REVISTA TÓPICOS
ISSN 2965-6672 | Qualis A2

# USO DE INTELIGÊNCIA ARTIFICIAL GENERATIVA NA EDUCAÇÃO MÉDICA: BENEFÍCIOS, RISCOS E IMPACTOS NA FORMAÇÃO CLÍNICA

## USE OF GENERATIVE ARTIFICIAL INTELLIGENCE IN MEDICAL EDUCATION: BENEFITS, RISKS, AND IMPACTS ON CLINICAL TRAINING

Ciências da Saúde • 05/11/2026

REGISTRO DOI: 10.70773/revistatopicos/793768248

Gabriela de Paula Vaz Candido Gomes[1]

Alexandre Fleury Curado de Faria[2]

Ana Clara Machado Bariani[3]

Clara Luquetti Paiva[4]

Daniel Gonçalves da Silva[5]

Felipe Schmaltz Zalaf[6]

Gabriel Alcino Souza Ferreira[7]

João Pedro Gonçalves Souza[8]

João Vitor Lelis Faria[9]

José Nicolas Andraos Filho[10]

Kamila Carvalho Naves de Afonseca[11]

Lucas Henrique Melo Guimarães[12]

Luis Fellipe Diniz Fernandes[13]

Mariana Bandeira Junqueira[14]

Matheus Lúcio Fernandes Gomes[15]

Natália Campos Trindade[16]

Natan Campos Trindade[17]

Pedro Henrique Miranda de Mendonça[18]

Ruan Carlos Vicente Barbosa dos Santos[19]

Sarah Elias Landim[20]

Thomás Liberato Dias[21]

**RESUMO**

A inteligência artificial generativa (IAG), alavancada pelos Modelos de Linguagem de Grande Escala (LLMs), emergiu como um divisor de águas na educação médica, transformando métodos de ensino e estratégias de aprendizagem. Este artigo teve como objetivo discutir, por meio de revisão bibliográfica narrativa de caráter descritivo e analítico, as evidências científicas recentes sobre o uso da IAG na formação médica, analisando seus potenciais benefícios, riscos e impactos na autonomia cognitiva e no raciocínio clínico dos estudantes. Foram analisados estudos publicados entre 2025 e 2026, com ênfase em revisões de escopo, revisões sistemáticas narrativas e ensaios críticos sobre o tema. A literatura indica que a IAG oferece oportunidades promissoras para a simulação de pacientes virtuais, o suporte ao aprendizado baseado em problemas (PBL) e a geração de materiais instrucionais customizados. No entanto, o uso acoplado e não regulado expõe os estudantes a alucinações algorítmicas, vieses em saúde e ao risco de atrofia cognitiva (deskilling) decorrente do descarregamento cognitivo (cognitive offloading). A efetividade pedagógica da tecnologia é intrinsecamente dependente do suporte estruturado (scaffolding), da supervisão docente contínua e do estabelecimento de matrizes de competência em IA. Conclui-se que a IAG deve ser adotada como ferramenta potencializadora e complementar, preservando a mentoria humana beira-leito, a investigação autônoma e o julgamento crítico na formação médica.

**Palavras-chave:** Inteligência Artificial Generativa; Educação Médica; Raciocínio Clínico; Metodologias Ativas; Autonomia Cognitiva.

**ABSTRACT**

Generative artificial intelligence (GenAI), driven by Large Language Models (LLMs), has emerged as a game-changer in medical

education, transforming teaching methods and learning strategies. This article aimed to discuss, through a descriptive and analytical narrative literature review, recent scientific evidence on the use of GenAI in medical training, analyzing its potential benefits, risks, and impacts on cognitive autonomy and clinical reasoning. Studies published between 2025 and 2026 were analyzed, emphasizing scoping reviews, systematic narrative reviews, and critical essays. The literature indicates that GenAI offers promising opportunities for virtual patient simulation, support for problem-based learning (PBL), and the generation of customized instructional materials. However, unguided and unregulated use exposes students to algorithmic hallucinations, health biases, and the risk of cognitive deskilling resulting from cognitive offloading. The pedagogical effectiveness of the technology is intrinsically dependent on instructional scaffolding, continuous faculty supervision, and the implementation of AI competency frameworks. It is concluded that GenAI should be adopted as a complementary and enhancing tool, preserving bedside human mentorship, independent inquiry, and critical judgment in medical education.
**Keywords:** Generative Artificial Intelligence; Medical Education; Clinical Reasoning; Active Learning; Cognitive Autonomy.

## 1. INTRODUÇÃO

A formação médica contemporânea enfrenta um cenário de profunda transformação impulsionado pelo avanço vertiginoso das tecnologias digitais de informação e comunicação. Se o advento da internet e dos motores de busca de alta velocidade democratizou o acesso à literatura científica nas últimas décadas, a introdução da Inteligência Artificial Generativa (IAG) e dos Modelos de Linguagem de Grande Escala (Large Language Models — LLMs), tais como

ChatGPT, DeepSeek, Gemini e Claude, inaugurou um novo paradigma no ecossistema educacional das ciências da saúde (Izquierdo-Condoy et al., 2025; Zhao et al., 2026). Essas ferramentas conversacionais, capazes de processar grandes volumes de dados linguísticos e gerar textos semanticamente articulados, simulações de diálogos e resoluções de problemas em tempo real, passaram a integrar rapidamente a rotina acadêmica dos estudantes de medicina (Xie; Zhang; Xiao, 2026).

A adesão dos discentes à IAG tem ocorrido de forma orgânica e acelerada, frequentemente ultrapassando o ritmo de formulação de diretrizes institucionais e regulamentações curriculares formais (Xie; Zhang; Xiao, 2026; Wulandari et al., 2025). Estudantes utilizam esses sistemas para sintetizar temas complexos da fisiopatologia, elaborar resumos, formular diagnósticos diferenciais hipotéticos e preparar-se para avaliações teóricas e práticas (Wulandari et al., 2025). Essa ampla aceitabilidade fundamenta-se na capacidade da IAG de atuar como um tutor sob demanda, oferecendo respostas imediatas e ambientes de prática privados e livres de julgamento, o que atenua a ansiedade associada ao aprendizado em cenários de alta pressão (Wulandari et al., 2025; Zhao et al., 2026).

Entretanto, essa rápida difusão suscita debates inflamados na comunidade acadêmica internacional. Por um lado, defende-se a IAG como um poderoso "potencializador cognitivo" (cognitive enhancer), capaz de democratizar o aprendizado, otimizar tarefas administrativas e permitir que estudantes e preceptores foquem no desenvolvimento de competências de ordem superior e no cuidado centrado no paciente (Izquierdo-Condoy et al., 2025; Xie; Zhang; Xiao, 2026). Por outro lado, surgem alertas contundentes sobre os riscos de atrofia de habilidades críticas (deskilling), passividade mental e

erosão da autonomia cognitiva (Izquierdo-Condoy et al., 2025). A tendência de utilizar os algoritmos como atalho para a obtenção de respostas prontas pode contornar o esforço cognitivo e a reflexão profunda, etapas indispensáveis para a consolidação de "esquemas de doença" (illness scripts) e para o desenvolvimento do raciocínio clínico autônomo (Jochem, 2026; Izquierdo-Condoy et al., 2025).

A problematização central que orienta esta pesquisa reside na seguinte questão: de que maneira a integração da inteligência artificial generativa afeta a formação médica, e quais estratégias pedagógicas são necessárias para maximizar seus benefícios instrucionais enquanto se mitigam os riscos de dependência cognitiva, alucinações e vieses na prática clínica? O problema ganha especial relevância diante da constatação de que a fluência verbal dos LLMs pode mascarar erros fáticos graves, informações inventadas (hallucinations) e condutas enviesadas, que, se absorvidas passivamente por aprendizes em fase de consolidação do conhecimento, podem comprometer a segurança do paciente e a qualidade da assistência futura (Zhao et al., 2026; Xie; Zhang; Xiao, 2026).

A justificativa para o desenvolvimento deste trabalho fundamenta-se na necessidade de fornecer uma síntese crítica e atualizada da literatura científica recente (2025–2026), superando a abordagem meramente técnica de desempenho de modelos (benchmarking) para focar nos impactos reais vivenciados pelos estudantes durante o processo de ensino-aprendizagem. Analisar como a IAG interage com metodologias ativas — como a Aprendizagem Baseada em Problemas (PBL) —, a simulação clínica e a mentoria médica é essencial para orientar docentes, gestores e alunos na construção de currículos reflexivos, éticos e adaptados às exigências do século XXI.

Diante disso, este artigo tem como objetivo discutir, por meio de uma revisão bibliográfica narrativa de caráter descritivo e analítico, o uso da inteligência artificial generativa na educação médica, examinando seus potenciais benefícios, riscos técnicos e éticos, e impactos no desenvolvimento do raciocínio clínico e na formação médica.

### 1.1. A Especificidade da Educação Médica Diante da Geração Automatizada de Respostas

A discussão sobre ferramentas generativas exige reconhecer que o aprendizado médico não se esgota na assimilação de informações corretas. A formação clínica envolve selecionar dados relevantes, interpretar informações incompletas, justificar decisões e reconhecer os próprios limites. A possibilidade de obter uma explicação instantânea pode facilitar a entrada em um assunto, mas não substitui o processo pelo qual o estudante aprende a construir, revisar e abandonar hipóteses. Assim, a avaliação da utilidade pedagógica da inteligência artificial generativa precisa considerar tanto o produto apresentado quanto a atividade intelectual efetivamente realizada pelo aluno. Essa distinção atravessa as análises de Izquierdo-Condoy et al. (2025), Wulandari et al. (2025) e Xie, Zhang e Xiao (2026).

O mesmo recurso pode assumir funções pedagógicas opostas conforme o momento de uso. Antes de uma discussão de caso, uma resposta completa pode reduzir o espaço para a formulação independente de hipóteses; após a elaboração inicial do raciocínio, a comparação com uma resposta alternativa pode revelar lacunas e estimular a revisão crítica. Não se trata, portanto, de classificar a tecnologia como benéfica ou prejudicial em abstrato, mas de

explicitar as condições em que ela amplia ou diminui a participação cognitiva do aprendiz. A supervisão docente e a sequência das atividades tornam-se variáveis essenciais na interpretação dos resultados educacionais (Jochem, 2026; Zhao et al., 2026).

### 1.2. Do Desempenho Textual à Competência Profissional

A fluência de uma resposta algorítmica não demonstra que o sistema compreenda o contexto humano da decisão clínica, assim como a reprodução correta de um protocolo pelo estudante não garante a capacidade de aplicá-lo diante de incertezas. A competência médica exige integrar conhecimentos biomédicos, comunicação, responsabilidade e reconhecimento das consequências das decisões. O problema de pesquisa, por isso, ultrapassa a comparação entre notas obtidas com e sem assistência tecnológica: importa identificar se o aluno consegue justificar o que decidiu, reconhecer alternativas e agir adequadamente quando a ferramenta não está disponível (Xie; Zhang; Xiao, 2026).

Essa perspectiva também delimita a relevância social do tema. A formação de profissionais que utilizam recursos digitais sem abdicar de sua responsabilidade intelectual depende de práticas educativas que tornem visíveis os critérios de confiança, os limites do conhecimento disponível e a necessidade de confirmação de informações sensíveis. O uso responsável da inteligência artificial na graduação deve ser discutido como parte da formação de julgamento profissional, não apenas como uma atualização instrumental do currículo (Izquierdo-Condoy et al., 2025; Zhao et al., 2026).

## 2. FUNDAMENTAÇÃO TEÓRICA OU REVISÃO DA LITERATURA

### 2.1. Evolução e Papel da IA Generativa na Educação Médica

A inteligência artificial generativa fundamenta-se em modelos de aprendizado profundo (deep learning) construídos sobre arquiteturas transformer, as quais utilizam mecanismos de auto-atenção para avaliar a relevância contextual de palavras e padrões em sequências extensas de dados (Izquierdo-Condoy et al., 2025). Diferentemente dos sistemas tradicionais de busca ou de regras fixas, os LLMs possuem a capacidade de produzir textos coesos, traduzir linguagens, codificar programas e simular diálogos complexos a partir de comandos em linguagem natural (prompts) (Zhao et al., 2026; Izquierdo-Condoy et al., 2025).

A porta de entrada da IAG na literatura acadêmica médica deu-se primordialmente por meio de estudos de benchmarking, nos quais modelos como o ChatGPT (GPT-3.5 e GPT-4) demonstraram desempenho impressionante ao atingir ou superar a nota de corte no United States Medical Licensing Examination (USMLE) e em exames de licenciamento e residência ao redor do mundo, incluindo Japão, China e especialidades como ortopedia, anestesiologia, nefrologia e oncologia (Zhao et al., 2026; Xie; Zhang; Xiao, 2026; Izquierdo-Condoy et al., 2025). Contudo, como ressaltam Xie, Zhang e Xiao (2026), o sucesso em exames de múltipla escolha reflete predominantemente a recuperação de conhecimento declarativo e o reconhecimento de padrões estatísticos, não devendo ser equiparado à competência clínica real.

Estudos recentes documentam a existência de uma "ilusão da escolha múltipla" (multiple-choice illusion), em que modelos de linguagem que obtêm excelente pontuação em testes estruturados apresentam uma queda expressiva de desempenho (em média

39,43%) quando avaliados por meio de perguntas discursivas ou de resposta livre sobre os mesmos conteúdos (Xie; Zhang; Xiao, 2026). Esse fenômeno demonstra que os LLMs enfrentam limitações severas de flexibilidade cognitiva e raciocínio adaptativo quando confrontados com cenários clínicos ambíguos, sofrendo frequentemente do efeito Einstellung (fixação cognitiva rígida em padrões memorizados) (Xie; Zhang; Xiao, 2026).

Apesar dessas limitações estruturais, o papel da IAG na educação médica evoluiu rapidamente para a geração de recursos educacionais e assistência personalizada. Educadores utilizam a tecnologia para elaborar questões de múltipla escolha alinhadas a diretrizes internacionais, formular vinhetas clínicas integradas e construir gabaritos comentados com significativa redução no tempo de autoria (Xie; Zhang; Xiao, 2026). Para os estudantes, a IAG consolidou-se como uma ferramenta versátil de estudo autorregulatório, oferecendo suporte 24 horas por dia para a síntese de tópicos extensos, explicação de mecanismos fisiopatológicos complexos e treinamento contínuo (Xie; Zhang; Xiao, 2026; Wulandari et al., 2025).

### 2.2. Aplicações da IA em Metodologias Ativas (PBL)

A Aprendizagem Baseada em Problemas (PBL, do inglês Problem-Based Learning) e a Aprendizagem Baseada em Casos (CBL) constituem pilares do ensino médico centrado no aluno, promovendo o raciocínio clínico, a busca autodirigida e o trabalho em equipe através do estudo de problemas da prática real (Jochem, 2026; Wulandari et al., 2025). A implementação tradicional do PBL, no entanto, exige expressivo investimento de tempo e capacitação

docente para a elaboração constante de problemas atualizados e para a mediação das sessões titoriais (Jochem, 2026).

Nesse contexto, a IAG surge como um recurso facilitador para a construção dinâmica de cenários clínicos multifacetados e adaptados aos objetivos de aprendizagem (Jochem, 2026; Xie; Zhang; Xiao, 2026). Estudos recentes demonstram que a aplicação de modelos como ChatGPT e DeepSeek em sessões de PBL nas disciplinas de hematologia, nefrologia e radiologia resultou em melhorias mensuráveis no desempenho acadêmico e no julgamento clínico dos estudantes quando comparados aos métodos de ensino convencionais (Jochem, 2026; Zhao et al., 2026). Observou-se, ainda, que a tecnologia possui o potencial de reduzir as disparidades de rendimento entre alunos com diferentes níveis de conhecimento prévio, atuando como um elemento nivelador (Jochem, 2026).

Entretanto, a integração da IAG ao PBL revela uma dicotomia marcante na postura dos estudantes. A literatura aponta que o impacto da ferramenta depende fundamentalmente do modo de interação adotado (Jochem, 2026; Izquierdo-Condoy et al., 2025). Quando o aluno utiliza a IA de forma ativa e questionadora — empregando-a para propor hipóteses diferenciais, confrontar interpretações e buscar justificativas baseadas em evidências —, o processo de investigação autônoma é fortalecido (Jochem, 2026; Wulandari et al., 2025). Por outro lado, quando a ferramenta é utilizada de forma passiva, apenas para extrair respostas prontas e preencher os objetivos da tutoria, ocorre um atalho cognitivo que descaracteriza a essência investigativa do PBL, comprometendo o desenvolvimento do pensamento crítico e a capacidade de

resolução de problemas (Jochem, 2026; Izquierdo-Condoy et al., 2025).

Além disso, a introdução do ensino de ética em inteligência artificial nos programas de PBL tem se mostrado indispensável. A capacitação dos discentes para reconhecer os limites éticos, a ausência de responsabilidade profissional do algoritmo e os potenciais vieses das respostas geradas promove uma postura mais cautelosa, crítica e segura no uso da tecnologia na prática médica (Jochem, 2026).

### 2.3. Desenvolvimento do Raciocínio Clínico e Simulação

O raciocínio clínico é o processo cognitivo pelo qual o médico estabelece a anamnese, interpreta dados físicos e laboratoriais, formula hipóteses diagnósticas e toma decisões terapêuticas fundamentadas (Wulandari et al., 2025; Izquierdo-Condoy et al., 2025). A assimilação dessa habilidade fundamenta-se em referenciais teóricos consolidados da educação médica, destacando-se o Aprendizado Cognitivo (Cognitive Apprenticeship), a Aprendizagem Autorregulada (SRL) e o Construtivismo (Wulandari et al., 2025).

A IAG conecta-se diretamente a esses modelos teóricos ao atuar como um "mentor cognitivo substituto" (Wulandari et al., 2025). Sob a ótica do Aprendizado Cognitivo, a ferramenta é capaz de tornar o pensamento do especialista visível para o estudante ao verbalizar, passo a passo, o encadeamento lógico que conecta um sintoma a uma hipótese diagnóstica (Wulandari et al., 2025). Sob a perspectiva do Construtivismo, a IAG possibilita a interação dialógica contínua, permitindo que o aluno teste hipóteses em um ambiente interativo

e adapte suas estruturas de conhecimento à medida que recebe explicações detalhadas (Wulandari et al., 2025).

No âmbito da simulação clínica, os LLMs impulsionam o desenvolvimento de Pacientes Virtuais (VPs) e tutores interativos de alta fidelidade conversacional (Zhao et al., 2026; Xie; Zhang; Xiao, 2026; Wulandari et al., 2025). Plataformas alimentadas por IA atuam como interlocutores em treinamentos de tomada de história clínica (anamnese), comunicação empática, revelação de más notícias e preparação para o Exame Clínico Objetivamente Estruturado (OSCE) (Zhao et al., 2026; Xie; Zhang; Xiao, 2026). A grande vantagem pedagógica dessas simulações reside na oportunidade de prática deliberada repetitiva em um ambiente seguro, privado e isento de riscos ao paciente real, acompanhada de feedback formativo imediato (Zhao et al., 2026; Wulandari et al., 2025).

Contudo, apesar do entusiasmo com os pacientes virtuais, a literatura destaca que os modelos de linguagem ainda carecem de sensibilidade contextual, empatia genuína e leitura de pistas não verbais (faciais, de tom de voz e de postura), elementos cruciais na consulta médica real (Zhao et al., 2026; Wulandari et al., 2025). Dessa forma, a simulação alimentada por IA é reconhecida como um recurso valioso para o treinamento inicial e a automação de etapas estruturadas, mas que exige a complementação inegociável da mentoria humana beira-leito.

### 2.4. Limitações Técnicas, Alucinações e Vieses em Saúde

Apesar das amplas possibilidades pedagógicas, a incorporação da IAG no ensino médico enfrenta severas limitações técnicas e éticas que não podem ser negligenciadas. A falha técnica mais

proeminente é o fenômeno da "alucinação", no qual o modelo gera respostas incorretas, diretrizes terapêuticas inadequadas ou citações bibliográficas totalmente fabricadas (PMIDs, autores e periódicos inexistentes), apresentando-as com tom persuasivo e de alta fluência acadêmica (Zhao et al., 2026; Xie; Zhang; Xiao, 2026; Izquierdo-Condoy et al., 2025; Wulandari et al., 2025).

Estudos focados na avaliação de fontes produzidas por LLMs revelam altas taxas de imprecisão e referenciação falsa, o que representa um perigo crítico para estudantes em estágios iniciais da formação, que muitas vezes não possuem a base conceitual necessária para detectar pequenos erros embutidos em textos aparentemente corretos (Xie; Zhang; Xiao, 2026; Izquierdo-Condoy et al., 2025; Wulandari et al., 2025). A reprodução acrítica dessas alucinações pode resultar no aprendizado de equívocos conceituais e na consolidação de condutas médicas inadequadas (Zhao et al., 2026; Izquierdo-Condoy et al., 2025).

Outro desafio crítico diz respeito aos vieses algorítmicos e às iniquidades em saúde perpetuadas pelos modelos. Como os LLMs são treinados em grandes bases de dados históricas, eles frequentemente replicam preconceitos estruturais, sub-representando populações vulneráveis e apresentando menor acurácia diagnóstica em cenários clínicos específicos (Xie; Zhang; Xiao, 2026; Izquierdo-Condoy et al., 2025). Demonstrou-se, por exemplo, que modelos avançados como o GPT-4o sub-representaram mulheres em simulações cardiovasculares e apresentaram menor precisão no diagnóstico de doença arterial coronariana no sexo feminino em comparação ao masculino, perpetuando vieses históricos da medicina (Xie; Zhang; Xiao, 2026).

Adicionalmente, evidenciam-se disparidades linguísticas significativas: as respostas fornecidas por LLMs em línguas não inglesas (como o português ou o espanhol) demonstram menor confiabilidade e acurácia clínica em comparação com os equivalentes em inglês, o que pode agravar desigualdades educacionais e assistenciais em países em desenvolvimento (Xie; Zhang; Xiao, 2026).

### 2.5. Conhecimento Declarativo, Contextualização e Transferência

O desempenho dos modelos em avaliações padronizadas deve ser interpretado a partir do tipo de tarefa exigida. Questões fechadas oferecem alternativas que restringem o espaço de resposta, ao passo que situações clínicas abertas requerem selecionar informações, estabelecer prioridades e lidar com possibilidades concorrentes. A diferença entre esses formatos ajuda a explicar por que bons resultados em testes não autorizam concluir que uma ferramenta possua competência clínica ampla. A análise de Xie, Zhang e Xiao (2026) chama atenção para a distância entre reconhecimento de padrões em exames e adaptação do raciocínio a cenários menos estruturados.

Para a educação médica, a consequência é metodológica: não basta medir a correção de uma resposta final. É necessário observar a qualidade da justificativa, a identificação de dados ausentes, a revisão de hipóteses e a capacidade de transferência do aprendizado para situações novas. Uma ferramenta pode apoiar o estudo de conceitos sem que esse apoio se converta automaticamente em habilidade clínica independente. Essa distinção orienta a leitura dos resultados reunidos por Zhao et al. (2026) e Wulandari et al. (2025).

### 2.6. A Interação Conversacional Como Recurso e Como Fonte de Risco

A interface em linguagem natural permite que estudantes formulem perguntas sucessivas, solicitem explicações alternativas e ajustem a complexidade do material ao seu nível de conhecimento. Em comparação com recursos estáticos, a possibilidade de diálogo favorece uma experiência de estudo adaptável. Contudo, a mesma fluidez pode produzir a impressão de interlocução especializada mesmo quando a resposta contém erros, simplificações ou referências inexistentes. O valor educacional da interação depende, portanto, de uma separação explícita entre clareza expositiva e confiabilidade factual (Zhao et al., 2026; Izquierdo-Condoy et al., 2025).

Uma aplicação coerente com essa limitação é tratar a resposta como objeto de investigação. O estudante pode solicitar hipóteses alternativas, identificar afirmações que necessitam de comprovação e confrontar a explicação com o conteúdo estudado. Nesse arranjo, a conversação não encerra o trabalho intelectual: ela oferece material para exercitar verificação e argumentação. Quando a interação termina na aceitação da primeira resposta, perde-se justamente o componente reflexivo que as metodologias ativas procuram desenvolver (Jochem, 2026; Wulandari et al., 2025).

### 2.7. A Construção de Casos no PBL e o Controle dos Objetivos de Aprendizagem

A geração de vinhetas clínicas pode auxiliar a diversificação de cenários e a adaptação de problemas aos objetivos de cada sessão. Entretanto, a elaboração de um caso educativo requer mais do que

coerência narrativa. É necessário decidir quais informações devem ser reveladas em cada etapa, que incertezas merecem discussão e quais erros comuns podem ser explorados de forma segura. Se o caso fornecer de imediato todos os elementos necessários à solução, o estudante terá menos oportunidades de investigar e formular perguntas, enfraquecendo o propósito do PBL (Jochem, 2026).

A mediação docente deve assegurar que a sequência do problema preserve espaço para busca independente, confronto entre explicações e síntese coletiva. A inteligência artificial pode ser empregada na preparação preliminar de materiais, mas o tutor permanece responsável por validar a consistência clínica e a pertinência pedagógica. Essa divisão de funções permite aproveitar a flexibilidade da ferramenta sem transferir a ela a definição do que constitui aprendizagem adequada (Jochem, 2026; Zhao et al., 2026).

### 2.8. PBL, Trabalho Colaborativo e Responsabilidade Pela Argumentação

As sessões de aprendizagem baseada em problemas valorizam a construção coletiva do raciocínio. Quando uma resposta gerada automaticamente passa a ser apresentada como solução pronta, os participantes podem reduzir a discussão das premissas que a sustentam. O risco não se restringe à presença de erros factuais: mesmo uma resposta correta pode abreviar a explicitação de dúvidas e a negociação argumentativa entre colegas. O ganho de velocidade, nesse caso, pode coexistir com uma perda de profundidade na atividade formativa (Jochem, 2026; Izquierdo-Condoy et al., 2025).

Uma integração mais consistente pressupõe que o grupo registre suas hipóteses antes de consultar a ferramenta e que, posteriormente, examine convergências e divergências. A comparação entre respostas torna visível o percurso do pensamento e oferece ao docente elementos para identificar dificuldades conceituais. A tecnologia passa a funcionar como contraponto a uma investigação já iniciada, preservando o protagonismo do estudante na formulação das questões (Wulandari et al., 2025; Jochem, 2026).

### 2.9. Simulação de Anamnese e Feedback Formativo

Pacientes virtuais permitem repetir entrevistas, reformular perguntas e experimentar sequências distintas de coleta de dados. Esse potencial é particularmente pertinente ao treinamento inicial de organização da anamnese, quando o aluno precisa desenvolver fluência na identificação de queixas, antecedentes e informações relevantes. A possibilidade de praticar sem expor pacientes reais a abordagens ainda imaturas constitui vantagem pedagógica descrita nas revisões de Zhao et al. (2026) e Wulandari et al. (2025).

O feedback automatizado, entretanto, deve ser analisado criticamente. Uma avaliação textual pode apontar omissões na sequência de perguntas, mas não equivale necessariamente à apreciação humana de postura, escuta, silêncio, empatia e adequação cultural. Por isso, a simulação generativa é mais bem compreendida como etapa preparatória, articulada a observação docente e experiências clínicas presenciais. A qualidade da prática não depende apenas do número de interações realizadas, mas da pertinência do retorno recebido e da capacidade do estudante de incorporá-lo (Xie; Zhang; Xiao, 2026).

### 2.10. Comunicação Clínica e Limites da Representação de Empatia

O uso de personagens virtuais para ensaiar conversas difíceis pode oferecer um espaço para experimentar diferentes formulações e reconhecer efeitos possíveis da linguagem. Ainda assim, a produção de frases empáticas não demonstra experiência emocional nem compreensão integral da situação vivida por uma pessoa. O ensino da comunicação clínica exige perceber reações não verbais, ajustar o ritmo da entrevista e responder às singularidades de cada paciente, aspectos que não podem ser inferidos apenas da qualidade de um diálogo escrito (Wulandari et al., 2025; Zhao et al., 2026).

A implicação pedagógica é evitar que a familiaridade com simulações seja tomada como substituto de relações reais. O aluno deve ser incentivado a refletir sobre o que o ambiente virtual representa adequadamente e o que permanece fora dele. Essa distinção ajuda a proteger a dimensão humanística da formação, sem negar a utilidade de exercícios preliminares de comunicação e estruturação da consulta (Xie; Zhang; Xiao, 2026).

### 2.11. Alucinações e Aparência de Autoridade

A apresentação de informações incorretas com linguagem segura constitui um risco singular em ambientes de aprendizagem. O estudante iniciante pode não dispor de repertório suficiente para distinguir uma explicação plausível de uma explicação correta. A presença de citações fabricadas intensifica o problema, pois confere aparência documental a afirmações que não foram verificadas. O desafio educacional consiste em formar hábitos de checagem que

não dependam apenas da percepção subjetiva de confiança (Izquierdo-Condoy et al., 2025; Zhao et al., 2026).

Uma resposta produzida por inteligência artificial deve ser tratada como material provisório até que suas proposições relevantes sejam confrontadas com fontes adequadas. Na formação clínica, esse procedimento possui valor adicional: ensina a separar informação, evidência e decisão. O exercício de identificar afirmações verificáveis, localizar contradições e explicar por que uma recomendação deve ser aceita ou rejeitada fortalece competências que continuam necessárias mesmo quando o conteúdo inicial é produzido rapidamente (Xie; Zhang; Xiao, 2026; Jochem, 2026).

### 2.12. Vieses, Representatividade e Interpretação de Cenários Clínicos

Os vieses algorítmicos discutidos no manuscrito evidenciam que a aparência de neutralidade tecnológica pode ocultar desigualdades de representação. Em situações de ensino, esse problema se manifesta quando exemplos, hipóteses ou prioridades clínicas reproduzem padrões históricos sem explicitar suas limitações. A análise crítica deve perguntar quais grupos estão presentes no cenário, quais características foram presumidas e se a resposta apresenta alternativas compatíveis com a diversidade de pacientes (Xie; Zhang; Xiao, 2026; Izquierdo-Condoy et al., 2025).

A formação em IA não pode restringir-se ao reconhecimento abstrato de que vieses existem. É necessário exercitar a comparação de respostas diante de variações relevantes dos casos, sempre com supervisão e sem pressupor que diferenças observadas representem automaticamente discriminação causal comprovada. O objetivo é

desenvolver vigilância crítica sobre possíveis assimetrias e fortalecer a responsabilidade do profissional por decisões individualizadas (Zhao et al., 2026).

### 2.13. Desigualdades Linguísticas e Contexto da Formação Brasileira

O desempenho variável dos modelos conforme o idioma merece atenção em currículos ministrados em português. A clareza da redação não elimina a possibilidade de imprecisões terminológicas, traduções inadequadas ou interpretações pouco sensíveis ao contexto local. Assim, a utilização de explicações em língua portuguesa deve ser acompanhada de verificação conceitual, sobretudo quando envolve nomenclaturas clínicas e recomendações assistenciais (Xie; Zhang; Xiao, 2026).

A questão linguística também afeta a equidade de acesso. Estudantes com maior domínio de idiomas estrangeiros podem encontrar mais facilidade para confrontar diferentes formulações, enquanto outros dependem da tradução oferecida pela própria ferramenta. A resposta institucional não deve ser presumir equivalência de desempenho entre línguas, mas estabelecer critérios de revisão e atividades que desenvolvam leitura crítica dos conteúdos gerados (Izquierdo-Condoy et al., 2025; Zhao et al., 2026).

## 3. METODOLOGIA

Trata-se de uma revisão bibliográfica narrativa, de caráter descritivo e analítico, destinada a sintetizar e discutir criticamente as evidências científicas sobre o uso da inteligência artificial generativa na educação médica, analisando seus benefícios, riscos e impactos na formação clínica e no raciocínio dos estudantes. A abordagem

narrativa foi escolhida por permitir a integração crítica de estudos de escopo, ensaios clínicos, revisões sistemáticas e artigos de reflexão conceitual, focando na aplicabilidade pedagógica e organizacional do tema sem a pretensão de estimar um efeito estatístico combinado.

A estratégia de busca contemplou publicações indexadas em bases de dados científicas de referência na saúde e educação médica, incluindo PubMed/MEDLINE, Europe PMC, Scopus, Web of Science, Google Scholar e o Journal of Medical Internet Research (JMIR). Foram utilizados, nos idiomas português e inglês, descritores e termos compostos combinados de forma livre, tais como “inteligência artificial generativa”, “modelos de linguagem de grande escala”, “ChatGPT”, “educação médica”, “raciocínio clínico”, “aprendizagem baseada em problemas”, “autonomia cognitiva”, “Generative Artificial Intelligence”, “Large Language Models”, “Medical Education”, “Clinical Reasoning” e “Problem-Based Learning”.

Priorizou-se a literatura científica recente publicada entre 2025 e 2026, de modo a capturar o estado da arte e as transformações decorrentes do surgimento de modelos avançados de linguagem. A seleção do acervo foi qualitativa e intencional, orientada pela relevância temática, rigor descritivo e alinhamento aos objetivos do estudo. Para compor a base analítica principal do trabalho, foram selecionados e examinados criticamente cinco artigos de elevada robustez teórica e empírica: a revisão de escopo de Zhao et al. (2026), o ensaio analítico de Izquierdo-Condoy et al. (2025), a revisão sobre competências clínicas de Xie, Zhang e Xiao (2026), a revisão sobre metodologias ativas de Jochem (2026) e a revisão sistemática narrativa de Wulandari et al. (2025).

A organização dos achados e a discussão do material fundamentaram-se em eixos temáticos integrados: a evolução dos Modelos de Linguagem de Grande Escala e o viés das avaliações formais; a incorporação da tecnologia na Aprendizagem Baseada em Problemas (PBL); o desenvolvimento do raciocínio clínico e a simulação de pacientes virtuais ancorados em teorias pedagógicas; as limitações técnicas ligadas a alucinações e vieses algorítmicos; o paradoxo entre potencialização cognitiva e atrofia de habilidades (deskilling); o papel do suporte pedagógico (scaffolding); a gestão do tempo e a preservação do cuidado humanizado; e a necessidade de institucionalização de matrizes de competência em IA.

Por se tratar de uma revisão narrativa, o estudo não realizou metanálise, avaliação quantitativa combinada ou aplicação do protocolo PRISMA para mapeamento exaustivo. Esta limitação metodológica é reconhecida na interpretação das evidências, ressaltando que o texto entrega uma apreciação analítica, qualitativa e contextualizada do estado atual da inteligência artificial na formação médica.

### 3.1. Delimitação do Objeto e Coerência com o Desenho Narrativo

O objeto desta revisão compreende usos educacionais da inteligência artificial generativa e suas repercussões potenciais sobre a aprendizagem e a formação clínica. A opção por uma abordagem narrativa permite relacionar resultados de estudos com desenhos distintos a questões pedagógicas transversais, como autonomia, supervisão e segurança. Essa escolha, porém, não autoriza interpretar a síntese como estimativa quantitativa de eficácia nem como levantamento exaustivo de toda a produção científica disponível. O alcance das conclusões deve permanecer proporcional

ao conjunto de cinco referências efetivamente apresentado no manuscrito.

A análise organiza o conteúdo em torno de perguntas interpretativas: que tarefa foi delegada à tecnologia, qual participação cognitiva permaneceu com o estudante, que tipo de avaliação foi empregado e quais limitações foram reconhecidas pelos autores? Essas perguntas não constituem uma nova etapa de coleta de dados, mas explicitam o modo de leitura crítica do acervo já selecionado. Tal procedimento favorece a transparência argumentativa sem atribuir à revisão narrativa características de uma revisão sistemática.

### 3.2. Heterogeneidade das Fontes e Cautela Inferencial

O acervo inclui revisões de escopo, sínteses narrativas e análises críticas, cujos propósitos e critérios de seleção não são idênticos. A comparação direta entre conclusões exige distinguir descrições de experiências educacionais, interpretações teóricas e resultados de avaliações específicas. Não seria metodologicamente adequado somar indicadores extraídos de contextos diferentes como se representassem uma amostra homogênea. A discussão, portanto, prioriza convergências conceituais e identifica pontos em que a evidência disponível não permite inferências fortes.

Também é importante evitar a dupla contagem argumentativa de achados que podem ter sido retomados em mais de uma revisão. Quando dois trabalhos comentam uma mesma tendência, isso não implica necessariamente duas demonstrações independentes. Por esse motivo, as referências são mobilizadas para sustentar

interpretações delimitadas, e não para produzir uma contagem artificial de estudos favoráveis ou contrários à tecnologia.

### 3.3. Critérios de Interpretação e Limitações da Síntese

A leitura crítica considera a diferença entre resultados imediatos de satisfação ou desempenho em testes e efeitos duradouros sobre raciocínio clínico, comportamento profissional ou segurança do paciente. Essa separação é necessária porque os desfechos não são intercambiáveis. Uma experiência avaliada positivamente pelos alunos pode ser pedagogicamente útil sem demonstrar retenção de conhecimento; da mesma forma, uma melhora em tarefa simulada não comprova transferência para atendimento real (Zhao et al., 2026; Xie; Zhang; Xiao, 2026).

A revisão não apresenta dados individuais de participantes, reanálise estatística ou novos resultados experimentais. As proposições adicionais desenvolvidas neste texto correspondem a interpretação crítica das referências já incluídas e devem ser lidas como tal. Essa delimitação impede que sugestões pedagógicas sejam confundidas com intervenções empiricamente validadas e preserva a coerência entre método, evidências e conclusões.

## 4. RESULTADOS E DISCUSSÕES OU ANÁLISE DOS DADOS

### 4.1. O Paradoxo do "Deskilling" Vs. Potencialização Cognitiva

A análise transversal da literatura revela que a inteligência artificial generativa atua como uma faca de dois gumes no desenvolvimento intelectual do estudante de medicina (Izquierdo-Condoy et al., 2025). De um lado, a ferramenta oferece uma capacidade sem precedentes de síntese bibliográfica, explicação instantânea de temas complexos

e geração de cenários de treino, configurando-se como um valioso "potencializador cognitivo" (cognitive enhancer) (Izquierdo-Condoy et al., 2025; Wulandari et al., 2025). De outro lado, a disponibilidade irrestrita de respostas articuladas cria a tentação do "descarregamento cognitivo" (cognitive offloading) contínuo, no qual o discente delega ao algoritmo tarefas analíticas essenciais, correndo o risco de sofrer atrofia de habilidades críticas (deskilling) e estagnação intelectual (Izquierdo-Condoy et al., 2025; Zhao et al., 2026).

Izquierdo-Condoy et al. (2025) destacam evidências empíricas nas quais o uso habitual e não orientado de IAG correlacionou-se negativamente com os escores de pensamento crítico em estudantes, demonstrando que a facilidade de obter resumos prontos induz a uma atitude de passividade mental. Em um estudo revisado por esses autores, a dependência excessiva de sistemas de IA associou-se a uma redução significativa na capacidade autonômica de resolução de problemas (tamanho do efeito de -0,41) (Izquierdo-Condoy et al., 2025). O problema não reside no acesso à informação, mas na eliminação do "esforço produtivo" (productive struggle) — o processo tensional de confrontar a incerteza, elaborar hipóteses e cometer erros controlados, indispensável para a consolidação da autonomia cognitiva (Izquierdo-Condoy et al., 2025; Xie; Zhang; Xiao, 2026).

A Tabela 1 sintetiza as principais diferenças conceituais e operacionais entre o uso da IAG como potencializador cognitivo e o seu uso como indutor de atrofia cognitiva (deskilling).

**Tabela 1.** Comparativo entre Potencialização Cognitiva e Deskilling no uso da IA Generativa na Educação Médica

| Dimensão | Potencialização Cognitiva (Cognitive Enhancer) | Atrofia Cognitiva (Deskilling / Passividade) |
|---|---|---|
| Postura do Estudante | Ativa, questionadora, reflexiva e autorregulada (Izquierdo-Condoy et al., 2025; Wulandari et al., 2025). | Passiva, acoplada, focada em obter respostas prontas (Izquierdo-Condoy et al., 2025; Jochem, 2026). |
| Papel da IA | Parceira de diálogo, geradora de hipóteses e plataforma de teste (Wulandari et al., 2025). | Substituta do julgamento crítico e da investigação autônoma (Izquierdo-Condoy et al., 2025). |
| Processo de Aprendizagem | Preserva o "esforço produtivo", encorajando a checagem em fontes primárias (Xie; Zhang; Xiao, 2026). | Elimina o esforço analítico via descarregamento cognitivo (offloading) (Izquierdo-Condoy et al., 2025). |
| Impacto na Autonomia | Fortalece a metacognição e a capacidade de tomada de decisão fundamentada (Izquierdo-Condoy et al., 2025). | Debilita a estrutura de raciocínio independente e a confiança sem a tecnologia (Izquierdo-Condoy et al., 2025). |
| Manejo de Erros/Alucinações | Auditoria crítica das respostas e identificação de vieses pelo aluno (Jochem, 2026; Xie; Zhang; Xiao, 2026). | Aceitação acrítica de informações falsas ou enviesadas do algoritmo (Zhao et al., 2026; Jochem, 2026). |

*Fonte: Elaboração própria com base em Izquierdo-Condoy et al. (2025), Wulandari et al. (2025), Xie, Zhang e Xiao (2026), Jochem (2026) e Zhao et al. (2026).*

Dessa forma, a literatura é categórica: a IAG só atua como potencializadora quando associada ao treinamento em autorregulação e letramento digital, no qual os alunos são instruídos a utilizar prompts de verificação de viés, auditar as respostas

recebidas e cruzar dados com diretrizes clínicas consolidadas (Izquierdo-Condoy et al., 2025; Jochem, 2026).

### 4.2. O Impacto do "Scaffolding" Pedagógico na Prática Clínica

Outro achado de grande relevância diz respeito à condicionalidade do benefício da IAG. A abrangente revisão de escopo conduzida por Zhao et al. (2026), que analisou 153 relatos de implementação prática da IAG no ensino médico de graduação, demonstrou que ganhos de aprendizado não são uma propriedade intrínseca da ferramenta, mas dependem inteiramente do desenho instrucional e da mediação pedagógica (scaffolding).

Ensaios controlados e comparativos mapeados por Zhao et al. (2026) e Xie, Zhang e Xiao (2026) apontam que os melhores resultados em tomada de história clínica, raciocínio diagnóstico e comunicação ocorreram quando a IAG foi inserida em tarefas delimitadas, com dados de conhecimento curados (retrouvada/RAG) e sob a supervisão ativa de preceptores humanos. Em contrapartida, estudos em que a tecnologia foi disponibilizada sem estruturação pedagógica ou como substituta de atividades humanas consolidadas registraram resultados nulos ou até desfavoráveis, incluindo desaceleração da tomada de decisão em equipe e maior ansiedade nos alunos (Zhao et al., 2026).

Um dado crucial revelado pela pesquisa de Zhao et al. (2026) e reforçado por Xie, Zhang e Xiao (2026) é a ineficácia das simples mensagens de aviso (warning labels), como a frase padrão "O ChatGPT pode cometer erros". Experimentos comportamentais demonstraram que o conhecimento prévio da possibilidade de erro não impede que estudantes sofram do viés de automação — a

tendência de confiar excessivamente nas sugestões do algoritmo e alterar respostas corretas para alinhá-las a conselhos incorretos da IA (Zhao et al., 2026; Xie; Zhang; Xiao, 2026).

Isso reforça que o scaffolding pedagógico não pode ser passivo. Os docentes precisam criar "estruturas de contenção pedagógica", tais como exigir que o aluno apresente o histórico de prompts utilizados, justifique por que aceitou ou rejeitou uma recomendação do algoritmo e aponte eventuais contradições em relação a diretrizes clínicas oficiais (Zhao et al., 2026; Izquierdo-Condoy et al., 2025).

### 4.3. Otimização de Tempo e Foco na Humanização

Um dos argumentos mais frequentes em favor da adoção da IAG na formação médica é a sua capacidade de otimizar a gestão do tempo acadêmico (Izquierdo-Condoy et al., 2025; Xie; Zhang; Xiao, 2026). Ao automatizar tarefas burocráticas e repetitivas — como a formatação inicial de trabalhos, a organização de cronogramas de estudo, a criação de resumos de grandes volumes de dados e a elaboração de notas de evolução simuladas —, a IA pode reduzir significativamente a sobrecarga administrativa que acomete os estudantes durante o internato e as rotações clínicas (Xie; Zhang; Xiao, 2026; Izquierdo-Condoy et al., 2025).

A questão central levantada pelos debatedores da área é se o tempo economizado pela automação algorítmica será efetivamente revertido para o aprimoramento da relação médico-paciente, para a prática do exame físico beira-leito e para o desenvolvimento da empatia e da escuta qualificada (Xie; Zhang; Xiao, 2026; Zhao et al., 2026). Como alertam Xie, Zhang e Xiao (2026) e Wulandari et al. (2025), a tecnologia não possui capacidade para vivenciar o

sofrimento humano, demonstrar compaixão genuína ou compreender as sutilezas éticas e culturais inerentes ao cuidado em saúde.

Se o ganho de eficiência gerado pela IAG for utilizado para afastar o estudante do contato direto com o paciente, promovendo o refúgio atrás de telas digitais, haverá um prejuízo incalculável na formação da identidade profissional e humanística do médico (Xie; Zhang; Xiao, 2026; Wulandari et al., 2025). A mentoria exercida por professores e preceptores experientes permanece, portanto, insubstituível na transmissão do saber tácito, na modelagem de atitudes profissionais e na mediação de dilemas bioéticos beira-leito — dimensões que nenhum modelo generativo é capaz de reproduzir (Wulandari et al., 2025; Xie; Zhang; Xiao, 2026).

### 4.4. Necessidade de Validação e Matrizes de Competência

Por fim, os achados da literatura convergem para a constatação de que o campo da IAG na educação médica carece de estudos longitudinais de alta qualidade metodológica (Zhao et al., 2026; Xie; Zhang; Xiao, 2026). A esmagadora maioria das publicações atuais avalia apenas desfechos imediatos, como a reação de satisfação dos alunos ou o ganho de conhecimento em testes aplicados logo após a intervenção (Zhao et al., 2026). Praticamente não existem dados sobre a retenção do aprendizado no longo prazo, a transferência de habilidades para cenários com pacientes reais ou os impactos diretos em indicadores de saúde e segurança assistencial (Zhao et al., 2026; Xie; Zhang; Xiao, 2026).

Diante da irreversibilidade da presença da IA nos ecossistemas de saúde, autores como Xie, Zhang e Xiao (2026) e Izquierdo-Condoy et

al. (2025) defendem a urgente institucionalização de Matrizes de Competência em IA estruturadas em níveis progressivos ao longo do currículo médico:

1. Nível Básico (Letramento em IA): Domínio de engenharia de prompts, compreensão dos mecanismos probabilisticos dos LLMs, conscientização sobre privacidade de dados e identificação do risco de alucinações (Xie; Zhang; Xiao, 2026).

2. Nível Intermediário (Análise Crítica e Aplicação Clínica): Capacidade de auditar criticamente os resultados algorítmicos, detectar vieses raciais, de gênero ou socioeconômicos embutidos, e integrar ferramentas de suporte à decisão nas rotações clínicas sob supervisão (Xie; Zhang; Xiao, 2026).

3. Nível Avançado (Governança e Liderança): Formação em governança ética, avaliação de impacto de novas tecnologias médicas, gestão de riscos de privacidade e participação no desenho de soluções tecnológicas voltadas à saúde (Xie; Zhang; Xiao, 2026).

O objetivo final da formação médica na era da inteligência artificial não é produzir médicos que evitem a tecnologia ou que a sigam cegamente, mas sim formar profissionais capacitados para liderar, auditar e direcionar os algoritmos, garantindo que a inovação tecnológica permaneça rigorosamente subordinada ao julgamento humano e à segurança do paciente (Xie; Zhang; Xiao, 2026; Izquierdo-Condoy et al., 2025).

### 4.5. A Autonomia Cognitiva Como Desfecho Formativo

A autonomia cognitiva não corresponde à recusa de instrumentos de apoio, mas à capacidade de formular problemas, avaliar alternativas e assumir responsabilidade pelas conclusões. Sob essa perspectiva, o uso de inteligência artificial pode ser compatível com aprendizagem independente quando o estudante mantém controle sobre perguntas, critérios de verificação e decisões. O risco surge quando a ferramenta passa a determinar o percurso do raciocínio sem que o aluno compreenda suas premissas (Izquierdo-Condoy et al., 2025).

A avaliação desse domínio exige observar o comportamento do estudante em diferentes momentos da tarefa. Importa saber se ele identifica informações faltantes antes de solicitar uma resposta, se consegue apontar fragilidades na explicação recebida e se sustenta suas conclusões sem depender integralmente do sistema. Essas dimensões são mais informativas sobre a formação profissional do que a simples frequência de uso da ferramenta (Wulandari et al., 2025; Xie; Zhang; Xiao, 2026).

### 4.6. Descarregamento Cognitivo e Distribuição das Tarefas

O descarregamento cognitivo não é necessariamente inadequado: recursos externos podem liberar atenção para atividades mais complexas. Na educação médica, a questão decisiva é identificar quais operações podem ser apoiadas sem comprometer competências que ainda estão em formação. Organizar material de estudo ou propor uma estrutura inicial de revisão é diferente de delegar integralmente a interpretação de um caso e a seleção de condutas. O mesmo ganho de eficiência pode, portanto, ter implicações distintas conforme a habilidade que se pretende desenvolver (Izquierdo-Condoy et al., 2025).

Uma organização pedagógica prudente distingue etapas de produção independente, comparação assistida e reflexão final. Primeiro, o estudante registra suas hipóteses; depois, utiliza a ferramenta para confrontá-las; por fim, explica o que manteve ou modificou e por quê. Essa sequência preserva o esforço de elaboração e transforma a assistência automatizada em oportunidade de metacognição, sem pressupor que todo uso frequente provoque atrofia de habilidades (Jochem, 2026; Wulandari et al., 2025).

### 4.7. Scaffolding Como Estrutura de Decisão Pedagógica

O suporte pedagógico estruturado pode ser compreendido como um conjunto de limites, perguntas e critérios de avaliação que orientam a interação com a ferramenta. Não se resume a oferecer instruções de uso; envolve definir objetivos de aprendizagem, momentos permitidos de consulta e evidências de que o estudante compreendeu o conteúdo. Essa estrutura explica por que experiências aparentemente semelhantes de integração tecnológica podem produzir resultados educacionais diferentes (Zhao et al., 2026).

No ensino de casos, o docente pode exigir a explicitação das hipóteses antes da consulta, solicitar comparação entre alternativas e avaliar a qualidade da justificativa final. Em exercícios de comunicação, pode combinar simulações automatizadas com observação humana. Em tarefas de síntese, pode distinguir a organização textual da verificação científica. O princípio comum é manter a responsabilidade pelo aprendizado no estudante e pelo desenho da atividade na instituição (Xie; Zhang; Xiao, 2026; Jochem, 2026).

### 4.8. Porque Alertas Genéricos São Insuficientes?

A advertência de que sistemas generativos podem errar é relevante, mas não constitui, isoladamente, um método de prevenção do viés de automação. Quando uma resposta é apresentada com segurança e riqueza de detalhes, o usuário pode atribuir-lhe credibilidade superior à justificável. O reconhecimento abstrato dessa possibilidade não garante que o estudante identifique erros concretos durante uma tarefa complexa (Zhao et al., 2026; Xie; Zhang; Xiao, 2026).

Medidas pedagógicas mais substantivas incluem solicitar a identificação de afirmações centrais, exigir justificativas independentes e promover discussões sobre respostas discordantes. Essas práticas deslocam a atenção da confiança no estilo do texto para a análise das evidências e do encadeamento argumentativo. Trata-se de uma proposta de organização didática coerente com os riscos apontados pelas referências, não de um protocolo cuja eficácia tenha sido demonstrada neste manuscrito.

### 4.9. Avaliação Formativa, Somativa e Uso Declarado da Tecnologia

A presença de ferramentas generativas modifica o significado de certas atividades avaliativas. Um texto bem redigido pode refletir habilidade de organização, assistência automatizada ou combinação de ambas, sem revelar diretamente o conhecimento do estudante. Por isso, atividades que pretendem medir raciocínio clínico precisam observar etapas do processo, como a formulação de hipóteses, a interpretação de novos dados e a defesa oral de decisões. A tecnologia não elimina a necessidade de avaliar competências; torna

mais importante explicitar o que cada instrumento de avaliação pretende medir (Xie; Zhang; Xiao, 2026).

A transparência sobre o uso de IA pode contribuir para distinguir apoio legítimo de substituição indevida da atividade acadêmica. Entretanto, exigir declaração de uso só terá sentido se houver regras claras, proporcionais aos objetivos educacionais e aplicáveis de forma consistente. A finalidade principal não deve ser punir o contato com ferramentas disponíveis, mas preservar a validade da avaliação e oferecer condições para que o estudante demonstre aprendizagem própria (Izquierdo-Condoy et al., 2025; Zhao et al., 2026).

### 4.10. Competências Progressivas e Adequação Ao Estágio Formativo

O domínio de inteligência artificial na educação médica não deve ser tratado como habilidade única. Em estágios iniciais, é prioritário compreender o funcionamento probabilístico dos modelos, reconhecer a possibilidade de erro e desenvolver hábitos básicos de verificação. Em fases posteriores, torna-se pertinente analisar vieses, discutir aplicação clínica supervisionada e avaliar consequências éticas. A progressão proposta no manuscrito, inspirada em Xie, Zhang e Xiao (2026), oferece uma estrutura conceitual para organizar objetivos curriculares.

Essa progressão não implica que estudantes mais avançados estejam imunes a respostas incorretas. Ao contrário, a complexidade das tarefas aumenta a necessidade de julgamento contextual. A competência madura consiste em decidir quando a ferramenta agrega valor, quando é inadequada e que controles devem

acompanhar seu uso. A formação, portanto, deve integrar conhecimento técnico, prudência clínica e capacidade de justificar limites de aplicação (Izquierdo-Condoy et al., 2025).

### 4.11. A Supervisão Docente Como Mediação Epistemológica

O professor não atua apenas como fiscal de respostas automatizadas. Sua função inclui ajudar o estudante a distinguir afirmações, argumentos e evidências; reconhecer ambiguidades; e compreender por que uma hipótese é mais plausível do que outra. Esse tipo de mediação é particularmente importante quando a ferramenta apresenta uma narrativa convincente, mas insuficientemente fundamentada. A experiência docente fornece contexto para que o aluno aprenda a avaliar não só a correção aparente, mas a qualidade do processo de decisão (Wulandari et al., 2025).

A incorporação de IA também demanda que docentes revisitem estratégias de ensino e avaliação. Não é necessário pressupor domínio irrestrito de todas as ferramentas, mas é fundamental compreender seus limites educacionais e definir situações em que o contato com pacientes, a discussão presencial e a prática supervisionada permanecem centrais. A integração curricular deve fortalecer a relação pedagógica, e não deslocá-la para um sistema que não assume responsabilidade profissional (Zhao et al., 2026; Xie; Zhang; Xiao, 2026).

### 4.12. O Tempo Economizado e a Qualidade da Formação Clínica

A redução do tempo empregado em tarefas repetitivas é um benefício potencial, mas o valor pedagógico desse ganho depende de sua destinação. Se a economia de esforço permitir maior

participação em discussão de casos, prática de exame físico e observação de atendimentos, poderá favorecer experiências formativas importantes. Se, ao contrário, ampliar apenas a produção de materiais sem aprofundamento, a eficiência operacional não se converterá necessariamente em aprendizagem (Izquierdo-Condoy et al., 2025; Xie; Zhang; Xiao, 2026).

Essa distinção é particularmente relevante durante atividades clínicas, em que a formação depende de exposição supervisionada a situações reais. A automatização de etapas documentais simuladas não substitui o encontro com o paciente, a escuta das preocupações e a interpretação dos achados do exame físico. O currículo deve tratar o tempo liberado como oportunidade a ser planejada, e não como benefício educacional automaticamente realizado (Wulandari et al., 2025).

### 4.13. Humanização e Identidade Profissional

A identidade médica se forma também pela observação de profissionais experientes e pelo exercício gradual de responsabilidades. Ferramentas capazes de reproduzir diálogos não substituem a experiência de lidar com sofrimento, vulnerabilidade, expectativas e dilemas éticos em encontros reais. O ensino da humanização requer situações em que o estudante aprenda a reconhecer limites de sua própria atuação e a responder a necessidades que não se reduzem a informações clínicas (Wulandari et al., 2025; Xie; Zhang; Xiao, 2026).

Por essa razão, a discussão sobre IA deve evitar uma falsa oposição entre inovação e cuidado humanizado. O problema não é a presença de ferramentas digitais, mas sua posição na organização do trabalho

educativo. Quando utilizadas para preparar atividades, gerar oportunidades de treino e apoiar reflexão posterior, elas podem coexistir com a centralidade da mentoria humana. A substituição indiscriminada de experiências presenciais, entretanto, exigiria evidências que não são oferecidas pelo conjunto de estudos analisado (Zhao et al., 2026).

### 4.14. Privacidade, Casos Simulados e Responsabilidade Institucional

A utilização de ferramentas generativas em ambientes de formação suscita questões de confidencialidade e responsabilidade. Embora o manuscrito se concentre em resultados educacionais, a proposta de matrizes de competência inclui atenção à privacidade e ao manejo ético de informações. A preparação de exercícios deve distinguir dados fictícios de informações provenientes de pacientes reais, evitando que a conveniência da ferramenta conduza ao compartilhamento inadequado de conteúdos sensíveis (Xie; Zhang; Xiao, 2026).

A responsabilidade por definir regras claras não pode ser transferida exclusivamente ao estudante. Instituições e preceptores precisam estabelecer limites de uso coerentes com os objetivos de ensino e com a proteção do paciente. A educação ética em IA envolve compreender que a produção de uma resposta por um sistema não elimina o dever humano de avaliar sua pertinência e suas consequências. Esse princípio articula governança, profissionalismo e segurança assistencial (Izquierdo-Condoy et al., 2025; Jochem, 2026).

### 4.15. Lacunas da Evidência e Risco de Extrapolação

As revisões analisadas ressaltam a predominância de avaliações de curto prazo, frequentemente baseadas em satisfação, desempenho imediato ou tarefas simuladas. Esses indicadores oferecem informações relevantes, mas não permitem concluir isoladamente que houve retenção duradoura, transferência para o cuidado real ou redução de riscos assistenciais. A interpretação dos resultados deve preservar essa hierarquia de desfechos e reconhecer a heterogeneidade das experiências relatadas (Zhao et al., 2026; Xie; Zhang; Xiao, 2026).

Também seria inadequado transformar observações de dependência cognitiva em afirmação de que qualquer uso de IA causa perda permanente de habilidades. As relações discutidas dependem do contexto, da frequência, do desenho instrucional e da forma de avaliação. Uma síntese equilibrada precisa reconhecer simultaneamente oportunidades promissoras e limites de inferência, evitando tanto entusiasmo tecnológico irrestrito quanto conclusões deterministas de prejuízo (Izquierdo-Condoy et al., 2025; Wulandari et al., 2025).

### 4.16. Proposta de Princípios para Implementação Curricular

A partir da discussão das cinco referências, é possível organizar princípios orientadores, sem apresentá-los como diretriz externa ou intervenção validada. O primeiro consiste em vincular o uso da tecnologia a objetivos de aprendizagem explícitos. O segundo é preservar momentos de raciocínio independente antes da consulta. O terceiro é exigir verificação de afirmações clínicas relevantes. O quarto é combinar feedback automatizado com supervisão humana. O quinto é avaliar competências em situações nas quais o

estudante precisa justificar suas decisões (Jochem, 2026; Zhao et al., 2026).

Esses princípios devem ser interpretados como desdobramentos analíticos do material revisado. Sua utilidade depende da adequação ao estágio do curso, à infraestrutura disponível e ao tipo de atividade. A adoção institucional requer ainda mecanismos de revisão periódica, pois a diversidade de modelos e de aplicações impede presumir que o desempenho observado em um contexto seja automaticamente reproduzido em outro (Xie; Zhang; Xiao, 2026).

### 4.17. Questões Prioritárias para Investigações Futuras

A literatura apresentada aponta a necessidade de avaliar aprendizagem sustentada ao longo do tempo e desempenho sem assistência automatizada. Estudos futuros poderiam distinguir situações de consulta livre, uso orientado e ausência de ferramenta, acompanhando não apenas respostas corretas, mas a qualidade das justificativas e a capacidade de reconhecer erros. Essas possibilidades são propostas de agenda científica derivadas das lacunas discutidas, não resultados de investigações realizadas neste artigo (Zhao et al., 2026).

Outra prioridade é examinar como diferentes condições institucionais, linguísticas e pedagógicas influenciam o uso da tecnologia. A formação médica brasileira apresenta contextos variados de ensino e assistência, de modo que a transferência direta de experiências descritas em outros ambientes requer cautela. Investigações contextualizadas poderão esclarecer que arranjos de supervisão e avaliação preservam melhor a autonomia cognitiva e a

segurança do paciente (Xie; Zhang; Xiao, 2026; Wulandari et al., 2025).

## 5. CONCLUSÃO

A integração da inteligência artificial generativa na educação médica representa uma mudança paradigmática irreversível, oferecendo oportunidades instrucionais inéditas ao mesmo tempo em que impõe desafios estruturais à formação dos futuros médicos. A literatura científica demonstra que a tecnologia atua como um valioso recurso educacional complementar, destacando-se na simulação de pacientes virtuais, na customização de materiais instrucionais, no suporte a metodologias ativas como a Aprendizagem Baseada em Problemas (PBL) e na criação de cenários seguros para a prática deliberada e repetitiva do raciocínio diagnóstico. Contudo, o uso passivo, acoplado e desprovido de mediação pedagógica constitui uma ameaça direta à autonomia cognitiva do discente, favorecendo o descarregamento cognitivo (cognitive offloading), a assimilação acrítica de alucinações algorítmicas e vieses históricos, e a consequente atrofia de habilidades analíticas fundamentais (deskilling).

Constata-se que os benefícios educacionais da inteligência artificial não são automáticos ou garantidos pela simples disponibilização da ferramenta; eles dependem intrinsecamente de um suporte pedagógico estruturado (scaffolding), do desenho criterioso das atividades e da supervisão ativa de preceptores humanos, uma vez que simples mensagens de alerta mostram-se ineficazes para evitar o viés de automação entre os estudantes. Paralelamente, a otimização de tempo proporcionada pela automação de tarefas burocráticas e administrativas deve ser intencionalmente

redirecionada para o fortalecimento da relação médico-paciente, para o aprimoramento do exame físico e para o cultivo da empatia beira-leito, dimensões que permanecem sob a mentoria insubstituível do corpo docente.

Torna-se premente a incorporação de Matrizes de Competência em Inteligência Artificial nos currículos das faculdades de medicina, de modo a capacitar os futuros profissionais a auditar, questionar e liderar a utilização dessas tecnologias de forma ética, crítica e focada no cuidado centrado na pessoa. Por fim, reconhece-se a necessidade de pesquisas pragmáticas e estudos longitudinais no contexto educacional brasileiro, fundamentais para avaliar o impacto real do uso da inteligência artificial generativa na retenção do conhecimento a longo prazo, no desempenho clínico à beira do leito e nos desfechos assistenciais ao longo da carreira médica.

### 5.1. Síntese Interpretativa e Alcance das Conclusões

A análise do material selecionado sustenta uma conclusão condicional: o potencial educacional da inteligência artificial generativa depende da maneira como ela é incorporada às tarefas e da qualidade da mediação pedagógica. Sua capacidade de produzir explicações, simular diálogos e organizar conteúdos não equivale, por si só, à formação de raciocínio clínico independente. O valor de cada aplicação precisa ser apreciado em relação ao objetivo de aprendizagem, à necessidade de verificação e ao espaço preservado para a iniciativa do estudante (Zhao et al., 2026; Izquierdo-Condoy et al., 2025).

A revisão também evidencia limites relevantes do conhecimento disponível. A heterogeneidade das experiências e a concentração

em desfechos imediatos restringem afirmações sobre consequências duradouras para competência profissional e segurança assistencial. Portanto, a adoção responsável da tecnologia deve combinar abertura à inovação, critérios de avaliação e compromisso contínuo com a formação humanística. A responsabilidade clínica e educativa permanece humana, inclusive quando parte do trabalho preparatório é apoiada por sistemas generativos (Xie; Zhang; Xiao, 2026; Wulandari et al., 2025).

## REFERÊNCIAS BIBLIOGRÁFICAS


IZQUIERDO-CONDOY, Juan S. et al. Generative Artificial Intelligence in Medical Education: Enhancing Critical Thinking or Undermining Cognitive Autonomy? **Journal of Medical Internet Research,** Toronto, v. 27, e76340, p. 1-9, 2025. DOI: https://doi.org/10.2196/76340.

JOCHEM, Leticia. Inteligência Artificial Generativa na Aprendizagem Baseada em Problemas (PBL) na Educação Médica: evidências de uma revisão narrativa. **Arquivos Catarinenses de Medicina,** Florianópolis, v. 55, n. 4, Supl. 1, p. 133-134, out. 2026.

WULANDARI, Annastasya Nabila Elsa et al. ChatGPT as a Pedagogical Tool for Clinical Reasoning in Medical Education: A Systematic Narrative Review. **Journal of Technological Pedagogy and Educational Development,** Purwokerto, v. 2, n. 2, p. 12-28, 2025. DOI: https://doi.org/10.59247/jtped.v2i2.21.

XIE, Renxian; ZHANG, Beien; XIAO, Lifeng. Generative artificial intelligence in medical education: from knowledge assessment to clinical reasoning and professional competence. **Frontiers in Medicine,** Lausanne, v. 13, p. 1855759, 25 aug. 2026. DOI: https://doi.org/10.3389/fmed.2026.1855759.

ZHAO, Junsheng et al. Generative artificial intelligence and the transformation of medical education: a scoping review. **Frontiers in Education,** Lausanne, v. 11, p. 1907589, 21 sept. 2026. DOI: https://doi.org/10.3389/feduc.2026.1907589.

---

[1] Médica pela Faculdade de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[2] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[3] Discente do Curso Superior de Medicina da Faculdade Morgana Potrich (FAMP) Campus Mineiros. E-mail: acesse o artigo original para visualizar o e-mail

[4] Discente do Curso Superior de Medicina da Universidade de Rio Verde Campus Rio Verde. E-mail: acesse o artigo original para visualizar o e-mail

[5] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[6] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[7] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[8] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[9] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[10] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[11] Discente do Curso Superior de Medicina da Universidade Federal do Mato Grosso do Sul Campus Três Lagoas. E-mail: acesse o artigo original para visualizar o e-mail

[12] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[13] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[14] Discente do Curso Superior de Medicina do Centro Universitário Atenas Campus Paracatu. E-mail: acesse o artigo original para visualizar o e-mail

[15] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[16] Discente do Curso Superior de Medicina da Universidade Federal do Tocantins Campus Araguari. E-mail: acesse o artigo original para visualizar o e-mail

[17] Discente do Curso Superior de Medicina da Universidade Estadual do Tocantins Campus Graciosa. E-mail: acesse o artigo original para visualizar o e-mail

[18] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[19] Discente do Curso Superior de Medicina da Universidade Federal de Goiás Campus Colemar Natal e Silva. E-mail: acesse o artigo original para visualizar o e-mail

[20] Discente do Curso Superior de Medicina da Zarns Campus Itumbiara. E-mail: acesse o artigo original para visualizar o e-mail

[21] Discente do Curso Superior de Medicina da Faculdade Morgana Potrich (FAMP). Campus Mineiros. E-mail: acesse o artigo original para visualizar o e-mail