



Inteligência Artificial Generativa e Resolução de Problemas Complexos na Educação em Engenharia: Um Protocolo Humano-IA para Aprendizagem Crítica no Ensino Superior

Generative Artificial Intelligence and Complex Problem Solving in Engineering Education: A Human-AI Protocol for Critical Learning in Higher Education

Samyr Cardoso Possidério

Universidade Estácio de Sá (UNESA), Rio de Janeiro, RJ, Brasil.

Resumo: A incorporação da Inteligência Artificial Generativa (IAG) ao ensino superior vem alterando práticas de aprendizagem, avaliação e produção acadêmica, com implicações particulares para a Educação em Engenharia, área em que a formação profissional depende de raciocínio quantitativo, modelagem, julgamento técnico, tomada de decisão e resolução de problemas complexos. Este estudo analisa potencialidades, desafios e perspectivas educacionais do uso da IAG como suporte à resolução de problemas em cursos de Engenharia. Adotou-se revisão integrativa de literatura, com ênfase em estudos publicados entre 2022 e 2026 e em referências clássicas sobre aprendizagem ativa, Problem-Based Learning e resolução de problemas. Os achados indicam benefícios associados à personalização, feedback imediato, exploração de alternativas, explicitação de raciocínios e simulação de cenários, mas também riscos de alucinações, confiança excessiva, dependência cognitiva, terceirização do esforço intelectual e fragilização da autonomia. Como contribuição original, propõe-se um protocolo conceitual humano-IA em sete etapas, no qual o estudante realiza análise inicial independente, interage criticamente com a ferramenta, compara alternativas, valida tecnicamente os resultados e desenvolve reflexão metacognitiva. Conclui-se que a efetividade educacional da IAG depende menos do acesso à tecnologia do que de desenhos pedagógicos capazes de preservar responsabilidade, julgamento e autonomia como competências centrais da formação do engenheiro.

Palavras-chave: inteligência artificial generativa; educação em engenharia; resolução de problemas complexos; ensino superior; aprendizagem baseada em problemas.

Abstract: The incorporation of Generative Artificial Intelligence (GenAI) into higher education is reshaping learning, assessment, and academic production, with particular implications for Engineering Education, where professional formation depends on quantitative reasoning, modeling, technical judgment, decision-making, and complex problem solving. This study analyzes the potentialities, challenges, and educational perspectives of using GenAI to support problem solving in engineering programs. An integrative literature review was conducted, emphasizing studies published between 2022 and 2026 and foundational references on active learning, Problem-Based Learning, and problem solving. Findings indicate benefits related to personalization, immediate feedback, exploration of alternatives, reasoning externalization, and scenario simulation, alongside risks involving hallucinations, overconfidence, cognitive dependence, outsourcing of intellectual effort, and weakened learner autonomy. As an original contribution, a seven-step human-AI conceptual protocol is proposed in which students conduct an independent initial analysis, interact critically with the tool, compare alternatives,

technically validate outputs, and engage in metacognitive reflection. The study concludes that the educational effectiveness of GenAI depends less on access to the technology than on pedagogical designs capable of preserving responsibility, judgment, and autonomy as core competencies in engineering formation.

Keywords: generative artificial intelligence; engineering education; complex problem solving; higher education; problem-based learning.

INTRODUÇÃO

A transformação digital observada nas últimas décadas alterou de forma substancial as relações entre tecnologia, conhecimento e educação. Mais recentemente, a difusão de sistemas de Inteligência Artificial Generativa (IAG) ampliou a capacidade de interação entre usuários e sistemas computacionais, permitindo a geração de textos, códigos, imagens, explicações, sínteses e soluções a partir de instruções formuladas em linguagem natural. A popularização dessas ferramentas, impulsionada por modelos de linguagem de grande escala, tornou a IAG acessível a estudantes e docentes sem exigir conhecimentos avançados de programação, deslocando o debate educacional da disponibilidade tecnológica para a qualidade pedagógica de sua utilização (Qian, 2025; Yusuf *et al.*, 2024; Bond *et al.*, 2024).

No ensino superior, a IAG vem sendo incorporada a atividades de tutoria, produção textual, programação, feedback, criação de exercícios, planejamento de estudos e avaliação. Revisões recentes mostram que os usos pedagógicos se concentram em suporte à aprendizagem, automatização de feedback e desenvolvimento de habilidades críticas, ao mesmo tempo em que surgem preocupações com alucinações, vieses, dependência e terceirização de processos cognitivos (Qian, 2025; Belkina *et al.*, 2025; Xia *et al.*, 2024). Estudos com estudantes também registram percepções simultaneamente favoráveis e cautelosas quanto à utilidade, confiabilidade e implicações acadêmicas da tecnologia (Chan; Hu, 2023). Esse quadro exige uma abordagem que não reduza a discussão à dicotomia entre permitir e proibir o uso de ferramentas generativas.

Na Educação em Engenharia, a discussão é particularmente relevante. A formação do engenheiro exige domínio conceitual, raciocínio quantitativo, capacidade de modelagem, avaliação de restrições, comunicação técnica, tomada de decisão e julgamento diante de incertezas. Problemas profissionais raramente se apresentam com todos os dados organizados e com um único procedimento previamente definido. Ao contrário, costumam envolver múltiplas variáveis, objetivos conflitantes e diferentes soluções tecnicamente plausíveis. Assim, a competência profissional depende de saber formular o problema, selecionar hipóteses, combinar conhecimentos e justificar decisões, e não apenas de produzir uma resposta final correta (Jonassen, 2011).

A literatura específica sobre modelos de linguagem na Educação em Engenharia ainda está em consolidação. Filippi e Motyl (2024) identificaram 370

registros em uma busca sistemática e, após a aplicação dos critérios de inclusão e exclusão, selecionaram apenas 20 estudos para análise aprofundada. Em paralelo, revisões mais amplas de ensino superior indicam que Engenharia figura entre os domínios com maior presença de aplicações educacionais de IAG, embora persistam lacunas quanto a desenhos experimentais, avaliação longitudinal e integração pedagógica disciplinar (Filippi; Motyl, 2024; Batista; Mesquita; Carnaz, 2024; Belkina *et al.*, 2025).

As evidências mais recentes sugerem que a IAG pode contribuir para resultados acadêmicos e habilidades cognitivas de ordem superior. Chen e Cheung (2025), em meta-análise com 57 estudos e 97 estimativas, observaram efeitos positivos sobre desempenho acadêmico e higher-order thinking, mas não encontraram efeito estatisticamente significativo sobre metacognição. A diferença é crucial: um estudante pode melhorar o produto final de uma tarefa com auxílio da IA sem necessariamente ampliar sua capacidade de monitorar, regular e justificar o próprio raciocínio.

Dessa tensão emerge o problema central deste trabalho: a mesma tecnologia que pode funcionar como suporte cognitivo, tutor dialogado e fonte de feedback também pode oferecer respostas completas antes que o estudante formule hipóteses e desenvolva estratégias próprias. Em cursos de Engenharia, essa substituição do esforço cognitivo é especialmente problemática, pois competências profissionais dependem da capacidade de enfrentar situações novas, validar resultados e reconhecer limites dos modelos empregados.

Diante desse contexto, o objetivo deste estudo é analisar as potencialidades, os desafios e as perspectivas educacionais associadas à utilização da Inteligência Artificial Generativa como ferramenta de apoio à resolução de problemas complexos no ensino superior de Engenharia. Como questão norteadora, pergunta-se: de que forma a Inteligência Artificial Generativa pode contribuir para a resolução de problemas complexos no ensino superior de Engenharia sem comprometer o desenvolvimento do raciocínio crítico e da autonomia cognitiva dos estudantes?

METODOLOGIA

O estudo foi delineado como revisão integrativa de literatura, de caráter exploratório, descritivo e analítico. A escolha decorreu da natureza recente e interdisciplinar do objeto, situado na interface entre Inteligência Artificial, Educação Superior, Educação em Engenharia e ciência da aprendizagem. A revisão integrativa foi utilizada para articular evidências provenientes de diferentes delineamentos e construir uma síntese aplicada. Para ampliar a transparência e a reprodutibilidade, a organização do processo de busca, elegibilidade, seleção e síntese foi orientada pelos princípios de relato do PRISMA 2020, sem pretensão de caracterizar o estudo como meta-análise (Page *et al.*, 2021).

A busca bibliográfica foi atualizada em agosto de 2026 e priorizou artigos revisados por pares indexados ou disponibilizados em bases e portais de ampla

circulação científica: Web of Science, Scopus, IEEE Xplore, ScienceDirect e SpringerLink. O Google Scholar foi empregado de forma complementar para rastreamento de citações e localização de referências clássicas. O recorte principal compreendeu trabalhos publicados entre 2022 e 2026, período correspondente à rápida difusão pública dos modelos generativos contemporâneos. Estudos anteriores foram mantidos quando indispensáveis à fundamentação de Inteligência Artificial na educação superior, aprendizagem ativa, Problem-Based Learning (PBL), metacognição e resolução de problemas complexos (Zawacki-Richter *et al.*, 2019; Prince, 2004; Dochy *et al.*, 2003; Jonassen, 2011).

Os descritores principais foram definidos em inglês, por concentrar a maior parcela da produção indexada: “Generative Artificial Intelligence”, “Generative AI”, “Large Language Models”, “Engineering Education”, “Complex Problem Solving”, “Problem Solving”, “Problem-Based Learning”, “Higher Education”, “Critical Thinking”, “Metacognition” e “Artificial Intelligence in Education”. Foram utilizadas combinações com os operadores booleanos AND e OR, incluindo expressões como (“Generative AI” OR “Large Language Models”) AND (“Engineering Education” OR “Higher Education”) AND (“Problem Solving” OR “Critical Thinking” OR “Metacognition”). Em português, foram utilizados descritores equivalentes para complementar a busca.

Os critérios de inclusão foram: (a) artigos científicos revisados por pares; (b) revisões sistemáticas, revisões de escopo, revisões integrativas ou meta-análises com aderência direta ao tema; (c) estudos empíricos sobre utilização de IAG no ensino superior; (d) pesquisas envolvendo resolução de problemas, pensamento crítico, metacognição, feedback, aprendizagem ativa ou autonomia; e (e) estudos diretamente relacionados à Educação em Engenharia ou suficientemente transferíveis a contextos STEM. Foram excluídos textos exclusivamente opinativos, estudos centrados apenas na arquitetura computacional dos modelos, trabalhos sem vínculo educacional, duplicatas e documentos sem informação metodológica suficiente para sustentar a análise. Documentos institucionais de alta autoridade, como a orientação da UNESCO sobre IAG em educação e pesquisa, foram incluídos exclusivamente para o eixo ético e regulatório (UNESCO, 2023).

A seleção ocorreu em três níveis: leitura de título e resumo; leitura do texto completo dos trabalhos potencialmente elegíveis; e extração temática dos estudos considerados mais aderentes à questão norteadora. Para cada referência central foram registrados, quando disponíveis, objetivo, delineamento, população ou corpus, aplicação de IAG, principais resultados, limitações e implicações pedagógicas. A síntese foi organizada em cinco eixos: (1) fundamentos e aplicações da IAG no ensino superior; (2) natureza da resolução de problemas complexos em Engenharia; (3) potencialidades pedagógicas; (4) desafios, riscos e limites; e (5) perspectivas para integração humano-IA. A análise foi qualitativa e comparativa, com atenção especial a revisões sistemáticas e meta-análises recentes, que oferecem maior amplitude de evidência (Chen; Cheung, 2025; Liu; Zhong, 2025; Qian, 2025).

Como limitação metodológica, esta revisão não realiza estimativa quantitativa própria do efeito nem pretende exaurir toda a literatura publicada. Seu propósito é integrar criticamente evidências de alta relevância e construir uma interpretação

orientada ao ensino de Engenharia. Esse posicionamento evita extrapolar resultados heterogêneos e é coerente com a literatura recente, que destaca forte dependência dos efeitos da IAG em relação ao desenho pedagógico, à população, à duração das intervenções e às estratégias de scaffolding (Chen; Cheung, 2025; Liu; Zhong, 2025).

Quadro 1 – Eixos analíticos empregados na revisão.

Eixo	Questão analítica	Contribuição para a pesquisa
IAG no ensino superior	Como a IAG vem sendo incorporada às práticas de ensino e aprendizagem?	Delimitação do cenário educacional e das aplicações emergentes.
Problemas complexos em Engenharia	Quais competências cognitivas e profissionais são mobilizadas?	Fundamentação disciplinar do problema de pesquisa.
Potencialidades	Em quais etapas da resolução a IAG pode apoiar o estudante?	Identificação de funções pedagógicas e cognitivas.
Riscos e limites	Quais efeitos podem comprometer aprendizagem e autonomia?	Análise crítica de dependência, erro, ética e integridade.
Integração pedagógica	Como estruturar a colaboração estudante-docente-IA?	Proposição de um modelo orientado à validação e meta-cognição.

Fonte: elaboração própria (2026).

INTELIGÊNCIA ARTIFICIAL GENERATIVA NO ENSINO SUPERIOR

A IAG pode ser compreendida como uma classe de sistemas capazes de produzir novos conteúdos a partir de regularidades aprendidas em grandes conjuntos de dados. Nos modelos de linguagem, o processamento estatístico de sequências permite gerar respostas contextualmente coerentes a instruções formuladas em linguagem natural. A arquitetura Transformer, introduzida por Vaswani *et al.* (2017), tornou-se um marco técnico para o desenvolvimento posterior de modelos de linguagem de grande escala e aplicações conversacionais contemporâneas.

Do ponto de vista educacional, a mudança mais significativa não é apenas o aumento da capacidade computacional, mas a facilidade de interação. Estudantes podem solicitar explicações em diferentes níveis de profundidade, reformular dúvidas, gerar exemplos e estabelecer diálogos iterativos. Essa característica aproxima os sistemas generativos de funções tradicionalmente associadas à tutoria e ao scaffolding, embora sem garantia intrínseca de correção factual ou adequação pedagógica (Kasneci *et al.*, 2023; Tlili *et al.*, 2023).

Qian (2025), ao revisar estudos empíricos sobre aplicações pedagógicas da GenAI em ensino superior, identificou três grandes frentes: feedback e avaliação automatizados, suportes de aprendizagem e desenvolvimento de habilidades críticas. A autora também destaca um paradoxo: ganhos de eficiência podem ocorrer simultaneamente ao risco de *overreliance*, isto é, dependência excessiva capaz de deslocar para a tecnologia processos cognitivos que deveriam ser desenvolvidos pelo estudante.

Bond *et al.* (2024) mostram que o campo mais amplo de Inteligência Artificial no ensino superior ainda enfrenta limitações metodológicas e éticas. Essa preocupação antecede a atual onda generativa: Zawacki-Richter *et al.* (2019) já apontavam desequilíbrio entre avanços técnicos e participação de educadores na pesquisa sobre IA no ensino superior. Com a IAG, a necessidade de rigor, colaboração interdisciplinar, proteção de dados e supervisão humana torna-se ainda mais crítica (Bond *et al.*, 2024; UNESCO, 2023).

Outro aspecto emergente é a qualidade da interação por prompts. Lee e Palmer (2025) demonstram que a formulação de comandos não deve ser tratada apenas como habilidade operacional. Revisões posteriores distinguem estratégias de prompting orientadas por técnica daquelas orientadas por processo cognitivo e mostram que *scaffolding* e conhecimento pedagógico-tecnológico são determinantes para uma integração educacional consistente (Lee; Palmer, 2025; Liu; Zhong, 2025). Para a Educação em Engenharia, ensinar o estudante a formular perguntas tecnicamente bem definidas pode integrar-se ao próprio desenvolvimento da competência de modelagem do problema.

Não obstante, a resposta produzida por um modelo generativo não equivale a conhecimento validado. Modelos podem gerar conteúdos plausíveis e incorretos, referências inexistentes, simplificações inadequadas e raciocínios numéricos inconsistentes. A literatura inicial sobre LLMs na educação já enfatizava riscos de desinformação, viés, opacidade e confiança indevida, ao lado de oportunidades de personalização e feedback (Kasneci *et al.*, 2023; Tlili *et al.*, 2023; Grassini, 2023). Portanto, qualquer integração educacional robusta deve incluir checagem, rastreabilidade das fontes e validação por métodos independentes.

Produto da Tarefa Versus Processo Cognitivo

Uma distinção analítica fundamental para este estudo é aquela entre desempenho no produto e desenvolvimento do processo cognitivo. O produto corresponde à qualidade observável da resposta final: correção, completude, organização, clareza ou desempenho numérico. O processo cognitivo envolve a capacidade do estudante de compreender o problema, mobilizar conceitos, justificar hipóteses, monitorar erros e transferir estratégias para situações novas.

Chen e Cheung (2025) fornecem evidência particularmente relevante para essa distinção. A meta-análise identificou efeito positivo global da GenAI em resultados de aprendizagem, com efeitos sobre *achievement* e *higher-order thinking*, mas ausência de efeito estatisticamente significativo sobre metacognição.

Em termos pedagógicos, isso significa que a melhoria do resultado final não pode ser interpretada automaticamente como fortalecimento da autonomia intelectual.

Daniel *et al.* (2025), ao sintetizar 158 estudos sobre desenvolvimento de habilidades acadêmicas, relatam amplo potencial da IAG para habilidades cognitivas, técnicas e interpessoais. Contudo, o efeito depende de integração intencional, alfabetização em IA e avaliação crítica das saídas produzidas. Liu e Zhong (2025), em revisão sistemática de 71 estudos empíricos sob a perspectiva TPACK, também destacam que scaffolding pedagógico e desenho instrucional influenciam os resultados. Para cursos profissionais, a questão deixa de ser apenas se a IA melhora o desempenho e passa a ser se o estudante consegue explicar e defender tecnicamente a solução depois de utilizá-la.

RESOLUÇÃO DE PROBLEMAS COMPLEXOS NA EDUCAÇÃO EM ENGENHARIA

A resolução de problemas é uma competência estruturante da formação em Engenharia. Em situações acadêmicas introdutórias, exercícios frequentemente apresentam variáveis conhecidas, dados suficientes e métodos relativamente definidos. Essa estrutura é útil para aprendizagem de fundamentos, porém representa apenas parcialmente a complexidade das situações profissionais.

Jonassen (2011) distingue problemas bem estruturados de problemas mal estruturados ou complexos. Nos primeiros, regras e caminhos de solução são relativamente previsíveis; nos segundos, objetivos, restrições e critérios podem ser ambíguos, podendo existir múltiplas soluções defensáveis. A engenharia profissional aproxima-se frequentemente do segundo grupo, especialmente em projeto, planejamento, diagnóstico, otimização e tomada de decisão.

Um problema real pode exigir a integração simultânea de segurança, desempenho, custo, sustentabilidade, disponibilidade de recursos, normas, cronograma, manutenção e impactos sociais. A solução tecnicamente mais eficiente em um critério pode ser inadequada em outro. Dessa forma, resolver problemas de engenharia implica construir e defender compromissos entre alternativas, explicitando premissas e reconhecendo incertezas.

Metodologias ativas procuram aproximar a experiência acadêmica desse tipo de raciocínio. Prince (2004) sintetiza evidências favoráveis à aprendizagem ativa no ensino de engenharia, enquanto Freeman *et al.* (2014), em meta-análise de cursos STEM, demonstraram vantagens de estratégias ativas em comparação com aulas expositivas tradicionais. No caso específico do PBL, Dochy *et al.* (2003) identificaram efeitos particularmente favoráveis sobre habilidades, ainda que os efeitos sobre aquisição imediata de conhecimento possam variar.

A aproximação entre IAG e PBL é, portanto, conceitualmente promissora. Um sistema generativo pode representar uma fonte de feedback, contra-argumentos, alternativas e perguntas, mas o desenho da atividade deve impedir que o modelo simplesmente substitua as etapas em que o estudante deveria construir entendimento

próprio. A tecnologia é mais coerente com os princípios do PBL quando expande o espaço de investigação, não quando encerra prematuramente a investigação fornecendo uma resposta acabada.

POTENCIALIDADES DA IAG NA RESOLUÇÃO DE PROBLEMAS DE ENGENHARIA

Personalização e Scaffolding Cognitivo

Uma das principais potencialidades da IAG consiste na possibilidade de adaptar explicações ao nível de compreensão manifestado pelo estudante. Em uma disciplina de Engenharia, o mesmo conceito pode ser reapresentado de forma qualitativa, matemática, gráfica ou aplicada. Essa flexibilidade pode reduzir barreiras iniciais e favorecer a progressão do aprendiz, sobretudo quando o modelo é orientado a oferecer pistas graduais em vez de entregar a solução completa.

O scaffolding pode ser estruturado por perguntas sucessivas: identificação das variáveis, definição das condições de contorno, seleção de leis físicas, escolha do modelo matemático e avaliação da plausibilidade do resultado. Quando o estudante precisa responder antes de receber a próxima pista, a IA funciona mais como tutor socrático do que como solucionador automático.

Feedback Imediato e Formativo

O tempo entre tentativa e feedback influencia a aprendizagem. Em turmas numerosas, o docente nem sempre consegue acompanhar individualmente cada etapa de resolução. A IAG pode oferecer feedback preliminar sobre uma estratégia, solicitar justificativas adicionais, identificar inconsistências aparentes e sugerir pontos a verificar. Esse retorno não deve ser entendido como validação final, mas como elemento formativo que mantém o estudante engajado no ciclo de tentativa, análise e revisão.

Xia *et al.* (2024) mostram que a GenAI está transformando práticas de avaliação no ensino superior, especialmente pela possibilidade de feedback automatizado e atividades mais personalizadas. Para Engenharia, uma aplicação promissora é separar claramente feedback formativo de certificação: a IA pode apoiar o processo, enquanto a decisão avaliativa final permanece vinculada a critérios explícitos e supervisão docente.

Geração e Comparação de Alternativas

Problemas complexos raramente possuem uma única solução. A IAG pode ser utilizada para ampliar o conjunto inicial de alternativas, apresentando estratégias que o estudante talvez não tenha considerado. O ganho pedagógico ocorre quando essas alternativas são submetidas à comparação baseada em critérios técnicos, econômicos, ambientais ou normativos.

Em vez de perguntar ao sistema ‘qual é a melhor solução?’, o professor pode exigir que o estudante formule critérios de decisão, atribua pesos quando pertinente, identifique limitações e produza uma justificativa independente. A IA passa, assim, de autoridade decisória para geradora de possibilidades que precisam ser examinadas.

Simulação de Cenários e Análise de Sensibilidade

A interação em linguagem natural facilita a formulação de cenários hipotéticos. O estudante pode explorar consequências de mudanças em parâmetros, hipóteses ou restrições, criando uma forma de análise de sensibilidade conceitual. Em problemas de materiais, estruturas, gestão, segurança ou sustentabilidade, esse recurso pode estimular perguntas do tipo ‘o que acontece se...?’, relevantes para a compreensão sistêmica.

Entretanto, a simulação textual não substitui softwares especializados, equações, ensaios ou modelos numéricos. A prática pedagógica deve deixar explícita a diferença entre explorar hipóteses com um modelo generativo e validar quantitativamente uma solução com ferramentas adequadas.

Desenvolvimento da Argumentação e do Pensamento Crítico

Uma estratégia particularmente útil consiste em transformar a própria falibilidade da IA em objeto de aprendizagem. Docentes podem solicitar ao modelo uma solução e pedir que os estudantes atuem como revisores técnicos, identificando hipóteses frágeis, erros de unidade, referências inexistentes, omissões normativas ou conclusões não sustentadas.

Essa abordagem desloca a atividade de ‘obter uma resposta’ para ‘avaliar uma resposta’. O estudante precisa mobilizar conhecimento disciplinar para discordar fundamentadamente do sistema. Qian (2025) destaca justamente a emergência de usos de GenAI voltados ao pensamento crítico, à criatividade e à autonomia, embora alerte para a necessidade de evitar dependência.

DESAFIOS, RISCOS E LIMITAÇÕES

Alucinações, Erros Técnicos e Falsa Plausibilidade

Modelos de linguagem podem produzir conteúdo fluente sem possuir mecanismo intrínseco de garantia da verdade. Esse fenômeno, frequentemente descrito como alucinação, torna-se crítico em engenharia, pois um erro pode ocorrer em uma unidade, hipótese, equação, coeficiente, interpretação de norma ou recomendação de projeto. A forma persuasiva da linguagem gerada pode aumentar a probabilidade de aceitação por estudantes com menor domínio do tema.

Por isso, respostas geradas devem ser tratadas como hipóteses ou rascunhos que necessitam de verificação. A alfabetização em IA inclui compreender que coerência linguística e correção técnica são propriedades diferentes.

Dependência Cognitiva e Terceirização do Raciocínio

O risco pedagógico mais profundo talvez não seja o erro da IA, mas a resposta correta obtida sem esforço cognitivo suficiente. Se etapas como interpretação, decomposição do problema, escolha de modelo e avaliação do resultado forem transferidas sistematicamente ao sistema, o estudante pode desenvolver eficiência operacional sem alcançar autonomia profissional.

Qian (2025) caracteriza essa tensão como potencial outsourcing de habilidades cognitivas e metacognitivas. Em consonância, Chen e Cheung (2025) não encontraram efeito significativo sobre metacognição, apesar de resultados positivos em outras dimensões. Esse achado justifica a necessidade de protocolos que preservem momentos de resolução independente e reflexão posterior.

Integridade Acadêmica e Autoria

A IAG também desafia modelos tradicionais de avaliação. Trabalhos domiciliares baseados apenas no produto final tornam-se menos informativos sobre o que o estudante efetivamente sabe fazer. Isso não significa abandonar atividades escritas, mas redesenhar evidências de aprendizagem, valorizando registros de processo, defesa oral, versões sucessivas, justificativas e validação das fontes.

A transparência sobre o uso da IA deve integrar as regras da atividade. O estudante pode ser solicitado a declarar a ferramenta, a finalidade, os prompts relevantes e quais partes foram revisadas ou rejeitadas. Essa prática aproxima a integridade acadêmica da rastreabilidade do processo.

Vieses, Privacidade e Responsabilidade

Ferramentas generativas reproduzem limitações dos dados e mecanismos que as constituem. Respostas podem refletir vieses, simplificações culturais e pressupostos não adequados ao contexto local. Além disso, inserir dados pessoais, institucionais ou confidenciais em plataformas externas pode produzir riscos de privacidade. Em atividades de engenharia envolvendo casos reais, projetos ou organizações parceiras, a gestão desses dados precisa ser explicitamente regulamentada.

A responsabilidade profissional permanece humana. No ensino, isso significa ensinar que a IA pode apoiar a análise, mas não absorve responsabilidade técnica, ética ou legal por uma decisão. Tal princípio é importante para evitar a construção de uma cultura de delegação acrítica.

Desigualdade de Acesso e Alfabetização em IA

Diferenças de acesso a versões pagas, recursos multimodais e conectividade podem criar vantagens desiguais entre estudantes. Além disso, usuários com maior repertório técnico tendem a formular melhores prompts e avaliar melhor as respostas. Assim, simplesmente liberar o uso de IA pode ampliar desigualdades pré-existentes.

Instituições devem combinar políticas de acesso com formação mínima em alfabetização de IA, incluindo limites, vieses, verificação de fontes, privacidade, prompt literacy e critérios disciplinares de validação.

PERSPECTIVAS EDUCACIONAIS: UM MODELO ESTRUTURADO PARA USO DA IAG EM ENGENHARIA

A síntese da literatura sugere que o principal determinante do valor educacional da IAG não é a presença da ferramenta, mas o desenho da atividade. Um modelo pedagogicamente robusto deve preservar a responsabilidade cognitiva do estudante e utilizar a IA como elemento de contraste, feedback e expansão de possibilidades.


Com base nos achados analisados, propõe-se uma sequência de sete etapas para problemas complexos em engenharia. A primeira etapa é a compreensão do problema, na qual o estudante identifica objetivos, variáveis, restrições e informações ausentes. A segunda é a formulação independente de hipóteses, antes de qualquer consulta à IA. A terceira é a interação estruturada com a ferramenta, solicitando alternativas, questionamentos ou explicações, e não uma solução final sem justificativa.

A quarta etapa consiste na comparação entre a proposta inicial do estudante e as saídas do sistema. Na quinta, ocorre a validação por equações, literatura, normas, softwares, ensaios ou outras fontes confiáveis. A sexta corresponde à tomada de decisão, com justificativa explícita da solução adotada. Por fim, a sétima etapa é metacognitiva: o estudante registra o que modificou, quais sugestões rejeitou, quais erros identificou e de que forma a interação influenciou seu raciocínio.

Esse arranjo procura transformar a interação humano-IA em uma atividade de aprendizagem deliberada. O estudante não é avaliado apenas pelo resultado, mas também pela qualidade das premissas, pela capacidade de contestar o modelo, pela robustez da validação e pela coerência da justificativa final.

A Figura 1 sintetiza visualmente o protocolo humano-IA proposto, evidenciando a centralidade da ação do estudante, o papel de suporte da IAG e a etapa indispensável de validação técnica antes da decisão final.

Figura 1 – Modelo conceitual do protocolo humano-IA para resolução de problemas complexos em Engenharia.



Fonte: elaboração própria (2026).

Quadro 2 – Proposta de protocolo pedagógico para resolução de problemas de Engenharia com IAG.

Etapa	Ação do estudante	Papel da IAG	Evidência de aprendizagem
1. Compreender	Delimita objetivos, dados e restrições.	Pode esclarecer termos após análise inicial.	Mapa do problema e premissas.
2. Formular	Propõe estratégia e hipóteses próprias.	Não utilizada nesta etapa.	Solução preliminar registrada.
3. Interagir	Formula prompts com contexto e critérios.	Gera alternativas, perguntas e explicações.	Registro de prompts e respostas.
4. Comparar	Confronta solução própria e saídas da IA.	Funciona como contraponto.	Matriz de convergências e divergências.
5. Validar	Verifica cálculos, fontes e normas.	Pode indicar caminhos, nunca validar sozinha.	Evidências externas de verificação.
6. Decidir	Seleciona e justifica a solução.	Oferece cenários alternativos.	Justificativa técnica final.
7. Refletir	Análise como a IA afetou seu raciocínio.	Objeto de reflexão metacognitiva.	Relato crítico do processo.

Fonte: elaboração própria (2026), com base em Qian (2025), Lee e Palmer (2025), Filippi e Motyl (2024) e Jonassen (2011).

Implicações para avaliação da aprendizagem

A adoção de um protocolo estruturado exige coerência avaliativa. Se a disciplina valoriza a resolução complexa, mas a avaliação mede apenas a resposta final, o estudante recebe incentivo para buscar eficiência e não compreensão.

Avaliações compatíveis com a era da IAG devem incorporar etapas intermediárias, defesa de hipóteses, comparação de alternativas e justificativa de validações.

Uma possibilidade é combinar desempenho de produto e processo. O produto pode ser avaliado por correção técnica, viabilidade e clareza; o processo, por qualidade da decomposição do problema, coerência das premissas, uso crítico da IA, verificação independente e reflexão metacognitiva. Esse modelo aproxima avaliação e competência profissional.

Xia *et al.* (2024) argumentam que a GenAI está pressionando o ensino superior a repensar a avaliação, sobretudo em relação à autenticidade das tarefas e ao equilíbrio entre eficiência, feedback e integridade. Para Engenharia, tarefas contextualizadas, defesa oral e análise de soluções alternativas tendem a produzir evidências mais ricas do que exercícios facilmente terceirizáveis.

Implicações para Formação Docente

A integração responsável da IAG depende também do desenvolvimento profissional docente. Professores precisam compreender funcionalidades e limites dos modelos, planejar prompts e rubricas, reconhecer riscos de privacidade e construir atividades nas quais a tecnologia desempenhe função pedagógica clara. Revisões recentes defendem que o uso efetivo requer alinhamento entre conhecimento tecnológico, pedagógico e disciplinar, e não apenas domínio instrumental da ferramenta (Belkina *et al.*, 2025; Liu e Zhong, 2025).

No campo da engenharia, essa formação deve preservar a centralidade do conhecimento disciplinar. Um bom desenho de atividade com IA requer que o professor saiba antecipar erros plausíveis, definir fontes de validação, estabelecer quais etapas podem ser apoiadas e quais devem ser executadas de forma independente. A expertise docente torna-se, portanto, mais e não menos relevante.

DISCUSSÃO

Os estudos analisados convergem em um ponto: a IAG possui potencial educacional relevante, mas seus efeitos são altamente dependentes do modo de integração. Revisões sistemáticas e meta-análises mostram benefícios em desempenho, feedback e habilidades de ordem superior, porém com heterogeneidade substancial e riscos associados ao uso não estruturado (Chen; Cheung, 2025; Qian, 2025; Yusuf *et al.*, 2024; Belkina *et al.*, 2025). A literatura, portanto, não sustenta que o simples acesso a ferramentas generativas produza automaticamente aprendizagem mais profunda.

Para a Educação em Engenharia, essa ambivalência não é apenas tecnológica, mas formativa. Formar engenheiros significa desenvolver capacidade de interpretar problemas, modelar fenômenos, comparar alternativas, justificar decisões e responder por implicações técnicas, econômicas, ambientais e éticas. Nesse sentido, a IAG pode atuar em três níveis complementares: no nível instrumental, amplia a velocidade de obtenção de explicações, exemplos e

alternativas; no nível cognitivo, pode apoiar decomposição, comparação e reflexão, desde que a atividade exija participação intelectual ativa; e, no nível formativo, pode contribuir para competências contemporâneas de colaboração humano-IA, desde que acompanhada de responsabilidade, validação e ética.

A meta-análise de Chen e Cheung (2025) fortalece a hipótese de que a IAG pode apoiar desempenho e higher-order thinking. Entretanto, a ausência de efeito significativo na metacognição impede concluir que o estudante automaticamente se torna mais autônomo. Essa lacuna é especialmente relevante para engenheiros, que precisam reconhecer quando um resultado é improvável, quando um modelo não se aplica, quando os dados são insuficientes e quando uma solução aparentemente eficiente viola restrições de segurança, normas ou viabilidade.

Filippi e Motyl (2024) mostram que a literatura específica em Engenharia ainda é pequena diante do crescimento geral da GenAI. Assim, há espaço para estudos experimentais que comparem ao menos três condições: resolução sem IA, uso livre de IA e uso estruturado por protocolo pedagógico. Tal desenho permitiria separar o efeito da disponibilidade da ferramenta do efeito do desenho educacional.

A convergência entre estudos de mapeamento também reforça que o campo está amadurecendo rapidamente. Yusuf *et al.* (2024), ao mapear 407 publicações, identificaram como temas dominantes aplicações, impactos, riscos éticos, adoção e desempenho. Batista, Mesquita e Carnaz (2024) observaram tendência semelhante em revisão focada no ensino superior. Esse crescimento, entretanto, torna ainda mais importante distinguir evidência empírica, percepção de usuários e proposições conceituais, evitando que entusiasmo tecnológico seja confundido com efetividade pedagógica comprovada.

Desse ponto de vista, a formação do engenheiro na era da IAG não pode ser reduzida à habilidade de obter respostas corretas com maior rapidez. Ela precisa incorporar competências de vigilância epistêmica, isto é, a capacidade de questionar premissas, rastrear fontes, reconhecer limites do modelo e validar tecnicamente o que foi gerado (Jonassen, 2011; UNESCO, 2023). A competência profissional desloca-se, assim, para um patamar em que cálculo, interpretação e julgamento se articulam com o uso crítico de sistemas inteligentes.

Além disso, a IAG pode contribuir para aproximar a aprendizagem de fluxos profissionais reais quando inserida em atividades que exijam leitura de requisitos, comparação de soluções, verificação por normas e softwares, documentação do raciocínio e defesa oral da proposta. Nessa perspectiva, a ferramenta não substitui a expertise do futuro engenheiro; ao contrário, torna mais visível a necessidade de integrar conhecimento científico, critérios de projeto, comunicação técnica e responsabilidade sobre consequências sociais e materiais das decisões (Prince, 2004; Freeman *et al.*, 2014; Liu e Zhong, 2025).

A variável dependente também deve ir além da nota final. Futuras pesquisas podem medir qualidade da solução, tempo, retenção, transferência para novos problemas, capacidade de detectar erros, confiança calibrada, metacognição e autonomia. Instrumentos mistos, combinando testes de desempenho, rubricas, análise de logs de interação e entrevistas, podem oferecer visão mais robusta.

Do ponto de vista institucional, a resposta à IAG não deve ser apenas normativa. Políticas de integridade são necessárias, mas precisam ser acompanhadas de redesign curricular. Quando tarefas autênticas exigem justificativa, validação e defesa, o uso de IA deixa de ser um atalho inevitável e pode tornar-se parte observável do processo de aprendizagem.

A principal contribuição conceitual deste estudo é defender uma mudança de foco: de “usar IA para resolver problemas” para “aprender a resolver problemas em interação crítica com IA”. Essa contribuição se materializa em um protocolo humano-IA de sete etapas, sintetizado na Figura 1 e detalhado no Quadro 2, concebido para preservar a finalidade formativa da Educação em Engenharia. Em vez de privilegiar apenas eficiência, o modelo enfatiza julgamento técnico, validação, argumentação, autonomia e responsabilidade profissional - atributos indispensáveis à formação do engenheiro em contextos de crescente automação cognitiva.

CONSIDERAÇÕES FINAIS

A Inteligência Artificial Generativa constitui uma transformação relevante para o ensino superior e apresenta aplicações particularmente promissoras na Educação em Engenharia. Sua capacidade de dialogar, explicar, gerar alternativas e fornecer feedback pode apoiar estudantes em diferentes etapas da resolução de problemas complexos.

Entretanto, o uso educacional da tecnologia envolve riscos que não podem ser tratados como aspectos periféricos. Alucinações, confiança excessiva, dependência cognitiva, desigualdade de acesso e problemas de integridade acadêmica afetam diretamente a confiabilidade e o valor formativo das atividades. Em Engenharia, onde decisões devem ser tecnicamente justificáveis, aceitar saídas generativas sem validação é incompatível com a própria natureza da formação profissional.

A revisão indica que o benefício da IAG depende menos de disponibilizar a ferramenta e mais de estruturar sua utilização. Propõe-se que atividades envolvendo problemas complexos preservem uma etapa inicial de compreensão e formulação independente, seguida por interação com a IA, comparação crítica, validação por fontes e métodos externos, tomada de decisão fundamentada e reflexão metacognitiva.

Nesse modelo, a IA não ocupa o lugar do estudante nem do professor. Atua como componente de um sistema de aprendizagem no qual o estudante permanece responsável pelo raciocínio e o docente pela arquitetura pedagógica e pelos critérios de qualidade. A colaboração humano-IA torna-se educacionalmente produtiva quando aumenta o número e a qualidade das perguntas que o estudante consegue formular, e não quando apenas reduz o tempo necessário para obter uma resposta.

Como agenda de pesquisa, recomenda-se testar empiricamente protocolos estruturados de uso da IAG em disciplinas de Engenharia, comparando-os com condições de uso livre e de ausência de IA. Estudos futuros devem incluir medidas de transferência, metacognição, detecção de erros e autonomia, além de desempenho

imediatamente. Essa agenda pode contribuir para uma integração da Inteligência Artificial que seja simultaneamente inovadora, crítica e coerente com as competências requeridas à formação de engenheiros.

REFERÊNCIAS

BAHROUN, Z.; ANANE, C.; AHMED, V.; ZACCA, A. Transforming education: a comprehensive review of generative artificial intelligence in educational settings through bibliometric and content analysis. **Sustainability**, v. 15, n. 17, 12983, 2023. DOI: <https://doi.org/10.3390/su151712983>.

BATISTA, J.; MESQUITA, A.; CARNAZ, G. **Generative AI and higher education: trends, challenges, and future directions from a systematic literature review**. Information, v. 15, n. 11, 676, 2024. DOI: <https://doi.org/10.3390/info15110676>.

BELKINA, M.; DANIEL, S.; NIKOLIC, S.; HAQUE, R.; LYDEN, S.; NEAL, P.; GRUNDY, S.; HASSAN, G. M. **Implementing generative AI (GenAI) in higher education: a systematic review of case studies**. Computers and Education: Artificial Intelligence, v. 8, 100407, 2025. DOI: <https://doi.org/10.1016/j.caeai.2025.100407>.

BOND, M.; KHOSRAVI, H.; DE LAAT, M.; BERGDAHL, N.; NEGREA, V.; OXLEY, E.; PHAM, P.; CHONG, S. W.; SIEMENS, G. A meta-systematic review of artificial intelligence in higher education: a call for increased ethics, collaboration, and rigour. **International Journal of Educational Technology in Higher Education**, v. 21, art. 4, 2024. DOI: <https://doi.org/10.1186/s41239-023-00436-z>.

CHAN, C. K. Y.; HU, W. Students' voices on generative AI: perceptions, benefits, and challenges in higher education. **International Journal of Educational Technology in Higher Education**, v. 20, art. 43, 2023. DOI: <https://doi.org/10.1186/s41239-023-00411-8>.

CHEN, S.; CHEUNG, A. C. K. Effect of generative artificial intelligence on university students' learning outcomes: a systematic review and meta-analysis. **Educational Research Review**, 100737, 2025. DOI: <https://doi.org/10.1016/j.edurev.2025.100737>.

DANIEL, K.; MSAMBWA, M. M.; WEN, Z. Can generative AI revolutionise academic skills development in higher education? A systematic literature review. **European Journal of Education**, v. 60, e70036, 2025. DOI: <https://doi.org/10.1111/ejed.70036>.

DOCHY, F.; SEGERS, M.; VAN DEN BOSSCHE, P.; GIJBELS, D. Effects of problem-based learning: a meta-analysis. **Learning and Instruction**, v. 13, n. 5, p. 533-568, 2003. DOI: [https://doi.org/10.1016/S0959-4752\(02\)00025-7](https://doi.org/10.1016/S0959-4752(02)00025-7).

FILIPPI, S.; MOTYL, B. **Large language models (LLMs) in engineering education: a systematic review and suggestions for practical adoption**.

Information, v. 15, n. 6, art. 345, 2024. DOI: <https://doi.org/10.3390/info15060345>.

FREEMAN, S.; EDDY, S. L.; MCDONOUGH, M.; SMITH, M. K.; OKOROAFOR, N.; JORDT, H.; WENDEROTH, M. P. Active learning increases student performance in science, engineering, and mathematics. **Proceedings of the National Academy of Sciences**, v. 111, n. 23, p. 8410-8415, 2014. DOI: <https://doi.org/10.1073/pnas.1319030111>.

GRASSINI, S. Shaping the future of education: exploring the potential and consequences of AI and ChatGPT in educational settings. **Education Sciences**, v. 13, n. 7, 692, 2023. DOI: <https://doi.org/10.3390/educsci13070692>.

JONASSEN, D. H. **Learning to solve problems: a handbook for designing problem-solving learning environments**. New York: Routledge, 2011.

KASNECI, E.; SESSLER, K.; KÜCHEMANN, S.; BANNERT, M.; DEMENTIEVA, D.; FISCHER, F.; GASSER, U.; GROH, G.; GÜNNEMANN, S.; HÜLLERMEIER, E.; KRUSCHE, S.; KUTYNIOK, G.; MICHAELI, T.; NEUMANN, C.; PETZOLD, M.; PFEFFER, J.; POQUET, O.; SAILER, M.; SCHMIDT, A.; SEIDEL, T.; STADLER, M.; WELLER, J.; KUHN, J.; KASNECI, G. ChatGPT for good? On opportunities and challenges of large language models for education. **Learning and Individual Differences**, v. 103, 102274, 2023. DOI: <https://doi.org/10.1016/j.lindif.2023.102274>.

LEE, D.; PALMER, E. Prompt engineering in higher education: a systematic review to help inform curricula. **International Journal of Educational Technology in Higher Education**, v. 22, art. 7, 2025. DOI: <https://doi.org/10.1186/s41239-025-00503-7>.

LIU, X.; ZHONG, B. Integrating generative artificial intelligence into student learning: a systematic review from a TPACK perspective. **Educational Research Review**, v. 49, 100741, 2025. DOI: <https://doi.org/10.1016/j.edurev.2025.100741>.

PAGE, M. J.; MCKENZIE, J. E.; BOSSUYT, P. M. *et al.* **The PRISMA 2020 statement: an updated guideline for reporting systematic reviews**. *BMJ*, v. 372, n. 71, 2021. DOI: <https://doi.org/10.1136/bmj.n71>.

PRINCE, M. Does active learning work? A review of the research. **Journal of Engineering Education**, v. 93, n. 3, p. 223-231, 2004. DOI: <https://doi.org/10.1002/j.2168-9830.2004.tb00809.x>.

QIAN, Y. **Pedagogical applications of generative AI in higher education: a systematic review of the field**. *TechTrends*, v. 69, p. 1105-1120, 2025. DOI: <https://doi.org/10.1007/s11528-025-01100-1>.

TLILI, A.; SHEHATA, B.; ADARKWAH, M. A.; BOZKURT, A.; HICKEY, D. T.; HUANG, R.; AGYEMANG, B. What if the devil is my guardian angel: ChatGPT as a case study of using chatbots in education. **Smart Learning Environments**, v. 10, art. 15, 2023. DOI: <https://doi.org/10.1186/s40561-023-00237-x>.

UNESCO. **Guidance for generative AI in education and research**. Paris: UNESCO, 2023.

VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, L.; POLOSUKHIN, I. **Attention is all you need**. In: Advances In Neural Information Processing Systems, 30, 2017. Proceedings [...]. [S. l.]: NeurIPS, 2017.

XIA, Q.; WENG, X.; OUYANG, F.; LIN, T. J.; CHIU, T. K. F. A scoping review on how generative artificial intelligence transforms assessment in higher education. **International Journal of Educational Technology in Higher Education**, v. 21, art. 40, 2024. DOI: <https://doi.org/10.1186/s41239-024-00468-z>.

YUSUF, A.; PERVIN, N.; ROMÁN-GONZÁLEZ, M.; MD NOOR, N. Generative AI in education and research: a systematic mapping review. **Review of Education**, v. 12, n. 2, e3489, 2024. DOI: <https://doi.org/10.1002/rev3.3489>.

ZAWACKI-RICHTER, O.; MARÍN, V. I.; BOND, M.; GOUVERNEUR, F. Systematic review of research on artificial intelligence applications in higher education: where are the educators? **International Journal of Educational Technology in Higher Education**, v. 16, art. 39, 2019. DOI: <https://doi.org/10.1186/s41239-019-0171-0>.