



## Arquitetura Assistida por IA Generativa para Apoio à Correção de Atividades em Redes de Computadores

**Diego Grossmann**, IFMA/Campus São João dos Patos, [diego.grossmann@ifma.edu.br](mailto:diego.grossmann@ifma.edu.br),  
<https://orcid.org/0000-0003-1088-7867>

**Thiago Reis da Silva**, IFMA/Campus São João dos Patos, [thiago.reis@ifma.edu.br](mailto:thiago.reis@ifma.edu.br),  
<https://orcid.org/0000-0003-4206-6801>

**Mario Meireles Teixeira**, UFMA, [mario.meireles@ufma.br](mailto:mario.meireles@ufma.br), <https://orcid.org/0000-0001-8771-1478>

**Edmundo Henrique Barbosa Luz**, UFMA, [ed.henrique.luz@gmail.com](mailto:ed.henrique.luz@gmail.com),  
<https://orcid.org/0009-0000-0237-1751>

**Resumo.** *O EnsinaNet.AI é uma plataforma baseada em IA generativa projetada para corrigir atividades práticas em Redes de Computadores, integrando múltiplos provedores de IA e permitindo personalização de prompts e feedbacks automatizados. A plataforma foi avaliada utilizando respostas de quatro estudantes processadas por dezesseis modelos distintos de IA, evidenciando diferenças nos tempos de processamento e nos índices de precisão. Os resultados destacam ganhos em escalabilidade, clareza e personalização, embora desafios como padronização e curadoria docente persistam. O estudo enfatiza a necessidade de integração tecnológica, formação continuada de professores e alinhamento pedagógico, além de sugerir o uso em laboratórios virtuais e análise ética da IA na educação.*

**Palavras-chave:** *Inteligência Artificial, Avaliação Automatizada, Redes de Computadores.*

## Generative AI-Assisted Architecture for Supporting the Grading of Activities in Computer Networks

**Abstract.** *EnsinaNet.AI is a generative-AI-based platform designed to grade practical Computer Networking exercises, integrating multiple AI providers and allowing the customization of prompts and automated feedback. The platform was evaluated using responses from four students processed by sixteen different AI models, revealing differences in processing times and accuracy rates. The results highlight gains in scalability, clarity, and personalization, although challenges such as standardization and teacher curation remain. The study emphasizes the need for technological integration, continuous teacher training, and pedagogical alignment, and it also suggests using the platform in virtual laboratories and conducting an ethical analysis of AI in education.*

**Keywords:** *Artificial Intelligence, Automated Assessment, Computer Networks.*

### 1. Introdução

A correção de atividades em turmas numerosas constitui um dos principais desafios para docentes no ensino superior. Conforme destaca Hutchison (2022), o aumento do número de estudantes por turma resulta em maiores cargas de trabalho para o instrutor, dificultando a oferta de feedback individualizado devido ao tempo limitado. Em contextos de ensino massificado, torna-se praticamente inviável fornecer devolutivas detalhadas e personalizadas, levando à insatisfação discente: “a quantidade e a utilidade do feedback fornecido variam amplamente, causando incerteza e confusão” (OLSEN; HUNNES, 2024, p. 130)



Henderson, Ryan e Phillips (2019) reforçam que fornece feedback personalizado exige conhecer o histórico e as metas de cada estudante, algo difícil com turmas grandes, estudantes online ou períodos curtos de ensino. Esse cenário é agravado pela limitação de tempo dos professores, reconhecida pelos docentes como o principal obstáculo para a produção de feedback de qualidade. Não por acaso, estudantes frequentemente reportam insatisfação, sendo o feedback um dos itens de maior reclamação (OLSEN; HUNNES, 2024; HENDERSON; RYAN; PHILLIPS, 2019).

Diante da escalabilidade como um desafio recorrente, a literatura aponta que, sem maneiras mais inteligentes e eficientes de fornecer feedback personalizado para grupos numerosos de estudantes, a transição para um paradigma de feedback mais dialógico torna-se impraticável (OLSEN; HUNNES, 2024, p. 129). Nesse contexto, o uso de tecnologias baseadas em Inteligência Artificial (IA) surge como uma alternativa. Venter, Coetzee e Schmulian (2025) argumentam que a integração da IA nos mecanismos de feedback oferece uma oportunidade para enfrentar esses desafios, permitindo a geração de feedback em escala, de forma rápida, personalizada e com baixo custo para os instrutores.

Neste contexto, surge o EnsinaNet.AI, uma ferramenta que utiliza IA generativa para auxiliar no processo de avaliação em contextos de grande escala, com foco na área de Redes de Computadores. A ferramenta permite que o docente amplie o alcance e a qualidade do feedback, promovendo maior equidade e eficiência no processo avaliativo. Assim, o desenvolvimento e a aplicação de sistemas baseados em IA configuram-se como uma estratégia para equilibrar qualidade, personalização e viabilidade na correção de atividades em turmas numerosas. O objetivo deste trabalho é investigar soluções para a correção de atividades em grandes turmas, com ênfase na apresentação e validação da ferramenta EnsinaNet.AI.

Este artigo está organizado da seguinte forma: a Seção 2 apresenta a fundamentação teórica e os trabalhos relacionados; a Seção 3 descreve a metodologia de pesquisa adotada; a Seção 4 detalha o projeto e implementação do artefato EnsinaNet.AI; a Seção 5 discute os procedimentos de avaliação e resultados obtidos; a Seção 6 apresenta conclusão do estudo e as perspectivas de trabalhos futuros.

## **2. Fundamentação Teórica e Trabalhos Relacionados**

A adoção de tecnologias digitais e de IA tem se intensificado no ensino superior, especialmente em áreas como Redes de Computadores. A Educação a Distância (EaD) amplia o acesso e a IA surge como aliada ao promover personalização, interatividade e escalabilidade (FAGUNDES et al., 2025).

A IA automatiza tarefas avaliativas e aprimora o feedback, liberando o docente para funções mais estratégicas (CANDEIA et al., 2024). A automação da avaliação, quando alinhada à personalização do ensino, contribui para eficiência e maior qualidade no acompanhamento dos estudantes.

Apesar dos avanços, a integração da IA traz desafios éticos, pedagógicos e técnicos, como privacidade de dados, dependência tecnológica e necessidade de formação continuada (FAGUNDES et al., 2025; UNESCO, 2023). Destaca-se ainda a importância da transparência e do acesso equitativo à tecnologia.

Modelos generativos, como o GPT-4, têm apresentado resultados positivos, tornando processos de avaliação mais dinâmicos e personalizados (CANDEIA et al., 2024). Tais ferramentas têm potencial para aumentar o engajamento dos estudantes e melhorar os resultados educacionais (FAGUNDES et al., 2025).



Soluções baseadas em IA já demonstram redução da carga de trabalho docente e maior eficiência na avaliação, proporcionando feedback em escala (LEE e MOORE, 2024). No entanto, seu uso requer políticas institucionais claras e formação continuada (UNESCO, 2023).

No ensino de Redes de Computadores, a IA amplia as possibilidades de oferta de feedback formativo e personalização das estratégias pedagógicas. O sucesso dessa integração, porém, depende de práticas docentes adaptadas e investimento em infraestrutura (DURSO, 2024). Dessa forma, a IA, quando implementada com responsabilidade, é diferencial para superar desafios da avaliação em larga escala e avançar na qualidade do ensino de Redes de Computadores.

### 3. Metodologia de Pesquisa

O presente trabalho adota o paradigma da *Design Science Research* (DSR) (HEVNER et al., 2004), utilizado no desenvolvimento de artefatos nas áreas de Engenharia de Software e Educação em Computação. A DSR orienta o processo de construção e avaliação de artefatos, buscando responder a problemas relevantes e ao mesmo tempo contribuir para o avanço do conhecimento científico, sendo compostas por três ciclos principais:

- i. **Ciclo de Relevância:** Foca na identificação e compreensão do problema no contexto real, considerando as necessidades dos *stakeholders* (professores, estudantes, gestores acadêmicos) e os requisitos do domínio;
- ii. **Ciclo de Rigor:** Fundamenta-se em conhecimento prévio, teorias e soluções existentes, garantindo que o desenvolvimento do artefato se apoie no estado da arte e em boas práticas;
- iii. **Ciclo de Design e Avaliação:** Envolve a construção do artefato (projeto, implementação e evolução) e a avaliação sistemática de sua utilidade, qualidade e desempenho.

No contexto deste trabalho, os ciclos DSR foram operacionalizados da seguinte forma, o ciclo de relevância (i) deste estudo parte do reconhecimento dos desafios enfrentados por docentes na avaliação de atividades em disciplinas de Redes de Computadores, especialmente em contextos de EaD e turmas numerosas. Como destacado na literatura, a adoção de tecnologias digitais e, mais recentemente, da IA, visa justamente suprir lacunas de escalabilidade, personalização e agilidade no feedback ao estudante (CANDEIA et al., 2024).

Apesar dos avanços em laboratórios virtuais e plataformas de simulação, a avaliação automática ainda é limitada e geralmente restrita a tarefas objetivas, o que compromete a análise qualitativa das respostas dos alunos (JOVANOVIĆ et al., 2012; FARIAS, 2008; PHAM E NGUYEN, 2019). Nessas situações, a avaliação manual se torna inviável em turmas grandes, afetando a motivação dos estudantes devido à demora na devolutiva.

Nesse contexto, identificou-se a necessidade de um artefato capaz de automatizar a correção de atividades, oferecer feedback detalhado e personalizado e permitir a integração de múltiplos modelos de IA. O EnsinaNet.AI foi desenvolvido para preencher essa lacuna, alinhando-se às demandas atuais do ensino de redes de computadores e integrando os avanços tecnológicos.



O ciclo de rigor (ii) fundamenta-se na busca pelo alinhamento entre o estado da arte e as necessidades do ensino de redes de computadores, assegurando que o desenvolvimento do EnsinaNet.AI seja ancorado em evidências científicas.

Inicialmente, foi realizada uma revisão sistemática da literatura sobre ambientes virtuais e remotos para o ensino de redes, abordando desde soluções de laboratórios virtuais clássicos (como WebLabs e Packet Tracer) até sistemas recentes de simulação e automação da avaliação (JOVANOVIĆ et al., 2012; FARIAS, 2008; SANGUINO et al., 2018; PHAM; NGUYEN, 2019; MERAYO et al., 2021; NUGROHO et al., 2019). Essa análise revelou que, embora tais ferramentas ampliem o acesso a práticas de laboratório, ainda apresentam limitações na avaliação qualitativa e personalizada do aprendizado dos estudantes, especialmente em atividades abertas e discursivas.

Com base nesses achados, o rigor científico foi fortalecido pela incorporação de pesquisas sobre a aplicação de IA na educação, especialmente na geração automatizada de feedback e personalização do ensino (CANDEIA et al., 2024). Essas referências sustentam a opção por integrar múltiplos modelos de IA generativa, promovendo não apenas a diversificação dos resultados avaliativos, mas também o potencial para ajustes fino (*fine-tuning*) e comparação cruzada de desempenho entre provedores.

A fundamentação teórica orientou a definição dos requisitos do EnsinaNet.AI, priorizando atributos de modularidade, escalabilidade e segurança. Os requisitos funcionais foram delineados a partir das demandas docentes e das fragilidades apontadas pela literatura: autenticação de usuários, gerenciamento de múltiplos tokens e provedores de IA, versionamento de API, execução paralela de correções, logging estruturado e suporte a *fine-tuning* pedagógico (CUI et al., 2012; WANG GUY C. HEMBROFF, 2010). Também foram priorizados aspectos não funcionais como extensibilidade para inclusão de novos modelos, compatibilidade com diferentes ambientes institucionais e proteção dos dados dos usuários.

A seleção e integração dos modelos de IA se deu de forma orientada pelo desempenho reportado na literatura e pela viabilidade de orquestração dos provedores (OpenAI, Gemini, Claude, Llama, Perplexity, entre outros). O sistema foi desenhado para permitir testes controlados e auditáveis, assegurando que o rigor experimental pudesse ser mantido tanto na coleta de métricas quantitativas (tempo de resposta, acurácia, *logs*) quanto na análise qualitativa (clareza, detalhamento técnico, personalização dos *feedbacks*). O Ciclo de Design e Avaliação (iii) são detalhados nas seções 4 e 5 respectivamente.

### 3.4. Aspectos Éticos e Disseminação

A pesquisa observa os princípios éticos de consentimento informado dos participantes e anonimização dos dados coletados. Os artefatos desenvolvidos, incluindo código-fonte e documentação, estão disponíveis no repositório <https://github.com/diegogrosmann/EnsinaNet.AI>.

## 4. Projeto e Implementação do Artefato

A partir dos requisitos levantados no ciclo de relevância e fundamentados no ciclo de rigor, foi projetado e implementado o artefato EnsinaNet.AI, uma ferramenta web para automação da correção de atividades em redes de computadores, integrando múltiplos serviços de IA generativa.

Os requisitos do EnsinaNet.AI foram derivados do contexto educacional e das limitações observadas em sistemas existentes (JOVANOVIĆ et al., 2012; PHAM e




Nguyen, 2019; SANGUINO et al., 2018; FARIAS, 2008). A ferramenta permite autenticação de usuários, integração com múltiplos provedores de IA generativa (como OpenAI, Gemini, Claude, entre outros) e submissão automatizada de atividades via API REST versionada. O sistema suporta execução paralela de correções, extração de texto de arquivos e registro detalhado das interações para auditoria e ajustes pedagógicos.

Na Figura 1, destacam-se a modularidade para inclusão de novos modelos de IA e possibilidade de personalização dos Prompts. Sobressaem-se ainda a segurança no gerenciamento de dados, desempenho escalável e compatibilidade com diferentes ambientes institucionais.

A arquitetura do EnsinaNet.AI é modular e orientada a microsserviços, permitindo flexibilidade e escalabilidade (WANG GUY C. HEMBROFF, 2010; CUI et al., 2012).


**Figura 1: Captura de telas da configuração de modelo de IA e PROMPT.**



**Fonte: Elaborada pelos Autores (2025).**

Os principais componentes incluem autenticação, configuração de IA, exposição de *endpoints* para submissão e monitoramento de atividades, orquestração das correções, treinamento de modelos (*fine-tuning*) e *logging* estruturado das interações. A modularidade facilita adaptações futuras e integração com novos provedores. A Figura 2 apresenta a tela de Gerenciamento de modelos treinados, onde é possível treinar modelos específicos para ajustar suas respostas ao padrão esperado.

**Figura 2: Captura da tela de Gerenciamento de Treinamento.**





### **Fonte: Elaborada pelos Autores (2025).**

O fluxo de correção automatizada no EnsinaNet.AI apresenta as seguintes etapas:

1. O usuário autentica-se no sistema e gera um token de acesso;
2. Submete uma atividade (texto ou arquivo) para correção via API, informando o token;
3. O sistema valida o token e extrai o texto do arquivo (se necessário);
4. A camada de orquestração aciona, em paralelo, as IAs configuradas para o token, aplicando prompts e parâmetros definidos; e
5. As respostas das IAs são consolidadas e registradas em log.
6. Se a captura de exemplos estiver ativa, o sistema armazena o prompt e as respostas para uso futuro em fine-tuning.
7. O resultado é retornado ao usuário via API.

#### **4.1. Diferenciais do EsinaNet.AI**

O EnsinaNet.AI inova ao:

- Permitir integração simultânea de múltiplos provedores de IA generativa, facilitando comparação, validação cruzada e personalização do processo avaliativo;
- Oferecer arquitetura extensível, possibilitando rápida adaptação a novos provedores e paradigmas de IA;
- Dispor de workflows completos para captura de exemplos, fine-tuning e auditoria detalhada das interações, ampliando o potencial pedagógico e a transparência do sistema;
- Implementar mecanismos de resiliência circuit breaker, execução paralela e monitoramento centralizado, alinhando-se a requisitos de robustez e escalabilidade essenciais para EAD;
- Favorecer a atuação estratégica do docente, que passa a focar na análise pedagógica dos feedbacks e não apenas na execução mecânica das correções.

A construção e evolução do EnsinaNet.AI seguem o ciclo iterativo da DSR, promovendo refinamento incremental a partir de avaliações práticas, feedback de usuários e avanços no estado da arte.

#### **5. Avaliação do Artefato**

A avaliação do artefato EnsinaNet.AI foi realizada a partir da análise de respostas submetidas por diferentes alunos a atividades práticas de redes de computadores, utilizando múltiplos modelos de IA para correção automatizada. No total, foram analisadas respostas de quatro alunos para uma atividade, avaliadas por 16 modelos de IA diferentes, incluindo provedores como OpenAI, Gemini, Grok, Nous, Mixtral, Claude, Perplexity, Llama, entre outros. A lista completa de modelos está disponível em <https://encurtador.com.br/uyQrD>.



Cada resposta foi submetida a diferentes IAs permitindo observar tanto a diversidade de *feedbacks* quanto o desempenho relativo de cada modelo. O conjunto de dados analisado compreende tanto métricas quantitativas (como tempo de resposta dos modelos) quanto qualitativas (clareza, detalhamento técnico, personalização, correção conceitual, entre outras).

A atividade realizada consistiu no laboratório “Endereçamento IP Estático em Rede Local”, composto por seis questões abertas que abordam desde a configuração básica de rede até a análise de falhas e a interpretação de pacotes do protocolo ICMP.

### 5.1. Desempenho dos Modelos de IA

O tempo médio para análise de cada resposta variou de 14,3 a 44,4 s, com média geral de aproximadamente 24,6 s ( $DP = 10,5$  s) considerando todos os modelos testados.

Dentre os modelos, o *Grok-2-latest* apresentou o menor tempo médio de resposta (14,3 s), seguido pelo *Nous-Hermes-2-Mixtral-8x7B-DPO* (16,3 s) e *GPT-4o* (17,5 s). Por outro lado, modelos como *Gemini-2.0-pro-exp-02-05* (44,4 s) e *Deepseek-reasoner* (43,4 s) apresentaram tempos de resposta significativamente superior à média.

No que se refere à acurácia, definida como a proporção de *feedbacks* conceitualmente corretos ou pertinentes segundo a avaliação docente, destaca-se o modelo *Gemini-2.0-flash-thinking-exp-01-21*, que obteve 100% de acurácia. Outros modelos com desempenho elevado foram o *Gemini-1.5-pro*, *Gemini-2.0-pro-exp-02-05* e *GPT-4o*, todos com 87,5% de acurácia média. O modelo *Claude-3-5-sonnet-20241022* apresentou o menor desempenho, com 50% de acurácia.

Ao analisar detalhadamente os resultados, observa-se que o erro mais recorrente entre os modelos de IA foi a validação equivocada da justificativa “*Para garantir uma boa comunicação, garantir a entrega, a segurança e evitar conflitos na rede*” como resposta adequada à questão “*Por que é importante que cada dispositivo tenha um endereço IP único na rede?*”. Diversos modelos classificaram como corretas respostas que associavam a unicidade do IP à segurança, embora esse argumento não se sustente tecnicamente.

Esse padrão de erro indica que os modelos de IA, mesmo quando apresentam boas métricas de acurácia geral, ainda tendem a aceitar justificativas imprecisas ou equivocadas quando formuladas de maneira plausível. Tal constatação pode ser reflexo da solicitação de prompt para que o feedback se ajustasse ao nível do aluno. O que dever ser investigado.

A análise dos resultados destaca que há variação considerável entre os modelos tanto em relação à velocidade de processamento quanto à qualidade do feedback gerado. Modelos que apresentaram melhor desempenho conceitual, como *Gemini-2.0-flash* e *GPT-4o*, também mantiveram tempos de resposta próximos ou abaixo da média geral, demonstrando potencial para aplicação prática em cenários educacionais que demandam devolutivas rápidas e assertivas.

### 5.2. Qualidade dos *Feedbacks* Gerados

A avaliação qualitativa dos *feedbacks* produzidos pelos modelos de IA considerou critérios como clareza, detalhamento técnico, personalização, correção conceitual, estímulo à reflexão, sugestão de recursos complementares e padronização das devolutivas. Os resultados indicam avanços relevantes, mas também evidenciam padrões de limitações comuns a diferentes modelos.



De modo geral, a clareza foi o critério com melhor desempenho, com 87,5% das respostas classificadas como claras (56 de 64), sendo este índice elevado em praticamente todos os modelos testados. Modelos como *Gemini-2.0-flash-thinking-exp-01-21*, *Gemini-1.5-pro* e *GPT-4o* apresentaram alto índice de clareza, sempre acima de 85%. Entretanto, a análise do detalhamento técnico revelou maior dispersão: apenas 50% das devolutivas atenderam plenamente a esse critério, com destaque negativo para alguns modelos (como *deepseek-chat*) que, apesar de detalhar alguns pontos, tenderam à superficialidade em respostas mais abertas.

Quanto à personalização, 65,6% dos *feedbacks* foram considerados adaptados ao contexto da resposta do aluno, sendo este índice superior nos modelos com maior acurácia, como o *Gemini-2.0-flash* (que também se destacou em clareza e correção conceitual) e *GPT-4o*. Por outro lado, modelos como *claude-3-5-sonnet-20241022*, além de menor acurácia, apresentaram dificuldades para ajustar o comentário ao conteúdo específico apresentado pelo aluno, entregando devolutivas genéricas.

No critério de correção conceitual (73,4%), observa-se que, embora modelos como *Gemini-2.0-flash* tenha atingido 100% de acerto, houve padrão de erro recorrente: diversos modelos validaram como correta a justificativa de que a unicidade do IP "garante a segurança", demonstrando dificuldade em rejeitar argumentos tecnicamente imprecisos quando bem articulados. Tal padrão foi identificado, por exemplo, no *Gemini-2.0-pro-exp-02-05* e no *Grok-2-latest*, ambos com bom desempenho geral, mas suscetíveis a esse tipo de erro sutil.

O estímulo à reflexão esteve presente em 59,4% das respostas, com variações entre modelos — o *GPT-4o* apresentou boa performance nesse critério, incentivando o aluno a explorar soluções alternativas, enquanto modelos como *Nous-Hermes-2-Mixtral-8x7B-DPO* mantiveram abordagem mais direta e menos exploratória. Sugestões de recursos complementares foram observadas em 53,1% dos *feedbacks*, com destaque para *Gemini-1.5-pro* e *Deepseek-reasoner* nesse aspecto.

Já a padronização foi o maior desafio: apenas 29,7% dos *feedbacks* mantiveram padrão consistente, reflexo da diversidade de modelos e do ajuste dos prompts. O *Gemini-2.0-flash* e o *GPT-4o* tiveram melhor uniformidade nas respostas, mas ainda assim apresentaram pequenas variações estruturais.

A análise qualitativa indica que, apesar de avanços em clareza, personalização e correção conceitual, ainda existem oportunidades de melhoria quanto ao detalhamento técnico e à padronização dos comentários. O ajuste dos prompts e a curadoria docente permanecem essenciais para garantir devolutivas mais homogêneas e ricas pedagogicamente.

### 5.3. Discussão dos Resultados

Os resultados obtidos demonstram que a aplicação do EnsinaNet.AI é viável e eficaz para automatizar a correção de atividades em disciplinas de Redes de Computadores, especialmente em cenários com turmas grandes. O sistema mostrou ganhos em escalabilidade e redução do tempo de resposta, ao mesmo tempo em que manteve um padrão elevado de clareza e personalização dos *feedbacks*, alinhando-se ao objetivo de oferecer suporte qualificado ao docente.

Em relação à diversidade de modelos avaliados, ficou evidente que há variação tanto no tempo de processamento quanto na qualidade conceitual das devolutivas. Destacam-se como mais promissores os modelos *Gemini-2.0-flash-thinking-exp-01-21* (100% de acurácia), *Gemini-1.5-pro*, *Gemini-2.0-pro-exp-02-05* e *GPT-4o* (todos com



acurácia média de 87,5%), que também apresentaram bom desempenho em clareza, detalhamento técnico e personalização. Por outro lado, modelos como o Claude-3-5-sonnet-20241022 mostraram desempenho inferior (50% de acurácia), ressaltando a importância da escolha criteriosa dos motores para contextos educacionais.

A análise qualitativa confirma que a maioria dos *feedbacks* gerados é clara e personalizada, com destaque para a capacidade dos melhores modelos em adaptar a devolutiva ao perfil do estudante e estimular a reflexão. Contudo, limitações persistem quanto à padronização dos comentários e à validação de justificativas tecnicamente imprecisas, o que reforça a necessidade de curadoria docente e ajustes contínuos nos prompts.

De forma geral, o EnsinaNet.AI atinge os objetivos propostos, validando sua utilidade como ferramenta para a avaliação automatizada em ensino de redes. Os dados obtidos indicam que, ao integrar múltiplos modelos de IA e proporcionar flexibilidade ao docente, a solução contribui para o acesso a *feedbacks* de qualidade, ao mesmo tempo em que potencializa a eficiência do processo avaliativo.

## 6. Conclusão

Este trabalho investigou o uso de IA generativa para automatizar a correção de atividades em turmas numerosas de Redes de Computadores, tendo como foco a apresentação e validação do EnsinaNet.AI. A ferramenta demonstrou-se viável, destacando ganhos em escalabilidade, clareza e personalização dos *feedbacks*, alinhando-se às demandas do ensino e superando desafios enfrentados por docentes.

A análise dos resultados mostrou que modelos como Gemini-2.0-flash-thinking-exp-01-21, Gemini-1.5-pro, Gemini-2.0-pro-exp-02-05 e GPT-4o se destacaram em acurácia e qualidade das devolutivas, enquanto outros, como Claude-3-5-sonnet-20241022, apresentaram limitações. Ressalta-se, portanto, a importância de uma escolha criteriosa dos motores de IA, bem como o papel da curadoria docente para assegurar a qualidade conceitual e a adequação dos *feedbacks*.

Como principal contribuição, o EnsinaNet.AI representa uma abordagem flexível para avaliação automatizada, capaz de possibilitar o acesso a *feedbacks* personalizados, otimizar o tempo docente e fortalecer o ensino em redes de computadores. Os desafios relacionados à padronização dos comentários e à dependência de curadoria permanecem, mas a experiência indica que a solução é escalável e adaptável a diferentes contextos.

Portanto, recomenda-se a ampliação da plataforma para integração com laboratórios virtuais e automação da avaliação qualitativa, bem como o desenvolvimento de estudos em larga escala e a incorporação de abordagens éticas no uso da IA. Os resultados aqui apresentados reforçam o potencial do uso responsável da IA generativa como estratégia para qualificar e modernizar os processos avaliativos no ensino superior. Os próximos passos deste trabalho incluem a integração do EnsinaNet.AI a laboratórios virtuais, a fim de ampliar seu uso, automatizar e aprimorar a avaliação qualitativa dos *feedbacks* gerados, e buscar maior padronização nas devolutivas dos diferentes modelos de IA. Destaca-se, ainda, a necessidade de estudos em larga escala, bem como a análise das questões éticas e de privacidade relacionadas ao uso da IA na educação. Tais iniciativas visam consolidar o EnsinaNet.AI como uma solução viável para o ensino de Redes de Computadores.

## Referências



CADEIA, Á. S.; MAGNAGO, W.; SIQUEIRA, N. K.; BAIÔCO, L. V.; NUNES, P.C. O impacto da Inteligência Artificial na Educação a Distância: Vantagens, Desafios e Exemplos de Aplicação Bem-Sucedida. *Revista Sociedade Científica*, v. 7, n. 1, p. 4400-4408, 2024. DOI: 10.61411/rsc202476617.

CUI, L.; TSO, F. P.; YAO, D.; JIA, W. Wefilab: A web-based wifi laboratory platform for wireless networking education. *IEEE Transactions on Learning Technologies*, v. 5, n. 4, p. 291–303, 2012. DOI: 10.1109/TLT.2012.6

DURSO, SAMUEL DE OLIVEIRA. Reflexões sobre a aplicação da inteligência artificial na educação e seus impactos para a atuação docente. *Educação em Revista*. 2024. DOI: 10.1590/0102-469847980

FAGUNDES, A. C.; MIRANDA, H. P. S.; COSTA, L. A. CHAVES. R. O.; CALUNGA, W. P. O. Inteligência artificial na modalidade de educação a distância: desafios e perspectivas. *Ciências Humanas*, v. 29, ed. 146, 2025. DOI: 10.69849/revistaft/ch102025005110947.

FARIAS, A. F. Desenvolvimento de um Web Lab SOA no domínio de redes de computadores. Dissertação (Mestrado em Computação) — Universidade Federal de Uberlândia, Uberlândia, 2008. Disponível em: <https://repositorio.ufu.br/handle/123456789/12471>. Acessado em: 28/06/2025

HENDERSON, M.; RYAN, T.; PHILLIPS, M. The challenges of feedback in higher education. *Assessment & Evaluation in Higher Education*, v. 44, n. 8, 2019. DOI: 10.1080/02602938.2019.1599815.

HEVNER, A. R.; MARCH, S. T.; PARK, J.; RAM, S. Design science in information systems research. *Management Information Systems Quarterly*, v. 28, p. 75–105, 2004. DOI: 10.2307/25148625

HUTCHISON, J. J. The Impact of Instructor Workload on the Use of Written Corrective Feedback. 2022. 1 v. (Tese de Doutorado em Educação) – Walden University, Minneapolis, 2022. Disponível em: <https://www.proquest.com/openview/f77a1976f4fc74ccbe3caad371640537/1?pq-origsite=gscholar&cbl=18750&diss=y>. Acesso em: 18/06/2025

JOVANOVIĆ, N.; POPOVIĆ, R.; MARKOVIĆ, S.; JOVANOVIĆ, Z. Web laboratory for computer network. *Computer Applications in Engineering Education*, v. 20, n. 3, p. 493–502, 2012. DOI: 10.1002/cae.20417

LEE, S. S.; MOORE, R. L. Harnessing Generative AI (GenAI) for automated feedback in higher education: A systematic review. *Online Learning Journal*, v. 28, n. 3, p. 82–104, 2024. DOI: 10.24059/olj.v28i3.4593.

MERAYO, N.; AGUADO, J. C.; MIGUEL, I.; DURÁN, R. J.; FERNÁNDEZ, P.; LORENZO, R. M.; ABRIL, E. J. A testbed and a simulation laboratory for training engineering students in optical access network technologies. *Computer Applications in Engineering Education*, v. 29, n. 6, p. 1892–1910, 2021. DOI: 10.1002/cae.22429

NUGROHO, E. P.; YULIANA, R.; JUNAETI, E.; KUSNENDAR, J.; PRABAWA, H. W. Using simulation in network security learning. *Journal of Physics: Conference Series*, v. 1280, p. 032038, 2019. DOI: 10.1088/1742-6596/1280/3/032038

OLSEN, T.; HUNNES, J. Improving students' learning—the role of formative feedback: experiences from a crash course for business students in academic writing.



Assessment & Evaluation in Higher Education, v. 49, n. 2, 2024. DOI: 10.1080/02602938.2023.2187744.

Pham, H. T. N.; Nguyen, A. T. Eve virtualization-based lab: A new approach in teaching network for students. In: Proceedings of the 2019 International Conference on Information Technology Education (ICITE). Danang, Vietnam: University of Danang, 2019. p. 98–106.

Sanguino, M. T. D. J.; González F. V. I. J.; Ancos, C. E.; Fernández, E. J. Exploring strengths and weaknesses: A case study after developing a remote network lab. Computer Applications in Engineering Education, v. 26, n. 5, p. 1422–1434, 2018. DOI: 10.1002/cae.21981

UNESCO. Para aproveitar a era da inteligência artificial na educação superior: um guia às partes interessadas do ensino superior. Paris: UNESCO, 2023.

VENTER, J.; COETZEE, S. A.; SCHMULIAN, A. Exploring the use of artificial intelligence (AI) in the delivery of effective feedback. Assessment & Evaluation in Higher Education, v. 50, n. 4, 2025. DOI: 10.1080/02602938.2024.2415649.

WANG, G. C. H.; HEMBROFF, R. Y. X. Using vmware vcenter lab manager in undergraduate education for system administration and network security. In: Proceedings of the ACM SIGITE Conference on Information Technology Education (SIGITE '10). Midland, Michigan, USA: ACM, 2010. p. 43–51. DOI: 10.1145/1867651.1867665.