

O Uso de Inteligência Artificial Generativa no Ensino de Diagramas de Classes: Um Estudo de Caso em Contexto Educacional

Yudi Vinícios Ribeiro Doi¹, Katyeudo Karlos de Sousa Oliveira²,
Gabriel Menon³, Anderson da Silva Marcolino¹

¹Universidade Federal do Paraná (UFPR)
R. Pioneiro, 2153 - Dallas, Palotina - PR, 85950-000

²Instituto Federal de Educação, Ciência e Tecnologia do Sertão Pernambucano
R. Maria Luzia de Araújo Gomes Cabral, 791 - João de Deus, Petrolina - PE, 56309-680

³Universidade Estadual do Oeste do Paraná (UNIOESTE)
R. Universitária, 2069 - Bloco B, Cascavel - PR, 85819-110

yudi.doi@ufpr.br, katyeudo.karlos@ifsertao-pe.edu.br,

gabriel.menon@unioeste.br, anderson.marcolino@ufpr.br

Abstract. *System modeling using the Unified Modeling Language (UML) requires abstraction skills, and many students face difficulties related to the syntax and semantics of diagrams. This study investigates the impact of Generative Artificial Intelligence (GenAI) on class diagram inspection by undergraduate students in a Computer Science Teacher Education program. The results indicate that the technology efficiently identifies logical and textual flaws but has limitations in interpreting graphical elements. The hybrid inspection approach encouraged critical validation of GenAI-generated responses, promoting active learning and deeper conceptual understanding. The findings highlight the potential of integrating human review with GenAI feedback to support Software Engineering education.*

Resumo. *A modelagem de sistemas por meio da Linguagem de Modelagem Unificada exige capacidade de abstração, e muitos estudantes enfrentam dificuldades relacionadas à sintaxe e à semântica dos diagramas. Este estudo avalia o impacto da Inteligência Artificial Generativa (IAGen) na inspeção de diagramas de classes por estudantes de Licenciatura em Computação. Os resultados indicam que a tecnologia identifica falhas lógicas e textuais com eficiência, mas apresenta limitações na interpretação de elementos gráficos. A auditoria híbrida estimulou a validação crítica das respostas da IAGen, promovendo aprendizagem ativa e aprofundamento conceitual. Os achados reforçam o potencial da integração entre revisão humana e feedback da IAGen como apoio ao ensino de Engenharia de Software.*

1. Introdução

O ensino da Linguagem de Modelagem Unificada (UML) na Engenharia de Software (ES) apresenta desafios persistentes na formação de estudantes. Conforme aponta [Azevedo 2021], muitos estudantes não dominam adequadamente a sintaxe e a semântica dos diagramas, o que compromete a construção de representações corretas de sistemas. Essa dificuldade resulta na confusão entre diferentes tipos de diagramas, como a mistura entre diagramas de classes e de caso de uso [Al-Ahmad et al. 2025, Khomokhoana et al. 2025].

Entre os artefatos da UML, o diagrama de classes destaca-se pela sua relevância acadêmica e profissional. Segundo [Bento 2020], trata-se da segunda modelagem mais utilizada no ambiente corporativo. Sua ampla adoção está relacionada à capacidade de representar a estrutura estática dos sistemas, incluindo atributos, operações e relacionamentos. Nesse sentido, o diagrama de classes permite materializar conceitos abstratos e organizá-los de forma compreensível [Fowler 2014, Pressman and Maxim 2021].

Apesar de sua importância, a elaboração desse tipo de diagrama exige competências como abstração, organização lógica e interpretação semântica. Tais habilidades nem sempre são plenamente desenvolvidas pelos estudantes, o que impacta a qualidade dos modelos produzidos [Tsoury et al. 2025]. Logo, há a necessidade de estratégias pedagógicas que auxiliem no processo de aprendizagem da modelagem conceitual [Yim and Su 2025].

Paralelamente, observa-se o avanço da Inteligência Artificial, em especial da Inteligência Artificial Generativa (IAGen) [Leong et al. 2025]. Essas tecnologias são capazes de gerar conteúdos inéditos a partir de padrões aprendidos, ampliando suas possibilidades de aplicação no contexto educacional [Mittal et al. 2024]. Nesse cenário, a IAGen tem sido utilizada como ferramenta de apoio à aprendizagem, auxiliando na produção de artefatos, revisão de conteúdos e oferta de feedback aos estudantes [Albino and Valente 2023, Rodrigues and Rodrigues 2023, Santaella 2024].

Embora o uso de IAGen na educação esteja crescendo, ainda são poucos os estudos que investiguem seu impacto específico na aprendizagem de modelagem estrutural em UML, especialmente na construção de diagramas de classes [Ibáñez et al. 2025]. A maioria das pesquisas concentra-se no ensino de programação, deixando lacunas no campo da modelagem conceitual [Oliveira et al. 2022, Oliveira et al. 2024, Canedo et al. 2025]. Assim, essa lacuna motiva a realização desta pesquisa qualitativa, por meio de um estudo de caso, que tem como questão norteadora: *Como o uso de IAGen influencia a qualidade e a compreensão conceitual dos estudantes na modelagem de diagramas de classes em UML?* Como objetivo geral, busca-se investigar o impacto da IAGen no desempenho e compreensão conceitual de estudantes nesse contexto. Articula-se, ainda, discussões sobre conceitos técnicos e pedagógicos, visto que os participantes são estudantes de um curso de Licenciatura em Computação.

Este trabalho está organizado como segue. A Seção 2 apresenta a fundamentação teórica e trabalhos correlatos. A Seção 3 apresenta o percurso metodológico da pesquisa. Na Seção 4 são apresentados os resultados, suas discussões e as ameaças à pesquisa. Na Seção 5 são apresentadas as conclusões e trabalhos futuros.

2. Fundamentação Teórica

Nesta seção é apresentada a fundamentação sobre diagramas de classe, inspeção de qualidade, IAGen aplicada na ES e os estudos correlatos.

Diagramas de Classes e Inspeção de Qualidade: o diagrama de classes é a principal ferramenta de modelagem orientada a objetos, ilustrando a estrutura de um sistema em um alto nível de abstração. No entanto, projetos reais necessitam de garantias contínuas de qualidade. A inspeção de software é amplamente reconhecida como uma técnica rigorosa de revisão por pares para avaliação de artefatos. Segundo a literatura, as inspeções melhoraram a produtividade e a segurança do produto, mitigando o efeito bola de neve dos defeitos [Siqueira et al. 2019, de Vasconcelos et al. 2006].

A abordagem baseada em *checklists* (listas de verificação) é considerada uma das mais eficazes e acessíveis para a auditoria. Diferentemente de métodos formais matemáticos que exigem curva de aprendizado íngreme, o *checklist* não exige que o auditor possua uma vasta

experiência prévia para aplicá-lo [Siqueira et al. 2019]. Ele guia o engenheiro a investigar se elementos cruciais como herança, composição, agregação, definição de tipos de dados e retornos, foram graficamente e logicamente bem estabelecidos.

Outro aspecto fundamental da avaliação dos modelos é a Analisabilidade e a Compreensibilidade. O modelo deve facilitar o diagnóstico de deficiências de projeto e possuir inteligibilidade suficiente para que seus elementos sejam entendidos rapidamente por diferentes desenvolvedores [Reinhartz-Berger and Sturm 2014, Bouwers et al. 2011].

Mais recentemente, a literatura tem discutido a combinação entre inspeção humana e apoio de ferramentas automatizadas como estratégia para reunir as vantagens complementares de cada abordagem, em processos como a revisão de código *human-in-the-loop* [Cihan et al. 2025, Yang et al. 2024]. Denomina-se aqui auditoria híbrida o processo em que um auditor humano e uma ferramenta automatizada (como uma IAGen) inspecionam o mesmo artefato, cujos resultados são confrontados e validados criticamente pelo revisor humano, que mantém a responsabilidade pela decisão final.

IAGen na Engenharia de Software: a transição tecnológica promovida pelos *Large Language Models* (LLMs - Modelos de Linguagem de Grande Escala) impôs desafios às metodologias tradicionais de ensino de computação. Chatbots, como o ChatGPT, conseguem sintetizar, gerar e criticar códigos e modelagens de marcação [Murad et al. 2024].

Pesquisas recentes sobre o uso do ChatGPT no ensino de modelagem indicam que estudantes que contam com o suporte de IAGen têm ganhos significativos de eficácia, que se refere ao grau de representação correta dos elementos e eficiência, correlata à redução de tempo. Ademais, a retenção de aprendizado em modelagem auxiliada por IA superou os grupos de controle que modelaram sem tal suporte [Murad et al. 2024]. Entretanto, a literatura adverte sobre os perigos da aceitação passiva das saídas do modelo (alucinações). Integrar a ferramenta em um modelo de avaliação comparativa obriga o estudante a exercitar o julgamento crítico, o que pode levar a melhores resultados [Silva 2020, Murad et al. 2024].

Estudos Correlatos: o ensino de modelagem de sistemas por meio da UML tem sido amplamente investigado na literatura, especialmente no que se refere às dificuldades enfrentadas por estudantes na compreensão e aplicação dos seus diagramas [Fernandes and Amaral 2022]. De acordo com [Metzner 2024], a aprendizagem de UML envolve o domínio de uma notação formal, mas também a capacidade de abstração e representação de conceitos complexos. Conforme [Khomokhoana et al. 2025], estudantes iniciantes tendem a apresentar dificuldades na distinção entre os diferentes tipos de diagramas, o que compromete a qualidade das soluções.

Nesse contexto, diversos estudos têm proposto abordagens pedagógicas para apoiar o ensino de modelagem. De acordo com [Kaur et al. 2023], estratégias baseadas em aprendizagem ativa, como resolução de problemas e estudos de caso, contribuem para o desenvolvimento das competências necessárias à modelagem conceitual. Além disso, conforme [Ardimento et al. 2024], o uso de ferramentas visuais e ambientes interativos pode facilitar a compreensão dos elementos da UML, reduzindo erros sintáticos e semânticos recorrentes.

Mais recentemente, observa-se o avanço de pesquisas que exploram o uso de tecnologias digitais no apoio ao ensino de ES. De acordo com [Engineer et al. 2024], ambientes educacionais mediados por tecnologia têm potencial para fornecer *feedback* imediato e personalizado aos estudantes, favorecendo o processo de aprendizagem. Conforme [Jebli et al. 2021], sistemas inteligentes de apoio ao ensino podem atuar como mediadores cognitivos, auxiliando na construção do conhecimento de forma mais guiada.

Com o surgimento da IAGen, novas possibilidades passaram a ser exploradas no contexto educacional. De acordo com [Pesovski et al. 2024], ferramentas baseadas em IAGen podem auxiliar na geração de exemplos, explicações e soluções, contribuindo para o aprendizado de conteúdos técnicos. Conforme [Deus et al. 2024], essas tecnologias têm sido aplicadas com maior frequência no ensino de programação, especialmente na geração automática de código e no suporte à resolução de exercícios.

Entretanto, a literatura ainda apresenta limitações quanto ao uso da IAGen no ensino de modelagem conceitual. De acordo com [Antal et al. 2024], a maior parte das pesquisas concentra-se na automação de tarefas relacionadas à codificação, havendo pouca exploração no apoio à construção de modelos abstratos, como diagramas de classes. Conforme [Yalim and Handley 2024], a ausência de estudos específicos nesse domínio dificulta compreender o real impacto dessas tecnologias na aprendizagem de conceitos estruturais.

Além disso, estudos recentes também apontam preocupações quanto ao uso da IAGen no contexto educacional. O uso excessivo dessas ferramentas pode levar à dependência tecnológica e à redução do esforço cognitivo dos estudantes [Zhai et al. 2024, Zhang and Xu 2025]. Conforme [Zhai et al. 2024], há o risco de aceitação passiva das respostas geradas pela IA, sem uma reflexão crítica sobre sua correção ou adequação.

Diante desse cenário, identifica-se uma lacuna relevante no que diz respeito ao uso da IAGen como ferramenta de apoio à aprendizagem de modelagem em UML. Diferentemente de estudos anteriores, que se concentram predominantemente no ensino de programação, o presente trabalho propõe analisar o impacto da IAGen na qualidade dos diagramas de classes produzidos e na compreensão conceitual dos estudantes. Dessa forma, busca-se contribuir para o avanço das pesquisas na interseção entre ES, Educação e Inteligência Artificial, oferecendo evidências empíricas sobre o uso dessas tecnologias no ensino de modelagem.

3. Percurso Metodológico

Esta pesquisa possui caráter exploratório e abordagem qualitativa, adotando como metodologia a condução de um estudo de caso. Segundo [Coutinho 2014], estudos de caso utilizam amostras intencionais e não probabilísticas, priorizando a compreensão aprofundada de fenômenos em contextos específicos, em vez da generalização estatística.

A abordagem qualitativa fundamenta-se na natureza subjetiva, reflexiva e contextual da intervenção realizada, quanto as percepções dos participantes acerca do uso da IAGen durante as atividades de inspeção. Pesquisas qualitativas mostram-se adequadas para compreender fenômenos educacionais complexos e contextualizados, priorizando profundidade analítica e interpretação dos dados [Bogdan and Biklen 1994, Creswell 2014].

Contexto e Amostra: duas turmas da disciplina de ES de um curso de Licenciatura em Computação (Turma 1 de sete estudantes e Turma 2 de cinco estudantes). Por estarem em um curso de licenciatura, os participantes exercem o papel de auditores juniores em formação técnica e de docentes críticos que avaliam a tecnologia sob a ótica educacional. Esta identificação é importante para complementar a investigação da pesquisa, visto que se difere de trabalhos que investigam estudantes de cursos de bacharelado ou tecnólogo. A análise pode corroborar para a desmistificação de preconceitos nas práticas contratuais de empresas de desenvolvimento de software, que muitas vezes não reconhecem licenciados como profissionais para atuar em áreas como desenvolvimento [Ayala and Rocha 2018].

Cuidados Éticos: a pesquisa foi registrada no Comitê de Ética em Pesquisa, sob o CAAE 95805826.7.0000.0107. Todos os participantes assinaram o Termo de Consentimento Livre e Esclarecido, contendo informações sobre os objetivos do estudo, participação vo-

luntária e garantia de anonimato e confidencialidade dos dados.

Procedimentos de execução: a execução foi planejada em nivelamento e três etapas.

Nivelamento e Modelagem Reversa: realização de quatro encontros teóricos de 50min cada (por meio de sequência didática criada a partir da ementa da disciplina), nos quais os estudantes participantes praticaram a modelagem por meio da engenharia reversa (do código para a UML), estabelecendo requisitos mínimos para um sistema contendo operações CRUD¹ e sobre técnicas de inspeção. Ao final, modelaram, a partir de escolha pessoal, um diagrama de classes de domínio diverso (biblioteca, agenda, e-commerce), que foram utilizados nas demais etapas, para inspeção.

Etapa 1 (inspeção manual): os diagramas elaborados foram distribuídos aleatoriamente entre os participantes, selecionados por conveniência, para aplicação do Instrumento de Coleta 1. **Etapa 2 (inspeção via IAGen):** os estudantes submeteram a imagem do diagrama (sem os registros da inspeção manual), juntamente com um *prompt* padronizado contendo as 12 questões do *checklist*, na versão gratuita do ChatGPT (sem *login*, visando minimizar vieses decorrentes do histórico do LLM), para que a IAGen realizasse a análise de qualidade. **Etapa 3 (comparação crítica):** após receberem as respostas da IAGen, os estudantes registraram os resultados no Instrumento de Coleta 2 e compararam as inspeções humana e automática, refletindo sobre as divergências e o uso da IAGen no contexto educacional.

Instrumentação: houve a concepção do artefato referente à sequência didática para as quatro aulas sobre modelagem de casos de uso e inspeção de tais diagramas, e de dois instrumentos: (i) instrumento de coleta 1, que trata-se de um questionário no formato de formulário (F1) de *checklist* impresso contendo 12 critérios estruturais da UML, para registro de defeitos sem o uso de IAGen, incluindo uma pergunta descritiva, levando os participante a refletir se, a partir da inspeção do diagrama de classes do colega, mudariam a modelagem do seu próprio diagrama; e (ii) instrumento de coleta 2 consiste em um formulário eletrônico (F2), implementado por meio do Google Forms, contendo um *prompt* com o questionário composto por 12 questões oriundas da inspeção do F1, destinadas à submissão à IAGen. Adicionalmente, o instrumento inclui questões avaliativas estruturadas em escala *Likert* de seis pontos (0 a 5), empregada para registro das percepções acerca da inspeção realizada pela IAGen, contrastando-a com a inspeção manual (F1), bem como para avaliarem reflexivamente a precisão, os possíveis erros da ferramenta e seu papel pedagógico.

A escolha por uma escala par (seis pontos) fundamenta-se na estratégia de supressão do ponto neutro (*forced-choice scale*), frequentemente utilizada para minimizar a concentração artificial de respostas em categorias intermediárias e estimular maior discriminação nas avaliações dos participantes [Kreitchmann et al. 2019].

Quanto à inspeção, definida em 12 questões presentes em ambos os instrumentos, consistiu na análise dos diagramas de classes produzidos pelos estudantes. Para isso, foi adotado um conjunto de critérios de inspeção previamente definidos, incluindo: (i) correção sintática, relacionada ao uso adequado da notação UML; (ii) correção semântica, referente à coerência dos elementos modelados; (iii) uso adequado de relacionamentos entre classes; e (iv) completude do diagrama em relação ao problema proposto.

Os instrumentos foram avaliados por um professor de ES e um estudante de mestrado de Pós-Graduação em Computação, para possíveis melhorias e remoções de vieses. Para


¹Corresponde ao conjunto fundamental de ações realizadas sobre dados em sistemas de informação, abrangendo a criação (*Create*), leitura (*Read*), atualização (*Update*) e exclusão (*Delete*) de registros.

garantir a transparência e replicabilidade do estudo, a disponibilidade dos artefatos foi feita por meio de disponibilização de pacote experimental on-line ².

Como IAGen a ser utilizada, selecionou-se o ChatGPT. A escolha deveu-se ao uso da ferramenta em trabalhos correlatos e aos resultados da pesquisa do *StackOverflow*, na qual o ChatGPT foi indicado como a ferramenta de IAGen mais utilizada para o desenvolvimento de software [Stack Overflow 2025, Deus et al. 2024].

Metodologia para Análise dos dados: a pesquisa caracteriza-se como qualitativa, sendo adotado o método de análise descritiva para a condução das análises. Esse método possibilita descrever, organizar e interpretar aspectos relevantes observados nos dados coletados, bem como comparar características identificadas entre os diferentes instrumentos e momentos da investigação [Reis and Reis 2002]. Para sua realização, consideraram-se as seguintes etapas: (a) definição dos objetivos da pesquisa; (b) elaboração das questões dos instrumentos de coleta; (c) coleta de dados; (d) organização, descrição e interpretação dos dados produzidos; e (e) redação das discussões a partir dos fenômenos, padrões e percepções.

Para preservar o anonimato, os doze estudantes foram identificados por códigos de E1 a E12. A Figura 1 apresenta as atividades da pesquisa, incluindo trabalhos futuros.



4. Resultados e Discussões

Os resultados estão organizados em dois grupos: (i) auditoria manual, realizada na Etapa 1 por meio do F1; e (ii) auditoria com IAGen, conduzida nas Etapas 2 e 3 com apoio do ChatGPT e do formulário reflexivo F2.


Antes da coleta de dados, os estudantes participaram de quatro aulas de nivelamento sobre modelagem de diagramas de classes e inspeção UML, conforme descrito na Seção 3. Em seguida, receberam a atividade prática, atuando como auditores juniores dos diagramas produzidos pelos colegas. Após assinatura do TCLE, os participantes realizaram a auditoria manual (F1) e, posteriormente, a auditoria com apoio do ChatGPT e do formulário F2.

Na segunda e terceira etapa, o diagrama foi devolvido digitalmente, visto que deveria ser enviado para o ChatGPT, bem como o formulário para inspeção pelo chat, com *prompt* pré estabelecido e questões de reflexão sobre o uso da IAGen (F2). A seguir são apresentados os resultados das etapas e uma seção consolidada.

4.1. Resultados da Auditoria Manual

A organização dos dados quantitativos obtidos a partir das respostas dicotômicas (Sim/Não) para as 12 questões de auditoria revelou as frequências absolutas entre os 12 participantes (E1 a E12) apresentadas na Figura 2.

²<https://doi.org/10.6084/m9.figshare.32962385>

Figura 2. Resposta da Auditoria Sem IAGen para as 12 Questões.

A análise qualitativa das respostas do F1 revelou evidências de domínio sintático, mas também inseguranças conceituais relacionadas à modelagem UML.

Quanto a compreensão e rigor sintático, os participantes demonstraram boa capacidade de identificar erros sintáticos e de tipagem de dados estruturais. O participante E4, por exemplo, observou corretamente a tipagem adequada para bancos de dados, sugerindo que “o atributo contato poderia ser varchar ao contrario de int”. O participante E8 demonstrou domínio sobre encapsulamento, afirmando que o “Atributo ‘Nome’ pode ser privado em todas as classes”, enquanto E7 demonstrou compreensão gráfica ao afirmar que “uma relação de herança é representada por meio de setas com a extremidade não preenchida”. E9 destacou erros de padrão de projeto e semântica de domínio, notando que o atributo “cib” deveria ser “CRB”³ e que não era um formato inteiro.

Já em relação às insegurança e incertezas conceituais, a maior carga de insegurança ocorreu na distinção e identificação de relacionamentos complexos (agregação, composição e classes associativas). O participante E2 apontou erros nas flechas de herança. E6 e E7 demonstraram incerteza ao avaliar classes associativas, focando superficialmente apenas na ausência de setas direcionais. Além disso, houve falhas de interpretação em que o E5 relatou que faltavam informações nos atributos e que as associações não estavam presentes, mas, paradoxalmente, marcou “Sim” para a viabilidade de codificação do sistema.


No geral, os resultados mostram um fenômeno de otimismo técnico” ou falta de rigor arquitetural por parte dos auditores juniores. Embora a maioria dos estudantes (como E2, E4, E5 e E11) tenha identificado falhas de multiplicidade, ausência de retornos (*void* em locais indevidos) e relacionamentos inconsistentes ou sem sentido”, 11 dos 12 participantes (91,6%) aprovaram a solução como viável para codificação (Q12). Apenas E1 julgou que o modelo não poderia ser desenvolvido devido à falta de informações sobre composição e agregação.

Este padrão sugere que a auditoria manual baseada em *checklists* é eficaz para alertar o revisor júnior sobre *bad smells* isolados [Santana and Figueiredo 2019], mas o estudante ainda encontra dificuldades para avaliar o impacto sistêmico que esses erros causarão durante a transição da modelagem UML para a engenharia direta de código-fonte. A percepção dos participantes indica uma carência no entendimento das consequências das classes associativas e agregações, elementos que frequentemente geraram respostas contraditórias.

³Sigla para Cédula de Identidade Bibliotecária.

4.2. Resultados da Auditoria com IAGen (ChatGPT)

A Figura 3 apresenta as respostas dicotômicas (Sim/Não) para as 12 questões de auditoria respondidas pela IAGen.



A análise descritiva, assim como foi aplicada para as respostas dos participantes, também foi aplicada para as respostas fornecidas pelo ChatGPT para cada uma das 12 questões da auditoria, submetida via *prompt*.

Em relação aos totais de respostas (Sim/Não), apresentadas na Figura 3, embora a IA tenda a gerar respostas longas e categorizadas como “Parcialmente”, a interpretação tabular dos dados aponta para um consenso de “Sim” unânime para a presença mínima de classes (Q1) e a explicitação de tipos de dados nos atributos e métodos (Q10 e Q11). A ferramenta forneceu respostas extensas e mais detalhadas. Por exemplo, identificou o uso errôneo do estereótipo <<uses>>, indicando que “é mais comum em diagramas de casos de uso, não em classes”, alertou para erros ortográficos como *Dafe* em vez de *Date* e apontou a falta de retornos *void* ou *boolean* em múltiplos métodos estruturais.

No entanto, para questões relacionais complexas (Q2, Q3, Q7 e Q9), os totais de “Não” e respostas divergentes aumentaram drasticamente, evidenciando as dificuldades do modelo generativo na interpretação de imagens estruturadas. A viabilidade de codificação (Q12) obteve majoritariamente respostas “Sim”, mas quase sempre acompanhadas de ressalvas pela IA (ex: “A estrutura do modelo permite implementação... mas precisa de ajustes”).

O processo de auditoria em relação às respostas da IAGen mostrou que os participantes confiam e concordam com a IA no que tange ao rigor sintático e boas práticas de tipagem. O participante E11 reiterou a precisão da IA em múltiplos itens auditados, como “está correto, a IA identificou e nomeou cada uma das classes”, “a IA está correta, não existe classe associativa”. O participante E8 concordou quando a IA alertou sobre a falta de parâmetros nos métodos e inconsistências no uso de agregação. Logo, ficou evidente que a IA atua como um revisor textual e lógico para atributos e assinaturas de métodos.

Os resultados indicam que a IAGen atua como um eficiente depurador estrutural em elementos menos complexos, identificando inconsistências que frequentemente passaram despercebidas pelos estudantes. Entretanto, as análises também evidenciaram limitações e alucinações relacionadas à interpretação gráfica da UML.

As evidências mais relevantes residem nos momentos em que os estudantes detectaram alucinações visuais da IA, demonstrando pensamento crítico. O participante E9 diag-

notificou uma alucinação relacional em que “o chat respondeu errado pois confundiu a seta preenchida da classe associativa com um losango preenchido de composição” e concluiu que a IA “parece ter dificuldade de reconhecer as relações e setas, pois cita estarem implícitas demais, mesmo elas estando completamente explícitas”. O participante E5 também refutou a IAGen, afirmando que “o chat GPT diz que no diagrama não possui composição, na qual seria indicado por um losango preenchido. Mas, existe sim uma composição”.


O participante E6 usou a IA para arbitrar um conflito com a auditoria manual de um colega, indicando insegurança na revisão humana ao afirmar que a pessoa que fez a análise do diagrama falou que está incorreta, mas está correta pelo *chat*. Já, E9 discordou da IA quanto à obrigatoriedade de regras de negócio, relatando: concordo que ‘calcularMulta’ poderia retornar valores, porém os parâmetros, não concordo que deveriam ser obrigatórios”.

A partir da análise descritiva, evidencia-se o que pode ser intitulada como uma auditoria híbrida curada. O uso da IAGen não suprimiu o raciocínio dos estudantes; pelo contrário, forçou-os a assumir uma postura de validadores sêniores. O padrão observado indica que a IA é altamente assertiva na avaliação de componentes textuais e semânticos da Orientação a Objetos (OO), como ausência de retornos ou tipagem fraca, mas sofre de limitações de visão computacional ao interpretar a notação gráfica da UML, como confundir setas de navegabilidade com losangos de composição. As percepções dos estudantes revelam que a intervenção tecnológica atua como um catalisador de aprendizagem ativa. Quando a IA emite um laudo incorreto (alucinação), o participante (E5, E9) é obrigado a resgatar a base teórica da ES para justificar por que a máquina falhou, exercitando a analisabilidade do software em um nível muito mais profundo do que se estivesse operando sem o auxílio tecnológico ou aceitando cegamente o gabarito. Contudo, percebe-se que estudantes com menor domínio técnico (como E6) podem tender ao viés de automação, confiando mais no Chat do que no colega de classe.

4.3. Consolidação dos Resultados sem e com IAGen

A consolidação dos resultados considerou as auditorias realizadas sem IAGen (Etapa 1), as percepções dos estudantes sobre as respostas do ChatGPT e as reflexões registradas no F2, composto por questões em escala Likert de seis pontos (0–5). A Figura 4 apresenta as percepções dos participantes sobre o uso da IAGen durante a auditoria.

Figura 4. Percepções dos Participantes na Auditoria com ChatGPT.



A análise integrada dos dados revelou três fenômenos principais: (i) limitações da auditoria manual e presença de otimismo técnico”; (ii) atuação da IAGen como depurador

sintático, porém com falhas visuais; e (iii) consolidação de um modelo híbrido de auditoria entre humano e IA. Na auditoria manual, observou-se que os auditores juniores identificam erros pontuais de notação, mas apresentam insegurança em relações semânticas mais complexas, como agregação e composição. Embora identificassem falhas relevantes, a maioria dos estudantes considerou os diagramas viáveis para codificação”, evidenciando dificuldade em dimensionar o impacto estrutural desses erros na implementação OO.

Em relação à atuação da IAGen, o ChatGPT ampliou a granularidade técnica da revisão ao identificar omissões que passaram despercebidas pela auditoria humana, como ausência de tipos de retorno (*void*, *boolean*) e tipagens inadequadas. Contudo, também foram identificadas limitações na interpretação visual da UML, especialmente na distinção entre setas de navegabilidade e losangos de composição. Essas limitações refletiram-se nos dados quantitativos da escala Likert. Na afirmação “O ChatGPT errou em muitos pontos que deveria ter analisado”, houve concentração significativa de respostas intermediárias (notas 3 e 4). Da mesma forma, a afirmação “Confio totalmente nas respostas do ChatGPT” apresentou predominância de notas baixas (0, 1 e 2), indicando que os estudantes perceberam a necessidade de validar criticamente as respostas da ferramenta.

Quanto ao modelo híbrido de auditoria, os resultados demonstram que a integração entre auditoria manual e IAGen foi percebida como mais eficaz do que o uso isolado de cada abordagem. As afirmações “Apenas a auditoria seria suficiente” e “Apenas a resposta do ChatGPT seria suficiente” receberam predominantemente notas baixas. Em contrapartida, a afirmação “A auditoria e a resposta do ChatGPT, juntas, foram suficientes para eu corrigir meu diagrama” apresentou concordância elevada, com 10 dos 12 participantes atribuindo notas 4 e 5. Esses resultados corroboram os achados de [Murad et al. 2024], que identificaram ganhos de eficácia e redução de esforço no uso do ChatGPT para ensino de ES e modelagem UML, desde que a curadoria final permaneça sob responsabilidade humana.

As métricas pedagógicas também indicaram valorização do material didático tradicional. Na comparação entre as afirmações “Acho que aprendo mais usando o ChatGPT” e “Acho que aprendo mais lendo o capítulo sobre diagrama de classes”, os estudantes atribuíram maior credibilidade ao material bibliográfico, com predominância de notas altas para o aprendizado baseado em leitura. Assim, sugerindo que a literatura teórica continua sendo percebida como fator central para validar criticamente as respostas produzidas pela IA.

Destarte, as evidências indicam que o confronto entre auditoria manual e respostas da IAGen favoreceu processos de aprendizagem ativa e analisabilidade crítica. Quando a IA produzia diagnósticos incorretos, os estudantes eram levados a revisar conceitos de OO para justificar os erros identificados. Assim, os resultados sugerem que a integração entre auditoria humana, IAGen e embasamento teórico contribui para elevar a qualidade final dos diagramas de classes de forma mais consistente do que abordagens aplicadas isoladamente.

4.4. Resultados e Discussões na Perspectiva Docente vs. Discente

Considerando que os participantes pertencem a um curso de Licenciatura em Computação, o F2, respondido na Etapa 3, foi complementado com três questões reflexivas sobre o uso da IAGen: (i) no contexto da aprendizagem, o ChatGPT ajuda ou atrapalha?; (ii) como futuro professor, o ChatGPT pode ser considerado uma boa ferramenta de ensino?; e (iii) quais regras deveriam existir para regular seu uso na educação?

Sob a perspectiva discente e técnica, a IAGen foi percebida como um recurso de apoio à produtividade, revisão e depuração de modelos UML e códigos. O participante E1 relatou utilizar a ferramenta “principalmente para correções e estudos”, destacando sua utilidade

na verificação de conformidade e esclarecimento de dúvidas. Entretanto, também emergiu a preocupação de que o uso excessivo de respostas prontas possa comprometer o desenvolvimento lógico e a capacidade de resolução de problemas dos estudantes.

Quando questionados sob a perspectiva docente, os participantes deslocaram o foco da produtividade para o processo cognitivo da aprendizagem. O ChatGPT foi reconhecido como uma ferramenta útil para apoio pedagógico, correção de atividades e esclarecimento de conteúdos. Contudo, surgiram preocupações relacionadas ao uso da IA como “muleta”, especialmente pela possibilidade de os estudantes terceirizarem o raciocínio e reduzirem sua autonomia intelectual e capacidade de pesquisa.

Na proposição de possíveis regras de uso, os participantes destacaram a necessidade de preservar práticas tradicionais de investigação científica. Foi sugerido que atividades acadêmicas continuassem exigindo pesquisas em livros, artigos e outras fontes formais, evitando a dependência exclusiva das respostas produzidas pela IA.

Os resultados mostram que estudantes de Licenciatura em Computação desenvolvem uma percepção bidimensional sobre a tecnologia. Sob a ótica técnica, a IA é vista como um copiloto de programação (*pair programming*) e um recurso eficiente para identificação rápida de erros e inconsistências. Já na perspectiva docente, a ferramenta passa a ser compreendida como um apoio pedagógico que exige mediação crítica e limites éticos claros. Nesse contexto, os participantes reconheceram que um artefato tecnicamente correto, gerado pela IA, pode mascarar fragilidades importantes no processo de aprendizagem. Enquanto a visão técnica tende a priorizar o produto final, a visão docente concentra-se no percurso cognitivo realizado pelo estudante para alcançar a solução.

4.5. Ameaças ao Estudo

As ameaças à validade interna incluem a fadiga dos participantes e as variações no conhecimento prévio sobre UML e IA, fatores que podem ter influenciado o esforço cognitivo e a qualidade das auditorias. Quanto à validade de construção, destaca-se o risco de viés de desejabilidade social, visto que os alunos sabiam que estavam sendo observados, e a subjetividade inerente à interpretação de questões abertas.

Em relação à validade externa, a generalização dos resultados é limitada pelo tamanho reduzido da amostra, pela abordagem qualitativa e pelo perfil específico dos participantes (estudantes de licenciatura). Como limitação do estudo, destaca-se a ausência de um grupo de comparação que realizasse a inspeção exclusivamente de forma manual, sem apoio da IAGen, bem como de medidas objetivas de aprendizagem (por exemplo, testes pré e pós-intervenção). Assim, os ganhos percebidos baseiam-se em autorrelatos e análise qualitativa, não sendo possível mensurar, no desenho atual, o efeito da IAGen sobre a aprendizagem.

Quanto à validade de conclusão, destaca-se ainda que os experimentos foram conduzidos com a versão gratuita do ChatGPT, sem login e sem acesso a modelos mais recentes ou personalizados. Como o desempenho de modelos de linguagem evolui rapidamente entre versões, os resultados aqui reportados são específicos a essa configuração, podendo variar de forma significativa caso versões pagas ou mais recentes da ferramenta sejam utilizadas. Por fim, a validade de conclusão envolve também o possível viés interpretativo do pesquisador na categorização dos dados qualitativos, risco que se buscou minimizar por meio de rigor, clareza metodológica e coerência na análise, conduzidas por pares.

5. Conclusão

Ao retomar a questão de pesquisa: *Como o uso de Inteligência Artificial Generativa influencia a qualidade e a compreensão conceitual dos estudantes na modelagem de diagramas*

de classes em UML?, os resultados demonstram que ferramentas de IAGen influenciam de maneira positiva a qualidade técnica dos modelos e a capacidade analítica dos estudantes.

Neste contexto investigado, o ChatGPT apresentou maior precisão do que os auditores juniores (estudantes auditando manualmente) na identificação de falhas de sintaxe UML, revelando omissões clássicas em métodos e relacionamentos. Mais importante, ao colocar o estudante no papel de avaliador dos resultados da IA, promoveu-se a compreensão conceitual ativa. Os participantes não se eximiram de apontar erros cometidos pelo LLM, consolidando um aprendizado prático que atende aos anseios técnicos (desenvolvimento de código) e pedagógicos de sua formação docente. Os resultados sugerem que o uso combinado da inspeção humana orientada por *checklist* com o *feedback* da IAGen constitui um arranjo promissor para o ensino de ES, cuja generalização para outros contextos requer investigação adicional.

Os achados desta pesquisa contribuem para a área de Informática na Educação ao demonstrar que a IAGen pode atuar como mediadora da aprendizagem em atividades de modelagem conceitual, favorecendo revisão, analisabilidade crítica e aprendizagem ativa. No contexto da ES, o estudo amplia as discussões sobre o uso pedagógico de LLMs além da programação, explorando sua aplicação na construção e inspeção de diagramas UML.

Para os estudantes, os resultados evidenciam que o uso combinado entre auditoria humana e IAGen estimula reflexões sobre erros sintáticos e semânticos, fortalecendo a participação crítica no processo de aprendizagem. Para os professores, a pesquisa indica que ferramentas como o ChatGPT podem apoiar práticas de acompanhamento, *feedback* e revisão de artefatos, desde que utilizadas com mediação pedagógica e validação humana.

Do ponto de vista educacional, o trabalho reforça a necessidade de integração crítica da IAGen nos ambientes de ensino, evitando tanto a rejeição absoluta quanto a dependência excessiva da tecnologia. Os resultados indicam que a IAGen possui potencial para ampliar o suporte à aprendizagem e aos processos de revisão técnica, desde que utilizada de forma ética, reflexiva e voltada ao desenvolvimento da autonomia intelectual dos estudantes.

Como trabalhos futuros, pretende-se ampliar a investigação para outros diagramas da UML, com amostras maiores e diferentes perfis de estudantes. Pretende-se também conduzir uma replicação do estudo incluindo um grupo de comparação submetido apenas à inspeção manual, além de medidas objetivas de aprendizagem (como testes de conhecimento pré e pós-intervenção). Também pretende-se investigar o uso de múltiplas IAGens e comparar seus desempenhos em atividades de inspeção e modelagem. Além disso, planeja-se desenvolver um guia pedagógico de auditoria apoiada por IAGen, visando apoiar docentes no uso crítico dessas tecnologias no ensino de ES.

6. Declaração sobre uso de Inteligência Artificial

Na redação deste artigo, foi utilizada a ferramenta de inteligência artificial generativa ChatGPT (versão 5.4), exclusivamente para apoio ao refinamento da redação e à revisão linguística, a partir de conteúdo originalmente elaborado pelos autores. Toda supervisão, validação e autoria intelectual do manuscrito são de responsabilidade dos autores humanos.

Disponibilidade de Artefatos

Os artefatos, instrumentos utilizados, dados coletados e informações da execução estão disponíveis em <https://doi.org/10.6084/m9.figshare.32962385>.

Referências

- [Al-Ahmad et al. 2025] Al-Ahmad, B., Alsobeh, A., Meqdadi, O., and Shaikh, N. (2025). A student-centric evaluation survey to explore the impact of llms on uml modeling. *Information*, 16(7):565.
- [Albino and Valente 2023] Albino, J. P. and Valente, V. (2023). Inteligência artificial e suas aplicações interdisciplinares. *Rio de Janeiro: Editora e-Publicar*.
- [Antal et al. 2024] Antal, G., Vozár, R., and Ferenc, R. (2024). Toward a new era of rapid development: Assessing gpt-4-vision’s capabilities in uml-based code generation. In *Proceedings of the 1st International Workshop on Large Language Models for Code*, pages 84–87.
- [Ardimento et al. 2024] Ardimento, P., Bernardi, M. L., Cimitile, M., and Scalera, M. (2024). A rag-based feedback tool to augment uml class diagram learning. In *Proceedings of the ACM/IEEE 27th International Conference on Model Driven Engineering Languages and Systems*, pages 26–30.
- [Ayala and Rocha 2018] Ayala, L. A. and Rocha, E. M. (2018). O curso de licenciatura em computação e o campo de atuação profissional: o que dizem seus egressos. *Anais CIET: Horizonte*.
- [Azevedo 2021] Azevedo, R. C. d. (2021). Rp-uml: uma arquitetura pedagógica para apoiar ensino-aprendizagem de modelagem de sistemas. Dissertação (mestrado em informática), Universidade Federal do Amazonas, Manaus, AM, Brasil. Acesso em: 12 jan. 2026.
- [Bento 2020] Bento, L. H. T. C. (2020). Uml: um estudo sobre o uso em empresas de desenvolvimento de software em são carlos – sp e região. Acesso em: 15 jan. 2026.
- [Bogdan and Biklen 1994] Bogdan, R. and Biklen, S. K. (1994). *Investigação Qualitativa em Educação: Uma Introdução à Teoria e aos Métodos*. Porto Editora, Porto.
- [Bouwers et al. 2011] Bouwers, E., Correia, J. P., van Deursen, A., and Visser, J. (2011). Quantifying the analyzability of software architectures. In *2011 Ninth Working IEEE/IFIP Conference on Software Architecture*, pages 83–92. IEEE.
- [Canedo et al. 2025] Canedo, E. D., OliveiraJr, E., and Tives, H. A. (2025). Professional use and teaching of uml: Perceptions of brasília-df region software practitioners and higher education instructors. In *Workshop sobre Educação em Computação (WEI)*, pages 24–35. SBC.
- [Cihan et al. 2025] Cihan, U., İcöz, A., Haratian, V., and Tüzün, E. (2025). Evaluating large language models for code review. *arXiv preprint arXiv:2505.20206*.
- [Coutinho 2014] Coutinho, C. P. (2014). *Metodologia de Investigação em Ciências Sociais e Humanas: teoria e prática*. Edições Almedina, S.A., Coimbra, Portugal, 2ª ed., reimpressão edition.
- [Creswell 2014] Creswell, J. W. (2014). *Investigação Qualitativa e Projeto de Pesquisa: Escolhendo entre Cinco Abordagens*. Penso, Porto Alegre, 3 edition.
- [de Vasconcelos et al. 2006] de Vasconcelos, A. M. L., Rouiller, A. C., Machado, C. F., and de Medeiros, T. M. M. (2006). *Introdução à Engenharia de Software e à Qualidade de Software*. UFLA/FAEPE, Lavras, MG.
- [Deus et al. 2024] Deus, W. S., da Silva Marcolino, A., Avellar, G. M. N., de Sousa Oliveira, K. K., and Barbosa, E. F. (2024). Avaliando resoluções de exercícios introdutórios de

programação na era das ias generativas: Um estudo de caso com o chatgpt. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, pages 1645–1657. SBC.

- [Engineer et al. 2024] Engineer, R., Yaremchuk, V., Suner, E., Khamis, O., Apostolu, A., and Ng, A. (2024). Uml mentor: A tool for interactive and collaborative software design education. In *Proceedings of the 2024 on ACM Virtual Global Computing Education Conference V. 2*, pages 309–309.
- [Fernandes and Amaral 2022] Fernandes, M. A. and Amaral, V. (2022). A simulation framework for uml education. In *2022 IEEE 46th Annual Computers, Software, and Applications Conference (COMPSAC)*, pages 161–166. IEEE.
- [Fowler 2014] Fowler, M. (2014). *UML Essencial: um breve guia para linguagem padrão*. Bookman editora.
- [Ibáñez et al. 2025] Ibáñez, M. B., Barrón-Estrada, M. L., and Zatarain-Cabada, R. (2025). Can multimodal large language models grade like an expert? a study on uml class diagram assessment accuracy. *Computer Applications in Engineering Education*, 33(5):e70080.
- [Jebli et al. 2021] Jebli, R., El Bouhdidi, J., and Chkouri, M. (2021). A proposed architecture of an intelligent system for assessing the student’s uml class diagram. *International Journal of Emerging Technologies in Learning (iJET)*, 16(21):4–12.
- [Kaur et al. 2023] Kaur, R., Malik, M. Z., and Singh, M. (2023). Improving delivery of uml class diagrams concepts in computer science education through collaborative learning. In *2023 IEEE Frontiers in Education Conference (FIE)*, pages 1–5. IEEE.
- [Khomokhoana et al. 2025] Khomokhoana, P. J., Fouché, R. C., and Nkalai, T. S. (2025). Semiotic analysis of uml class diagrams in pedagogy: a case of first-year bcis students. *Discover Education*, 4(1):342.
- [Kreitchmann et al. 2019] Kreitchmann, R. S., Abad, F. J., Ponsoda, V., Nieto, M. D., and Morillo, D. (2019). Controlling for response biases in self-report scales: Forced-choice vs. psychometric modeling of likert items. *Frontiers in psychology*, 10:2309.
- [Leong et al. 2025] Leong, L.-Y., Hew, T.-S., Ooi, K.-B., Tan, G. W.-H., and Koohang, A. (2025). Generative ai: Current status and future directions. *Journal of Computer Information Systems*, pages 1–34.
- [Metzner 2024] Metzner, A. (2024). Systematic teaching of uml and behavioral diagrams. In *2024 36th International Conference on Software Engineering Education and Training (CSEE&T)*, pages 1–5. IEEE.
- [Mittal et al. 2024] Mittal, U., Sai, S., Chamola, V., and Sangwan, D. (2024). A comprehensive review on generative ai for education. *Ieee Access*, 12:142733–142759.
- [Murad et al. 2024] Murad, S. B., Lemos, F. F. S., Melo, S. M., Paschoal, L. N., and Prates, J. M. (2024). Evidências sobre o uso do chatgpt no ensino de modelagem de software: um experimento controlado. In *Anais do Simpósio Brasileiro de Informática na Educação (SBIE)*. SBC.
- [Oliveira et al. 2024] Oliveira, K. K. d. S., da Silva Marcolino, A., Falcão, T. P., and Barbosa, E. F. (2024). Ensino e aprendizagem de programação na educação 4.0: Um mapeamento sistemático da literatura. *Simpósio Brasileiro de Educação em Computação (EDUCOMP)*, pages 245–255.

- [Oliveira et al. 2022] Oliveira, K. K. d. S., Falcão, T. P., and Barbosa, E. F. (2022). Um framework para a aprendizagem de habilidades de programação e habilidades do século xxi. In *Congresso Brasileiro de Informática na Educação (CBIE)*, pages 138–143. SBC.
- [Pesovski et al. 2024] Pesovski, I., Santos, R., Henriques, R., and Trajkovik, V. (2024). Generative ai for customizable learning experiences. *Sustainability*, 16(7):3034.
- [Pressman and Maxim 2021] Pressman, R. S. and Maxim, B. R. (2021). *Engenharia de software-9*. McGraw Hill Brasil.
- [Reinhartz-Berger and Sturm 2014] Reinhartz-Berger, I. and Sturm, A. (2014). Comprehensibility of uml-based software product line specifications: A controlled experiment. *Empirical Software Engineering*, 19(3):678–713.
- [Reis and Reis 2002] Reis, E. and Reis, I. (2002). Análise descritiva de dados. Technical report, Departamento de Estatística da UFMG. Acesso em: 24 set. 2024.
- [Rodrigues and Rodrigues 2023] Rodrigues, O. S. and Rodrigues, K. S. (2023). A inteligência artificial na educação: os desafios do chatgpt. *Texto livre*, 16:e45997.
- [Santaella 2024] Santaella, L. (2024). *A inteligência artificial é inteligente?* Edições 70, São Paulo, SP, Brasil, 1 edition. E-book. Disponível em: <https://app.minhabiblioteca.com.br/reader/books/9786554270540/>. Acesso em: 22 jan. 2026.
- [Santana and Figueiredo 2019] Santana, A. D. and Figueiredo, E. (2019). On the impact of bad smell agglomerations on software quality. In *Anais Estendidos do X Congresso Brasileiro de Software: Teoria e Prática*, pages 31–37, Porto Alegre, RS, Brasil. SBC.
- [Silva 2020] Silva, S. S. d. (2020). *Blended learning com jogos de empresas para desenvolver soft skills na educação executiva e gerencial: um quase-experimento*. PhD thesis, Universidade de São Paulo (USP) e Universidade de Salamanca, São Paulo / Salamanca.
- [Siqueira et al. 2019] Siqueira, D. d. S. e., Paulon, M. M., and Guedes, G. T. A. (2019). Técnicas de inspeção para diagramas de classes uml: Uma revisão sistemática. *Anais do Simpósio Brasileiro de Engenharia de Software*.
- [Stack Overflow 2025] Stack Overflow (2025). The 2025 developer survey. Acesso em: 19 abril 2026.
- [Tsoury et al. 2025] Tsoury, A., Hindy Ling, H., Beimel, D., and Bar-Lev, S. (2025). From omelet to uml: assessing the role of process thinking on process model quality among novice analyst. *Software Quality Journal*, 33(1):16.
- [Yalim and Handley 2024] Yalim, C. and Handley, H. H. (2024). Integrating generative artificial intelligence with systems architecting diagram creation: Advancement, challenges, opportunities and future perspectives. In *Proceedings of the American Society for Engineering Management 2024 International Annual Conference*, Virginia Beach, VA, USA.
- [Yang et al. 2024] Yang, Z., Gao, C., Guo, Z., Li, Z., Liu, K., Xia, X., and Zhou, Y. (2024). A survey on modern code review: Progresses, challenges and opportunities. *arXiv preprint arXiv:2405.18216*.
- [Yim and Su 2025] Yim, I. H. Y. and Su, J. (2025). Artificial intelligence (ai) learning tools in k-12 education: A scoping review. *Journal of Computers in Education*, 12(1):93–131.
- [Zhai et al. 2024] Zhai, C., Wibowo, S., and Li, L. D. (2024). The effects of over-reliance on ai dialogue systems on students’ cognitive abilities: a systematic review. *Smart learning environments*, 11(1):28.

- [Zhang and Xu 2025] Zhang, L. and Xu, J. (2025). The paradox of self-efficacy and technological dependence: Unraveling generative ai's impact on university students' task completion. *The Internet and Higher Education*, 65:100978.