

# Integração de IA Generativa e Repositórios Educacionais: Potencializando a Eficácia Pedagógica e a Recomendação de Conteúdos com o LLaMA2

Renan Zafalon da Silva<sup>1</sup>, Paulo Cesar Ramos Pinho<sup>1</sup>, Maria Isabel Giusti Moreira<sup>2</sup>,  
Raymundo Carlos Machado Ferreira Filho<sup>2</sup>, Tiago Thompen Primo<sup>1</sup>

<sup>1</sup>Programa de Pós-Graduação em Ciência da Computação  
Universidade Federal de Pelotas (UFPEL) Pelotas - RS - Brazil

<sup>2</sup>Instituto Federal Sul-rio-grandense  
Câmpus Pelotas Visconde da Graça, Pelotas - RS - Brazil

{renan.zafalon, paulo.pinho, tiago.primo}@inf.ufpel.edu.br,  
mariamoreira, raymundofilho}@ifsul.edu.br

**Abstract.** *This article presents the development of an educational recommendation system based on generative artificial intelligence (GenAI) integrated with the ProEdu repository. The system aims to personalize learning by suggesting content and learning paths tailored to the individual needs of students. Utilizing the LLaMA2 transformer model, the proposal addresses the integration of AI to enhance pedagogical effectiveness and student engagement. The applied methodology includes case studies and feedback analysis, allowing for continuous evaluation and refinement of the system. The results indicate significant potential in personalizing learning and improving academic outcomes.*

**Resumo.** *Este artigo apresenta o desenvolvimento de um sistema de recomendação educacional baseado em inteligência artificial generativa (IA-Gen) integrado ao repositório ProEdu. O sistema visa personalizar a aprendizagem ao sugerir conteúdos e itinerários formativos adaptados às necessidades individuais dos alunos. Utilizando o modelo Transformer LLaMA2, a proposta aborda a integração de IA para aprimorar a eficácia pedagógica e o engajamento dos estudantes. A metodologia aplicada inclui estudos de caso e análise de feedback, permitindo uma avaliação contínua e refinamento do sistema. Os resultados indicam potencial significativo na personalização do aprendizado e na melhoria dos resultados acadêmicos.*

## 1. Introdução

A inteligência artificial (IA) tem se consolidado como uma ferramenta revolucionária na educação, oferecendo a capacidade de personalizar o aprendizado e fornecer *feedback* imediato. Os sistemas de recomendação (SR), que utilizam IA, desempenham um papel crucial ao orientar usuários através de enormes volumes de dados, sugerindo recursos educacionais que estão alinhados com suas preferências e necessidades específicas [Bobadilla et al. 2013]. Na educação, a inteligência artificial generativa (IAGen) é aplicada de diversas formas. Plataformas de tutoria inteligente, como o Duolingo, utilizam IAGen para desenvolver conteúdo de aprendizado de idiomas ajustado em tempo

real com base no desempenho do aluno. A IAGen e os Sistemas de Recomendação Educacional (SRE) oferecem soluções poderosas para personalizar e enriquecer a experiência de aprendizado, atendendo às necessidades individuais dos alunos. Elas facilitam a identificação de lacunas no conhecimento, fornecem materiais de estudo relevantes e criam experiências de aprendizado adaptativas, tornando o aprendizado mais acessível, inclusivo e eficaz.

Este projeto de pesquisa visa desenvolver e implementar um sistema de recomendação baseado em IA generativa, integrado ao repositório de conteúdos educacionais ProEdu. O repositório ProEdu, é uma plataforma digital destinada ao armazenamento, organização e disponibilização de materiais educativos e científicos. O objetivo do trabalho é proporcionar recomendações eficientes de itinerários formativos, aprimorando a personalização e a eficácia do processo educacional. O trabalho propõe uma solução com IA generativa e repositórios educacionais de forma a contribuir com estado da arte da literatura e possibilitar avanço na personalização e recomendação de conteúdos obtidos por repositório educacional. Além disso a questão de pesquisa também busca compreender de forma mais aprofundada o impacto da IAGen no desenvolvimento acadêmico de alunos e professores.

A personalização do aprendizado é uma estratégia essencial no cenário educacional contemporâneo, caracterizado pela diversidade de perfis de alunos e pelas variadas necessidades de aprendizagem. Esta diversidade exige abordagens pedagógicas que sejam não apenas flexíveis, mas também adaptativas, capazes de atender às particularidades de cada estudante. A integração de inteligência artificial generativa com recursos educacionais oriundos de repositórios digitais apresenta um potencial significativo para a personalização das recomendações de conteúdos educacionais. Tal integração pode levar a melhorias mensuráveis nos resultados acadêmicos e no engajamento tanto de alunos quanto de educadores. Este projeto está em consonância com as demandas atuais por inovação educacional, representando um avanço crucial na adoção de tecnologias de ponta no ensino. Ao explorar a aplicação de IA generativa, o projeto busca não apenas otimizar a eficácia pedagógica, mas também fomentar uma cultura de aprendizagem mais inclusiva e motivadora, adaptando-se continuamente às evoluções do conhecimento e às dinâmicas do ambiente educacional.

O presente trabalho está estruturado da seguinte forma: na seção 1, é apresentada a introdução do estudo; a seção 2 abrange a fundamentação teórica; a seção 3 oferece um resumo da revisão sistemática realizada em pesquisas anteriores. A seção 4 detalha a metodologia utilizada para o desenvolvimento da aplicação, enquanto a seção 5 descreve o projeto do sistema de recomendação baseado em IA generativa. Na seção 6, são discutidas a proposta de desenvolvimento e os objetivos da pesquisa. Finalmente, na seção 7, são apresentadas as conclusões do estudo e os próximos passos a serem seguidos.

## **2. Fundamentação Teórica**

A Inteligência Artificial Generativa (IAGen) representa uma vertente da inteligência artificial que se dedica à criação de novos dados, como imagens, músicas ou textos, utilizando modelos de aprendizado de máquina. Diferente da simples análise e classificação de dados preexistentes, a IAGen treina modelos em vastos conjuntos de dados, conhecidos como Modelos de Linguagem de Grande Escala (LLMs), para produzir novos dados

com base nesse aprendizado [Bilgram and Laarmann 2023]. Um exemplo notável dentro dessa categoria é o LLaMA2, a segunda versão de uma série de modelos de linguagem desenvolvidos pela Meta AI (anteriormente conhecida como Facebook AI). Esses modelos foram projetados para entender e gerar texto em linguagem natural, destacando-se entre os LLMs por sua capacidade de processamento e geração de conteúdo textual.

O progresso nas técnicas de geração de conteúdo tem sido notável, impulsionando o desenvolvimento de diversos modelos generativos. Entre os modelos mais destacados estão as Redes Generativas Adversariais (GANs), propostas por [Goodfellow et al. 2014], que desempenham um papel crucial na criação de conteúdos realistas. As GANs consistem em duas redes neurais que são treinadas simultaneamente: uma rede geradora, que cria amostras, e uma rede discriminadora, que avalia a autenticidade dessas amostras. Esse processo de competição gera um ciclo iterativo de aprendizagem, no qual as amostras produzidas se tornam cada vez mais realistas e de alta qualidade.

Além das GANs, a Geração Aumentada por Recuperação (RAG), quando integrada a modelos de linguagem de grande porte (LLMs), aprimora significativamente a precisão das respostas ao combinar a geração de texto com a recuperação de informações em tempo real. Nesse método, um sistema de busca é utilizado para recuperar documentos ou dados relevantes, que são processados e integrados ao conteúdo gerado pelo modelo. Por exemplo, o LLaMA2, ao responder a consultas, acessa fontes de informação atualizadas, proporcionando maior acurácia e relevância nas respostas fornecidas [Lewis et al. 2020].

Adicionalmente, as redes generativas que utilizam mecanismos de atenção, como o *transformer*, proposto por [Vaswani et al. 2017], têm se destacado especialmente na geração de textos e na tradução automática. Esses modelos capturam relações semânticas e sintáticas em sequências de texto, permitindo a produção de traduções que são ao mesmo tempo fluentes e coerentes. Em conjunto, essas abordagens avançadas expandem significativamente as aplicações da IA Generativa, cada uma contribuindo de maneira distinta para a criação de conteúdos inovadores. Outro processo relevante de uma IA generativa é o *fine-tuning*, é um método de ajuste de um modelo pré-treinado em um novo conjunto de dados específico, para que ele produza resultados mais alinhados a uma aplicação particular. Este ajuste é realizado treinando o modelo em um subconjunto menor e mais relevante de dados, permitindo que ele se adapte às nuances e contextos específicos da nova tarefa [Howard and Ruder 2018].

### 3. Revisão Sistemática da Literatura

A revisão sistemática sobre inteligência artificial generativa (IAGen) e sistemas de recomendação educacionais investigou as principais técnicas utilizadas, o impacto da IAGen na personalização de recomendações, e suas possibilidades em contextos educacionais. A metodologia seguida para a condução dessa revisão foi sistematizada e estruturada, baseada no protocolo de *Kitchenham* [Kitchenham et al. 2007]. A metodologia do processo da revisão sistemática incluiu várias etapas importantes, dentre elas:

- **Definição do tema de pesquisa:** O foco foi a aplicação de IAGen em sistemas de recomendação educacionais, buscando identificar lacunas e oportunidades na literatura existente.

- **Definição das palavras-chave e repositórios de busca:** utilizou-se uma combinação de termos específicos como "educational recommendation systems" AND "generative artificial intelligence" AND "machine learning in education". As buscas foram realizadas em bases de dados renomadas, como IEEE Xplore, ScienceDirect, Springer Link, ACM Digital Library, e Google Acadêmico.
- **Levantamento e seleção de artigos:** foram analisados mais de 17.000 artigos, dos quais 21 foram selecionados para a revisão detalhada, seguindo critérios de inclusão e exclusão rigorosos. Artigos duplicados, não acessíveis na íntegra, ou que não abordassem diretamente o tema foram excluídos.
- **Leitura crítica e síntese dos estudos selecionados:** Os artigos selecionados foram lidos integralmente, e as informações relevantes foram sintetizadas para responder a oito questões de pesquisa específicas, que abordavam desde as técnicas de IA utilizadas até a acessibilidade e a operação offline dos sistemas de recomendação.

Os resultados da revisão destacaram várias lacunas na literatura. Embora a IA-Gen demonstre grande potencial para personalizar a experiência de aprendizado, faltam estudos que explorem a acessibilidade para alunos com deficiências e a viabilidade de sistemas de recomendação operando *offline*. Além disso, a integração e reutilização eficazes de repositórios educacionais ainda são áreas pouco exploradas, sugerindo que futuras pesquisas devem focar na otimização desses recursos para melhorar a personalização do aprendizado. Resultados detalhados da relação entre os artigos e as questões que subsidiaram os resultados, os gráficos que apresentam os resultados da pesquisa e conclusões estão disponíveis no seguinte endereço <sup>1</sup>.

#### 4. Metodologia

A presente pesquisa adotará uma metodologia integrada que combina o desenvolvimento de software com métodos de pesquisa-ação. Essa abordagem permitirá uma análise aprofundada e iterativa das interações entre os usuários e a plataforma desenvolvida. Estudos de caso detalhados serão conduzidos com participantes que utilizam a plataforma, desempenhando um papel ativo na identificação de problemas, desenvolvimento de intervenções e análise dos resultados. Esses estudos de caso serão fundamentais para compreender as complexidades contextuais do uso do sistema em ambientes reais. Além disso, serão aplicados questionários estruturados aos usuários voluntários para a coleta de dados quantitativos e qualitativos, que serão cruciais para avaliar a experiência de uso do sistema e obter *insights* sobre a eficácia das intervenções implementadas. A coleta e análise desses dados permitirão uma triangulação robusta dos resultados, assegurando a validade e confiabilidade das conclusões da pesquisa.

Para o treinamento do modelo de recomendação de recursos educacionais, foi escolhido o *transformer* LLaMA2 devido à sua arquitetura avançada, que permite o processamento paralelo e eficiente de grandes volumes de dados. O LLaMA2 acelera o treinamento ao dividir tarefas entre várias unidades de processamento, otimizando o uso dos recursos computacionais. Além disso, sua estrutura modela com precisão padrões complexos em dados textuais, garantindo maior personalização e relevância nas recomendações educacionais. A escolha do *transformer* LLaMA2 também se alinha com as necessidades

<sup>1</sup><https://anonymous.4open.science/r/artigo-B8FF/TABELAS.pdf>

de escalabilidade e flexibilidade requeridas em sistemas educacionais modernos, garantindo não apenas a eficiência no treinamento, mas também um desempenho robusto na aplicação prática. Em comparação com outros modelos, como o GPT-3, o LLaMA2 se destaca por sua otimização para rodar em infraestruturas computacionais menos robustas, o que o torna uma opção econômica e escalável para ambientes educacionais. Sua capacidade de ajuste fino também permite adaptações específicas a diferentes contextos, como o ProEdu, resultando em recomendações altamente personalizadas que atendem às necessidades individuais dos alunos.

Para a coleta de dados, serão aplicados questionários estruturados a usuários voluntários, com o objetivo de gerar dados quantitativos e qualitativos. Os dados quantitativos serão analisados por meio de técnicas estatísticas descritivas e inferenciais, utilizando bibliotecas Python como *pandas*, *NumPy*, *SciPy* e *statsmodels*. A IAGen foi utilizada nesse trabalho para revisão textual e para complementar a fundamentação teórica [OpenAI 2023].

## 5. Projeto do Recomendador de IA Generativa

A figura 1, apresenta um fluxograma geral do funcionamento do modelo de recomendação com IA generativa.

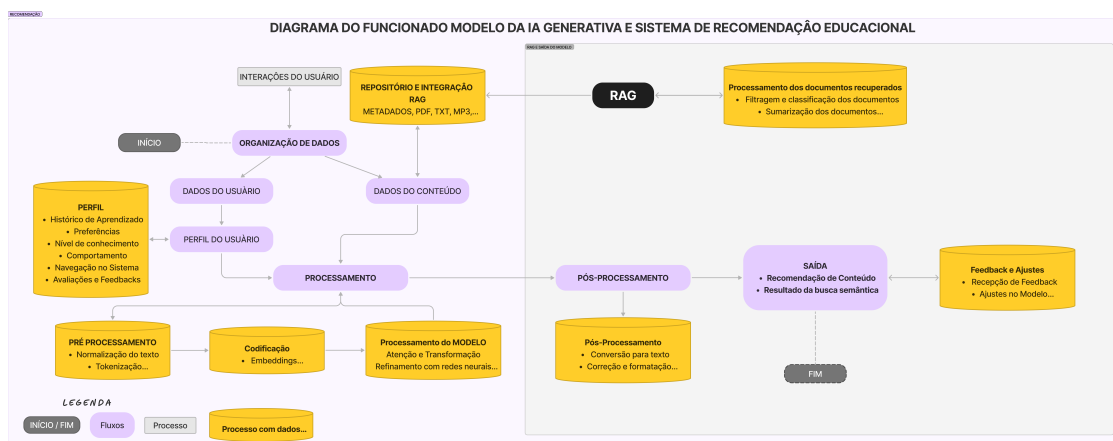


Figura 1. Fluxograma do funcionamento modelo de recomendação

Inicialmente, o sistema se prepara para receber interações do usuário que servirão para preparação e inicialização do funcionamento do modelo. Abaixo está listado o passo a passo do funcionamento do modelo:

- **Coleta de dados do perfil do usuário:** o sistema considera diversos aspectos do perfil do usuário, como histórico de aprendizado, preferências, nível de conhecimento, comportamento de navegação no sistema, e avaliações ou *feedbacks* anteriores. Esses dados são necessários para personalizar a experiência de uso e otimizar a geração de recomendações ou respostas.
- **Organização dos dados:** essa etapa inclui a normalização, limpeza e estruturação dos dados tanto do usuário quanto do conteúdo disponível.
- **Dados do Conteúdo:** Refere-se à integração e manipulação de dados referentes ao conteúdo disponível para recomendação, incluindo metadados de arquivos, textos,

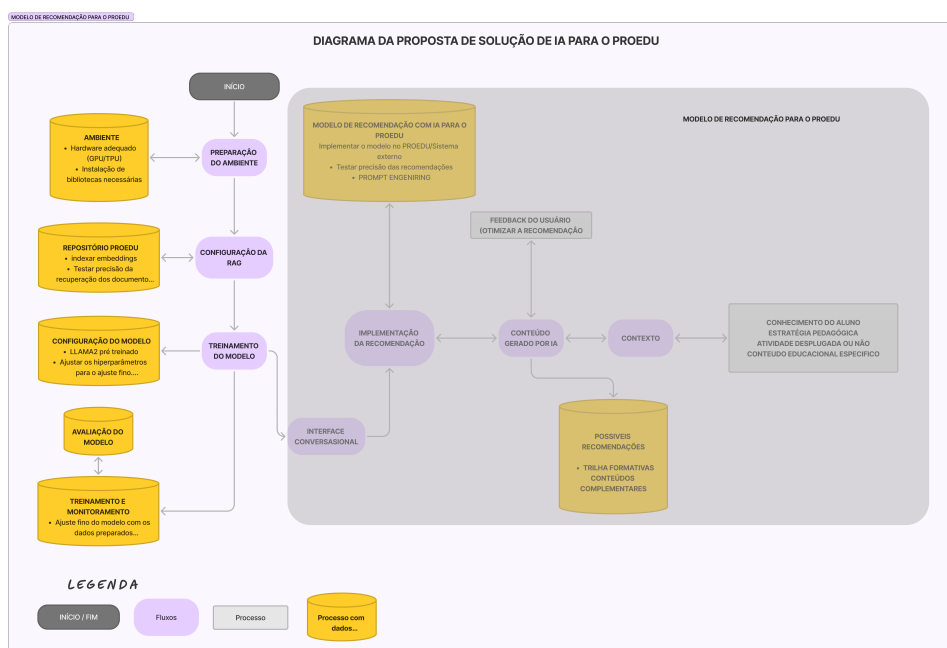


Figura 2. Fluxograma do modelo de recomendação para o repositório ProEdu

PDFs, áudios, entre outros formatos. Estes dados são essenciais para a fase de recuperação de informações (RAG).

- **Repositório e Integração RAG:** representa a integração com um repositório de informações onde os dados recuperáveis estão armazenados.
- **Processamento dos Documentos Recuperados:** após a recuperação, os documentos passam por filtragem, classificação e sumarização, sendo então integrados à entrada do modelo para fornecer contexto ou informações relevantes.
- **Processamento:** esta fase compreende o processamento dos dados do usuário e do conteúdo, incluindo codificação de *embeddings* e o uso de transformadores e outras redes neurais para refinar as representações de dados e gerar saídas apropriadas.
- **Pós-processamento:** nesta fase, o texto gerado é refinado, corrigido e formatado antes de ser apresentado ao usuário. Isso pode incluir tarefas como verificação gramatical, ajuste de estilo ou sumarização final.
- **Saída:** a saída inclui a recomendação de conteúdo ou resultados de buscas semânticas realizadas pelo sistema. Esta é a resposta final que é entregue ao usuário.
- **Feedback e Ajustes:** após a entrega da saída, o sistema coleta feedback do usuário para ajustar e refinar o modelo. Esse feedback é fundamental para a melhoria contínua do sistema.

Na figura 2, foi apresentado um diagrama com os fluxos do modelo que vai ser utilizado na recomendação de conteúdos e busca semântica para o ProEdu. Abaixo está listado o passo a passo do funcionamento do modelo:

- **Preparação do Ambiente:** nessa fase o ambiente de desenvolvimento será configurado adequadamente. Isso inclui a disponibilidade de hardware adequado (como GPUs ou TPUs) e a instalação das bibliotecas de software necessárias para o treinamento de modelos de IA.

- **Repositório PROEDU:** o repositório de dados do PROEDU será configurado para indexar embeddings e testar a precisão na recuperação de documentos. Isso é essencial para a fase de recuperação de informações (RAG), que suporta a recomendação educacional.
- **Configuração da RAG:** a configuração da etapa de recuperação de informações (RAG) envolve a preparação dos dados indexados para garantir uma recuperação eficiente. Este processo assegura que os documentos mais relevantes sejam prontamente acessíveis ao modelo de IA, otimizando a qualidade e a precisão das respostas fornecidas.
- **Configuração do Modelo:** um modelo pré-treinado (neste caso, LLaMA2) é configurado e ajustado com hiperparâmetros específicos para o PROEDU. O ajuste fino é uma etapa crucial para adaptar modelos pré-treinados a contextos específicos.
- **Treinamento do Modelo:** nesta fase, o modelo é treinado utilizando os dados específicos do PROEDU. O treinamento inclui a aplicação de técnicas de ajuste fino e a integração com o RAG configurado anteriormente.
- **Interface Conversacional:** o sistema de IA é integrado a uma interface conversacional, que permite interações diretas com os usuários para fornecer recomendações e coletar *feedback*.
- **Implementação da Recomendação:** a recomendação gerada pelo modelo é implementada e apresentada ao usuário através da interface conversacional. Este é o ponto onde o modelo converte as informações recuperadas em sugestões úteis para o usuário.
- **Conteúdo Gerado por IA:** o conteúdo gerado pelo modelo de IA é contextualizado e preparado para ser apresentado ao usuário. Isso inclui a aplicação de técnicas de NLP para garantir que o conteúdo seja relevante e bem formatado.
- **Possíveis Recomendações:** baseado no conteúdo gerado e no contexto do usuário, são feitas possíveis recomendações, como trilhas formativas e conteúdos complementares.
- **Contexto:** o contexto do usuário, que inclui informações sobre o conhecimento prévio, a estratégia pedagógica, e as atividades educacionais, é considerado ao gerar e personalizar as recomendações.
- **Feedback do Usuário:** *feedback* contínuo dos usuários é coletado para otimizar o sistema de recomendação. Este *feedback* é utilizado para ajustar o modelo e melhorar a qualidade das recomendações futuras.

## 6. Proposta

O desenvolvimento de um sistema de recomendação baseado em inteligência artificial (IA) generativa para sugerir conteúdos educacionais e itinerários formativos personalizados a partir do repositório de conteúdos ProEdu, propõe uma inovação significativa no campo da educação. Este sistema visa proporcionar uma experiência de aprendizagem altamente personalizada tanto para alunos quanto para professores, atendendo às necessidades individuais e promovendo uma educação mais eficaz e envolvente. Os objetivos específicos do projeto são:

- Desenvolver um modelo de IA que seja capaz de analisar e aprender com o histórico de aprendizado e as preferências de alunos e professores, permitindo recomendações personalizadas.

- Integrar uma ampla variedade de conteúdos educativos, como artigos e exercícios práticos, adaptados aos diferentes estilos de aprendizagem, otimizando a experiência de ensino-aprendizagem.
- Criar um mecanismo de *feedback* contínuo, que possibilite aos alunos avaliar a relevância das recomendações recebidas, contribuindo assim para a constante melhoria do sistema de recomendação.
- Implementar uma interface amigável e acessível, que se integre de maneira fluida ao ambiente do repositório de conteúdos, facilitando a usabilidade.
- Monitorar e analisar o acesso dos alunos, com base em suas interações e engajamento com os conteúdos recomendados, visando ajustes contínuos no sistema.

A personalização do aprendizado emergiu como uma estratégia indispensável no contexto educacional contemporâneo, marcado pela diversidade de perfis estudantis e pela variedade de necessidades de aprendizagem. A demanda por abordagens pedagógicas flexíveis e adaptativas, capazes de responder às especificidades de cada aluno, é crescente. Nesse sentido, a integração de inteligência artificial generativa com recursos educacionais provenientes de repositórios digitais oferece um potencial transformador. A personalização das recomendações educacionais pode resultar em melhorias significativas nos resultados acadêmicos e no engajamento, tanto de estudantes quanto de educadores. Ao explorar a aplicação da IA generativa, o projeto busca não apenas otimizar a eficácia pedagógica, mas também promover uma cultura de aprendizagem mais inclusiva e motivadora.

## 7. Conclusão

Esta pesquisa evidenciou a importância crucial da integração entre inteligência artificial generativa e repositórios educacionais que contêm conteúdos curados, como o ProEdu, para a personalização e aprimoramento da eficácia pedagógica. A utilização do modelo *Transformer* LLaMA2, em combinação com uma metodologia robusta de estudos de caso e análise contínua de *feedback*, resultou em um sistema de recomendação altamente eficiente. Esse sistema é capaz de identificar e sugerir conteúdos que não apenas atendem às necessidades específicas dos alunos, mas também são alinhados com os objetivos educacionais mais amplos. A curadoria de conteúdos dentro de repositórios como o ProEdu, quando aliada a um sistema de recomendação inteligente, amplifica o impacto educacional, garantindo que os alunos acessem materiais relevantes e de alta qualidade.

Os resultados iniciais do trabalho revelam lacunas significativas na contribuição para os repositórios educacionais, particularmente na integração de recomendações de conteúdos com o uso de IA generativa. Os próximos passos do projeto de pesquisa serão:

- Treinamento do modelo LLaMA2 com a base de conteúdos do repositório do ProEdu.
- Implementação de busca semântica em um sistema integrado ao ProEdu.
- Implementação da recomendação de conteúdos personalizada conforme perfil do usuário.
- Realização de testes com usuários voluntários, incluindo alunos, professores e servidores.
- Aplicação de questionários aos usuários voluntários para coletar *feedback*.
- Análise dos logs do sistema em conjunto com as respostas dos questionários para validar o funcionamento do sistema.



## Referências

- Bilgram, V. and Laarmann, F. (2023). Accelerating innovation with generative ai: Ai-augmented digital prototyping and innovation methods. *IEEE Engineering Management Review*, pages 1–5.
- Bobadilla, J., Ortega, F., Hernando, A., and Gutiérrez, A. (2013). Recommender systems survey. *Knowledge-based systems*, 46:109–132.
- Goodfellow, I., Pouget-Abadie, J., Mirza, M., Xu, B., Warde-Farley, D., Ozair, S., Courville, A., and Bengio, Y. (2014). Generative adversarial nets. In Ghahramani, Z., Welling, M., Cortes, C., Lawrence, N., and Weinberger, K., editors, *Advances in Neural Information Processing Systems*, volume 27. Curran Associates, Inc.
- Howard, J. and Ruder, S. (2018). Universal language model fine-tuning for text classification. In *Proceedings of the 56th Annual Meeting of the Association for Computational Linguistics (ACL)*. Association for Computational Linguistics.
- Kitchenham, B., Charters, S., et al. (2007). Guidelines for performing systematic literature reviews in software engineering.
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., Yih, W.-t., Rocktäschel, T., et al. (2020). Retrieval-augmented generation for knowledge-intensive nlp tasks. In *Advances in Neural Information Processing Systems*, volume 33, pages 9459–9474.
- OpenAI (2023). Openai. Accessed: 2024-08-15.
- Vaswani, A., Shazeer, N., Parmar, N., Uszkoreit, J., Jones, L., Gomez, A. N., Kaiser, Ł., and Polosukhin, I. (2017). Attention is all you need. *Advances in neural information processing systems*, 30.