking*), com *prompts* específicos por bloco; manter rastreabilidade (qual trecho originou qual afirmação); e exigir verificação humana de pontos regulatórios críticos (Isep, 2025; Bingham *et al.*, 2025; Hung; Kumar; Fischer, 2026). Em outras palavras, o antídoto ao *Lost in the Middle* consiste no desenho de fluxo de trabalho que não dependa de atenção uniforme do LLM sobre artefatos longos (Liu *et al.*, 2024).

O *Lost in the Middle* introduz uma forma particular de assimetria documental: partes do expediente que o sistema negligencia podem ser precisamente aquelas que o empreendedor ou a consultoria teriam menos incentivo a destacar no resumo executivo. Se a autoridade ambiental passar a depender de sínteses geradas por LLM a partir de volumes integrais mal particionados, cria-se um incentivo perverso à estratégia de posicionamento textual, não necessariamente fraudulenta de forma deliberada, mas estruturalmente favorável a quem controla a arquitetura do documento. Por isso, protocolos de uso deveriam exigir não apenas *chunking*, mas também a amostragem adversária, isto é, a verificação deliberada de seções intermediárias e anexos,

independentemente do resumo automático (Liu *et al.*, 2024; Bingham *et al.*, 2025; Isep, 2025).

4. CONFIANÇA, VIÉS DE AUTOMAÇÃO E A ARMADILHA DA CONFIANÇA (*TRUST TRAP*).

4.1. Descarga Cognitiva e *Automation Bias*

Lyell e Coiera (2017) sistematizam a tendência de aceitar recomendações ou *outputs* de sistemas automatizados sem verificação suficiente, mesmo quando a verificação seria possível e necessária. O fenómeno chamado de viés de automação (*automation bias*) associa-se à carga cognitiva e à complexidade da tarefa de verificação: quanto mais custoso ou opaco for auditar o sistema, maior a probabilidade de aceitação acrítica.

A descarga cognitiva (*cognitive offloading*), transferir parte do esforço de memória, análise ou redação para a ferramenta, é, em si, adaptativa. Torna-se problemática quando se converte em substituição do julgamento sob pressão de prazo e volume, exatamente as condições típicas de órgãos licenciadores e consultorias ambientais (Isep, 2025; Bond; Dusík, 2025; Fast; Fitzpatrick; Dilay, 2025).

4.2. Fluência Linguística e Confiança Cega

Os LLMs produzem textos coerentes, bem estruturados e linguisticamente convincentes. Essa fluência é um atributo de interface, não um certificado de veracidade factual (Ji *et al.*, 2023). Zuin e Goergen (2025) problematizam a opacidade de sistemas de aprendizado profundo e o risco de tomar uma pela outra, argumento diretamente transferível a pareceres e sumários

ambientais assistidos por IA generativa. O resultado é uma armadilha da confiança (*trust trap*) em quatro passos: o profissional enfrenta alta demanda; delega ao LLM etapas de leitura, síntese ou redação (descarga cognitiva) (Lyell; Coiera, 2017); recebe uma resposta fluente e aparentemente profissional (Zuin; Goergen, 2025; Ji *et al.*, 2023); e, em consequência, reduz a inspeção crítica (*automation bias*) (Lyell; Coiera, 2017; Bittencourt, 2025). Em tarefas fora da fronteira ou com documentos longos, o erro se instala de forma silenciosa (Dell'Acqua *et al.*, 2026; Liu *et al.*, 2024).

Bittencourt (2025) formula de modo direto o dilema ético da confiança em IA em domínios de alto risco: quem avisará quando o sistema estiver errado? A pergunta é transferível ao licenciamento: se o analista não audita, e o gestor confia no parecer assistido por IA, o erro pode percorrer a cadeia decisória com aparência de rigor (Bittencourt, 2025; Bingham *et al.*, 2025).

4.3. Alta Carga de Trabalho no Setor Ambiental

A prática de AIA e licenciamento é intensiva em documentação, prazos administrativos e múltiplos atores (empreendedor, consultoria, órgão ambiental, Ministério Público, sociedade) (Isep, 2025; Forghaniallahabadi, 2025). Nesse cenário, a promessa de eficiência da IA generativa é particularmente atrativa. Contudo, a mesma pressão que motiva a adoção também aumenta a probabilidade de *trust trap*, pois não há tempo para verificar tudo o que se delegou (Lyell; Coiera, 2017; Bond; Dusík, 2025).

Bond e Dusík (2025) registram preocupações de profissionais com *prompt engineering*, compreensão crítica e dependência excessiva. Somada ao risco formativo já apontado (seção 2.3), a armadilha da

confiança deixa de ser apenas individual e pode tornar-se organizacional e geracional (Isep, 2025; Hermann, 2025).

A armadilha da confiança pode ser descrita, de modo sintético, como o produto de três fatores que se reforçam: (i) pressão de produção (volume de processos e prazos); (ii) opacidade parcial do modelo (dificuldade de explicar por que determinada passagem foi enfatizada ou omitida) (Zuin; Goergen, 2025; Forghaniallahabadi, 2025); e (iii) heurística de fluência (Ji *et al.*, 2023; Zuin; Goergen, 2025). No licenciamento, o análogo da recomendação automatizada em domínios clínicos (Lyell; Coiera, 2017) é o enquadramento de tipologias, a lista de impactos “relevantes”, o rol de condicionantes sugeridas ou o sumário de conformidade legal. Aceitá-los sem rastreio reproduz, em contexto de alto risco, o viés descrito por Bittencourt (2025).

Importa distinguir confiança calibrada de confiança cega. Confiança calibrada é aquela ajustada à evidência de desempenho em tarefas específicas e ao custo do erro. Confiança cega é a generalização indevida. A fronteira irregular de Dell’Acqua *et al.* (2026) é, em essência, um argumento contra a confiança cega, porquanto o desempenho não é estacionário ao longo do mapa de tarefas.

5. TAXONOMIA DE ALUCINAÇÕES E SEUS IMPACTOS NO LICENCIAMENTO AMBIENTAL

Ji *et al.* (2023) distinguem, de modo amplamente adotado, alucinações intrínsecas e extrínsecas. Na alucinação intrínseca, o conteúdo gerado contradiz a fonte fornecida ou o conhecimento de referência no *input*: o modelo afirma o contrário do que está no documento. Na alucinação extrínseca, o conteúdo não está

sustentado pela fonte: a IA inventa fatos, números, citações, entidades ou relações. Não necessariamente contradiz um trecho explícito, mas adiciona informação não verificável a partir do material dado.

A IAlA, nos *Principles for Use of AI in IA* (Bingham *et al.*, 2025), inclui explicitamente as *AI hallucinations*, informação falsa ou enganosa apresentada pelo sistema, entre as limitações que exigem *oversight* humano (Princípio 5).

Nos dois tipos de alucinação, o risco regulatório é grave, pois o texto permanece legível e persuasivo. A alucinação não se anuncia como erro, apresenta-se como continuidade narrativa (Ji *et al.*, 2023; Zuin; Goergen, 2025). Combinada ao *Lost in the Middle* (Liu *et al.*, 2024), a alucinação extrínseca pode preencher lacunas que o modelo não recuperou no miolo do documento, enquanto a intrínseca pode sobrescrever o que foi mal recuperado.

A fiabilidade, no licenciamento, não se reduz à taxa de erro do LLM em *benchmarks* genéricos. Depende da qualidade e completude do *input* (Isep, 2025), do desenho do *prompt* e do fluxo (Cilliers *et al.*, 2025), da competência do usuário (Bingham *et al.*, 2025), e da governança institucional de *disclosure* e verificação (Bond; Dusík, 2025; Fast; Fitzpatrick; Dilay, 2025). Por isso, discussões de confiança devem deslocar-se da pergunta ingênua “posso confiar no ChatGPT?” para “em que condições de tarefa, dado, supervisão e responsabilidade o uso é defensável?” (Dell’Acqua *et al.*, 2026; Bingham *et al.*, 2025).

6. EVIDÊNCIAS ESPECÍFICAS DA LITERATURA SOBRE IA EM AVALIAÇÃO DE IMPACTO AMBIENTAL E LICENCIAMENTO

Forghaniallahabadi (2025) analisou 63 estudos e mapeia aplicações em predição e modelagem, coleta e processamento de dados, suporte à avaliação e decisão, e monitoramento em tempo real. O quadro teórico da autora destaca forte presença de transformação digital e governança, e menor cobertura de inovação responsável, ou seja, a dimensão ética e antecipatória ainda é subexplorada na literatura sobre avaliação ambiental.

Bond e Dusík (2025) situam o estado da arte da IA na AIA. Embora haja registros desde os anos 1990, o interesse cresce de forma acentuada com os LLMs. Há ganhos de eficiência e integração de dados, mas persistem preocupações de fiabilidade, viés, transparência e acurácia. Os autores concluem que o futuro depende de salvaguardas, governança e padrões profissionais, em diálogo explícito com os princípios da IAIA (Bingham *et al.*, 2025).

Hung, Kumar e Fischer (2026) revisam o uso de NLP em avaliação de impacto, articulando aplicações e preocupações de transparência, *prompting* e qualidade de *outputs*, tema diretamente ligado a IA generativa em textos de EIA e coerente com Bond *et al.* (2024) e Cilliers *et al.* (2025).

A ISEP (2025) lista benefícios operacionais em *baseline*, análise geoespacial, NTS, cenários e monitoramento, e enuncia seis princípios: compreensão e competência; alinhamento regulatório; transparência; acurácia e verificação; *garbage in, garbage out* (GIGO); e utilidade, não dependência. Detalha barreiras técnicas, éticas e organizacionais, inclusive privacidade, viés, impacto ambiental da própria IA e risco à formação de novos profissionais.

A IAIA (Bingham *et al.*, 2025) publicou princípios construídos em consulta aos associados nas conferências de 2023 e 2024 e adotados em 2025. Destacam-se responsabilidade humana plena, transparência de uso, não substituição de métodos regulatórios sem certificação, *oversight* por *expertise*, consciência de limitações, incluindo alucinações, proteção de vulneráveis e privacidade, competência em IA e prevenção de *model collapse*.

As orientações da ISEP (2025) e da IAIA (Bingham *et al.*, 2025) não substituem ciência empírica, mas oferecem uma gramática normativa já incorporada pela literatura (Bond; Dusík, 2025; Hung; Kumar; Fischer, 2026).

Fast, Fitzpatrick e Dilay (2025) oferecem síntese de *policy/prática* sobre IA e avaliação de impacto, reforçando a agenda de riscos, oportunidades e governança em diálogo com a literatura de *practitioners*.

Cilliers *et al.* (2025) avaliam GPT customizado para *screening* de EIA na África do Sul com 20 casos reais e três versões iterativas do *screeener*. O estudo mostra potencial, mas também a necessidade de instruções contextuais alinhadas ao regime legal e de supervisão humana. A melhoria entre versões ilustra que usar GPT nessa tarefa envolve engenharia de contexto regulatório.

Bond *et al.* (2024) examinam o uso de *chatbot* para revisão crítica de literatura sobre IA em EIA, evidenciando o caráter experimental e a necessidade de julgamento humano na curadoria de resultados, coerente com a fronteira irregular (Dell'Acqua *et al.*, 2026) e com o risco de alucinações em citações (Ji *et al.*, 2023).

No panorama brasileiro, o debate acerca da articulação entre IA e licenciamento ainda se encontra em estágio inicial se comparado à produção internacional. Salib e Garcia (2021) analisam o uso de IA e algoritmos no licenciamento ambiental à luz do princípio da precaução. Argumentam que a pretensão de prever objetivamente impactos futuros por meio de algoritmos pode fragilizar a proteção ambiental e tensionar o *in dubio pro ambiente*, reforçando a necessidade de análise caso a caso. Essa posição não nega utilidade instrumental de ferramentas, mas questiona a delegação de juízos sob incerteza (Salib; Garcia, 2021). Fertig, Fertig e Souza (2018) oferecem análise preliminar da inserção de IA em processos de licenciamento no cenário brasileiro. Da Silva *et al.* (2025) discutem a IA como mediadora em processos decisórios de planejamento urbano e licenciamento, com ênfase em governança e auditabilidade. Hermann (2025) contribui, a partir da educação e da ética, para problematizar a opacidade algorítmica e a confusão entre fluência e verdade, temas que interessam à formação de profissionais ambientais.

7. DIRETRIZES PARA USO CRÍTICO E RESPONSÁVEL NO LICENCIAMENTO AMBIENTAL

Com base na síntese deste artigo, propõem-se diretrizes práticas para uso da IA no licenciamento ambiental.

- Mapear a fronteira tecnológica da organização

Cada órgão ou consultoria deve classificar tarefas em: (a) elegíveis a apoio por LLM com supervisão leve; (b) elegíveis apenas com auditoria reforçada; (c) não elegíveis a automação de juízo (significância, precaução, decisão de mérito) (Dell'Acqua *et al.*, 2026;

Salib; Garcia, 2021; Bingham *et al.*, 2025). Esse mapeamento deve ser revisado periodicamente.

- Adotar postura de Centauro em tarefas sensíveis

A formulação do problema cabe ao humano, a execução assistida à IA e a verificação e a decisão novamente ao humano; a integração Ciborgue deve ser evitada em etapas fora da fronteira (Dell'Acqua *et al.*, 2026; Isep, 2025; Lyell; Coiera, 2017).

- Particionar processos longos antes de submetê-los

Aplicar *chunking* por tema/volume; exigir citações a trechos; confrontar condicionantes e dados numéricos com a fonte (Liu *et al.*, 2024; Isep, 2025; Hung; Kumar; Fischer, 2026).

- Exigir auditoria humana e *disclosure*

Registrar ferramenta, data e modo de uso (Bingham *et al.*, 2025, Princípio 2). Toda afirmação regulatória ou quantitativa gerada ou mediada por LLM deve ser verificável (Ji *et al.*, 2023; Isep, 2025). A responsabilidade final deve ser humana (Bingham *et al.*, 2025).

- Treinar para desconfiança produtiva

Imprescindível a formação e instrução dos usuários sobre limites de LLMs, alucinações, *Lost in the Middle*, *automation bias*, GIGO e ética (Ji *et al.*, 2023; Liu *et al.*, 2024; Lyell; Coiera, 2017; Isep, 2025; Hermann, 2025; Zuin; Goergen, 2025; Bittencourt, 2025). É uma maneira de assegurar o princípio de competência em IA (Bingham *et al.*, 2025).

- Proteger dados sensíveis e privacidade

Evitar *upload* de dados pessoais, territoriais sensíveis ou informação de grupos vulneráveis em ferramentas sem garantia contratual e jurídica adequada (Bingham *et al.*, 2025, Princípio 6; Isep, 2025).

- Acompanhar indicadores mínimos de governança interna

Organizações que adotem IA generativa no fluxo de licenciamento deveriam acompanhar, pelo menos internamente: percentual de peças com *disclosure* de uso de IA, número de não conformidades detectadas na auditoria humana de *output*, incidentes de alucinação documentados e horas de formação crítica por analista (Bond; Dusík, 2025; Isep, 2025; Fast; Fitzpatrick; Dilay, 2025; Bingham *et al.*, 2025).

- Compatibilidade com o ordenamento e com a precaução

Qualquer protocolo deve ser lido à luz do dever estatal de proteção ambiental e do princípio da precaução. Ferramentas que produzam aparência de certeza estatística ou de objetividade em cenários de incerteza científica merecem escrutínio reforçado (Salib; Garcia, 2021; Da Silva *et al.*, 2025). As ferramentas podem organizar informação; no entanto, não substituem o juízo precautório em incerteza (Fertig; Fertig; Souza, 2018; Salib; Garcia, 2021).

8. CONSIDERAÇÕES FINAIS

Esta revisão crítica articulou evidências sobre IA generativa no trabalho de conhecimento com o campo da avaliação de impacto e do licenciamento ambiental. Três conclusões estruturam a síntese: (1) os ganhos de produtividade são reais, porém condicionais. A fronteira tecnológica irregular (Dell'Acqua *et al.*, 2026) impõe distinção rigorosa entre tarefas em que LLMs tendem a ajudar e

tarefas em que tendem a prejudicar o desempenho, notadamente juízos de significância, incerteza e precaução no licenciamento (Salib; Garcia, 2021; Bond; Dusík, 2025); (2) as vulnerabilidades estruturais dos modelos (recuperação irregular em contextos longos e alucinações intrínsecas e extrínsecas) interagem com vulnerabilidades humanas e organizacionais (Lyell; Coiera, 2017; Bittencourt, 2025; Zuin; Goergen, 2025). A fluência do texto é o elo que une ambos os lados do risco; (3) a literatura e as orientações profissionais de AIA convergem para um núcleo normativo: responsabilidade humana inegociável, transparência de uso, verificação, competência e alinhamento regulatório (Bingham *et al.*, 2025; Isep, 2025; Bond; Dusík, 2025; Fast; Fitzpatrick; Dilay, 2025). Evidências empíricas com IA generativa em EIA, como o *screening* assistido por GPT (Cilliers *et al.*, 2025) e o uso de *chatbot* em revisão de literatura (Bond *et al.*, 2024), confirmam potencial e, simultaneamente, a dependência de desenho contextual e supervisão.

No Brasil, a agenda de pesquisa permanece aberta e urgente: faltam estudos empíricos sobre uso real de LLMs em órgãos licenciadores e consultorias; protocolos de *disclosure* adaptados ao direito ambiental brasileiro; avaliações de erro em processos administrativos reais; e formação crítica de analistas (Salib; Garcia, 2021; Fertig; Fertig; Souza, 2018; Da Silva *et al.*, 2025; Hermann, 2025). Sem isso, a adoção seguirá informal, desigual e potencialmente lesiva à confiança pública no licenciamento.

Em última instância, a inteligência artificial generativa pode ser instrumento de apoio ao trabalho de conhecimento ambiental. Não pode, contudo, figurar como *locus* da responsabilidade. A decisão

sobre o território, sob incerteza e sob dever de proteção, permanece humana (Bingham *et al.*, 2025; Isep, 2025; Salib; Garcia, 2021).

O presente trabalho foi realizado com apoio da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior - Brasil (CAPES) – Código de Financiamento 001 e da Universidade do Estado de Santa Catarina (UDESC), por meio do Programa de Bolsas de Monitoria de Pós-Graduação (PROMOP).

Declaração sobre o uso de Inteligência Artificial: Ferramentas de inteligência artificial generativa (OpenAI, Anthropic, xAI) foram utilizadas exclusivamente como apoio à revisão linguística, aprimoramento da redação acadêmica, tradução do resumo, padronização de referências bibliográficas e organização estrutural do manuscrito. Todas as análises, resultados, interpretações e conclusões apresentadas neste estudo são de responsabilidade exclusiva dos autores.

REFERÊNCIAS BIBLIOGRÁFICAS

BINGHAM, C., BOND, A., *et al.* **Principles for use of AI in IA.** Fargo: International Association for Impact Assessment, 2025. (Special Publication Series, n. 16). Disponível em: https://iaia.org/wp-content/uploads/2025/06/SP16_AI-in-IA.pdf. Acesso em: 3 ago. 2026.

BITTENCOURT, M. S. Você vai avisá-los quando estiverem errados? Viés de automação e inteligência artificial na medicina. **Arquivos Brasileiros de Cardiologia**, Rio de Janeiro, v. 122, n. 5, e20250300, 2025. DOI: [10.36660/abc.20250300](https://doi.org/10.36660/abc.20250300). Disponível em: <https://www.scielo.br/j/abc/a/WJDWpS78653m9YqZPvdmwG/>. Acesso em: 3 ago. 2026.

BOND, A.; CILLIERS, D.; RETIEF, F.; ALBERTS, R.; ROOS, C.; MOOLMAN, J. Using an artificial intelligence chatbot to critically review the scientific literature on the use of artificial intelligence in environmental impact assessment. **Impact Assessment and Project Appraisal**, v. 42, n. 2, p. 189-199, 2024. DOI: [10.1080/14615517.2024.2320591](https://doi.org/10.1080/14615517.2024.2320591).

BOND, A.; DUSÍK, J. Artificial intelligence in impact assessment: the state of the art. **Impact Assessment and Project Appraisal**, 2025. DOI: [10.1080/14615517.2025.2594274](https://doi.org/10.1080/14615517.2025.2594274). Disponível em: <https://www.tandfonline.com/doi/full/10.1080/14615517.2025.2594274>. Acesso em: 3 ago. 2026.

CILLIERS, D.; BOND, A.; RETIEF, F.; ALBERTS, R.; ROOS, C. Large language model-assisted EIA screening: a case study using GPT. **Impact Assessment and Project Appraisal**, v. 43, n. 4, p. 267-277, 2025. DOI: [10.1080/14615517.2025.2523628](https://doi.org/10.1080/14615517.2025.2523628).

DA SILVA, V. F. *et al.* Planejamento urbano e licenciamento ambiental: o uso de IA como mediadora em “ecologias de decisão” distribuída entre dados. **Aracê**, v. 7, n. 9, e7824, 2025. DOI: [10.56238/arev7n9-058](https://doi.org/10.56238/arev7n9-058). Disponível em: <https://periodicos.newsciencepubl.com/arace/article/view/7824>. Acesso em: 3 ago. 2026.

DELL'ACQUA, F.; MCFOWLAND, E., III; MOLLICK, E.; LIFSHITZ, H.; KELLOGG, K. C.; RAJENDRAN, S.; KRAYER, L.; CANDELON, F.; LAKHANI, K. R. Navigating the jagged technological frontier: field experimental evidence of the effects of artificial intelligence on knowledge worker productivity and quality. **Organization Science**, v. 37, n. 2, p. 403-423, 2026. DOI: [10.1287/orsc.2025.21838](https://doi.org/10.1287/orsc.2025.21838).

FAST, H. M.; FITZPATRICK, P.; DILAY, K. **Artificial Intelligence (AI) and Impact Assessment (IA) Memo**. [S. l.]: MBECO Network, 2025. Disponível em: https://mbeconetwork.org/wp-content/uploads/2025/08/25-08-05_Memo-on-AI-and-IA_Final.pdf. Acesso em: 3 ago. 2026.

FERTIG, Katharine Schaeffer; FERTIG, Kristhine Schaeffer; SOUZA, Gabriel. **Análise do uso de inteligência artificial no auxílio de processos de licenciamento ambiental**. [S. l.]: IFSC, 2018. Disponível em: https://wiki.sj.ifsc.edu.br/images/6/63/Artigo_SUS.pdf. Acesso em: 3 ago. 2026.

FORGHANIALLAHABADI, M. **Artificial Intelligence (AI) in Environmental Assessment (EA): a systematic literature review**. Dundee: University of Dundee, 2025. DOI: [10.20933/100001470](https://doi.org/10.20933/100001470). Disponível em: <https://discovery.dundee.ac.uk/en/publications/artificial-intelligence-ai-in-environmental-assessment-ea-a-syste/>. Acesso em: 3 ago. 2026.

HERMANN, N. Ética e inteligência artificial: o que inquieta? **Educação & Sociedade**, v. 46, e296750, 2025. DOI: [10.1590/ES.296750](https://doi.org/10.1590/ES.296750). Disponível em: <https://www.scielo.br/j/es/a/fyVqsnXMDzX3Pq8xdZ5DpBS/>. Acesso em: 3 ago. 2026.

HUNG, S. F.; KUMAR, P.; FISCHER, T. B. Natural language processing in impact assessment: a review of applications and concerns. **Impact Assessment and Project Appraisal**, v. 44, n. 1, p. 68-73, 2026. DOI: [10.1080/14615517.2026.2620186](https://doi.org/10.1080/14615517.2026.2620186).

INSTITUTE OF SUSTAINABILITY AND ENVIRONMENTAL PROFESSIONALS (ISEP). **ISEP Advice Note: Using AI in EIA**: the use

of Artificial Intelligence in Environmental Impact Assessment. [S. l.]: ISEP, 2025. Disponível em: <https://www.isepglobal.org/media/15fc2b0w/isep-2025-ai-in-ia.pdf>. Acesso em: 3 ago. 2026.

JI, Z.; LEE, N.; FRIESKE, R.; YU, T.; SU, D.; XU, Y.; ISHII, E.; BANG, Y. J.; MADOTTO, A.; FUNG, P. Survey of hallucination in natural language generation. **ACM Computing Surveys**, v. 55, n. 12, art. 248, 2023. DOI: [10.1145/3571730](https://dl.acm.org/doi/10.1145/3571730). Disponível em: <https://dl.acm.org/doi/10.1145/3571730>. Acesso em: 3 ago. 2026.

LIU, N. F.; LIN, K.; HEWITT, J.; PARANJAPE, A.; BEVILACQUA, M.; PETRONI, F.; LIANG, P. Lost in the middle: how language models use long contexts. **Transactions of the Association for Computational Linguistics**, v. 12, p. 157-173, 2024. DOI: [10.1162/tacL_a_00638](https://doi.org/10.1162/tacL_a_00638).

LYELL, D.; COIERA, E. Automation bias and verification complexity: a systematic review. **Journal of the American Medical Informatics Association**, v. 24, n. 2, p. 423-431, 2017. DOI: [10.1093/jamia/ocw105](https://doi.org/10.1093/jamia/ocw105). Disponível em: <https://pubmed.ncbi.nlm.nih.gov/27516495/>. Acesso em: 3 ago. 2026.

SALIB, M. L. L.; GARCIA, D. S. S. O uso da inteligência artificial e dos algoritmos no licenciamento ambiental e o princípio da precaução. **Conpedi Law Review**, Florianópolis, v. 7, n. 1, p. 1-20, 2021. DOI: [10.26668/2448-3931_conpedilawreview/2021.v7i1.7598](https://doi.org/10.26668/2448-3931_conpedilawreview/2021.v7i1.7598). Disponível em: <https://www.indexlaw.org/index.php/conpedireview/article/view/7598>. Acesso em: 3 ago. 2026.

ZUIN, A. Á. S.; GOERGEN, P. L. A inteligência artificial, a ética e a relação orgânica entre professores e alunos. **Educação & Sociedade**, v. 46, e297394, 2025. DOI: [10.1590/ES.297394](https://doi.org/10.1590/ES.297394). Disponível em:

<https://www.scielo.br/j/es/a/kKrPyTWHK7myCRVSMNwYJtw/>. Acesso em: 3 ago. 2026.

¹ Discente do Programa de Pós Graduação em Ciências Ambientais – Doutorado. Universidade do Estado de Santa Catarina (UDESC) Campus Centro de Ciências Agroveterinárias (CAV). E-mail: [acesse o artigo original para visualizar o e-mail](#)

² Discente do Programa de Pós Graduação em Ciências Ambientais – Mestrado. Universidade do Estado de Santa Catarina (UDESC) Campus Centro de Ciências Agroveterinárias (CAV). E-mail: [acesse o artigo original para visualizar o e-mail](#)

³ Docente Sênior da Pós Graduação em Ciências Ambientais. Universidade do Estado de Santa Catarina (UDESC) Campus Centro de Ciências Agroveterinárias (CAV). E-mail: [acesse o artigo original para visualizar o e-mail](#)