

Guia de estudo personalizado com LLM e arquitetura multi-agente

Kleber José Araujo Galvão Filho¹, Ranielson Oscar Araújo Paiva¹, Giseldo da Silva Neo²,
Alana Viana Borges da Silva Neo³, Evandro de Barros Costa¹,
Olival de Gusmão Freitas Júnior¹

¹Instituto de Computação – Universidade Federal de Alagoas (UFAL)

²Instituto Federal de Alagoas (IFAL)

³Instituto Federal do Mato Grosso do Sul (IFMS)

{kjagf, ranilsonpaiva, olival, evandro}@ic.ufal.br

alana.viana@copin.ufcg.edu.br, giseldo.neo@ifal.edu.br

Abstract. Teacher overload and the need for personalization are constant challenges in technical education. This study proposes to mitigate such issues through the use of a recommendation system based on large language models (LLMs) and intelligent agents. The tool collects data provided by students and automatically generates study plans adapted to each learner's time availability and focus. An evaluation with 16 students, based on the Technology Acceptance Model (TAM), revealed high acceptance, with emphasis on interface clarity and ease of use. The system contributes to more effective pedagogical practices, reduces teacher workload, and preserves critical instructional mediation. It is a viable and scalable solution for contemporary educational contexts.

Resumo. A sobrecarga docente e a necessidade de personalização representam desafios constantes no ensino técnico. Este estudo propõe minimizar tais problemas com o uso de um sistema de recomendação baseado em LLMs e agentes inteligentes. A ferramenta coleta dados fornecidos pelos estudantes e gera automaticamente planos de estudo adaptados ao tempo e foco de cada um. A avaliação com 16 alunos, baseada no modelo TAM, revelou alta aceitação, com destaque para a clareza da interface e facilidade de uso. O sistema contribui para práticas pedagógicas mais eficazes, reduz a carga do professor e mantém sua mediação crítica. Trata-se de uma solução viável e escalável para o contexto educacional contemporâneo.

1. Introdução

A pandemia de COVID-19 impactou profundamente a educação, ampliando a carga de trabalho e os níveis de estresse entre docentes da educação básica, média e técnica. Estudos realizados nesse período apontam um aumento expressivo de sobrecarga e sintomas de *burnout*. Uma meta-análise global realizada até 2022 revelou que, em média, 52% dos professores apresentaram sinais de exaustão emocional, superando inclusive profissionais da saúde [Ozamiz-Etxebarria et al. 2023].

No Brasil, levantamento com 6.775 docentes da rede pública mostrou que 71% deles sentiam-se estressados pela carga de trabalho no período pós-pandemia

[Ferreira 2023]. A adoção emergencial do ensino remoto e híbrido demandou rápida adaptação a novas tecnologias, muitas vezes sem suporte institucional, resultando em ampliação da jornada laboral e interferência na vida pessoal. Relatos docentes indicam também níveis elevados de ansiedade, medo e enfraquecimento dos limites entre as esferas profissional e privada, especialmente em função do *home office* [Nascimento et al. 2023].

Esse cenário compromete não apenas a saúde dos professores, mas também a qualidade do ensino. Ao mesmo tempo, as lacunas de aprendizagem deixadas pelo ensino remoto intensificaram a demanda por práticas pedagógicas personalizadas. Contudo, a personalização tradicional exige esforços adicionais dos docentes, o que pode agravar ainda mais sua sobrecarga.

Nesse contexto, tecnologias educacionais avançadas emergem como alternativas para mitigar o excesso de trabalho e viabilizar práticas personalizadas em larga escala. Sistemas de recomendação educacional e *Large Language Models (LLMs)* vêm sendo utilizados com esse propósito, automatizando etapas como curadoria e planejamento de conteúdo [Bhatt et al. 2025, Silva et al. 2023]. Modelos como o GPT-4 têm sido empregados com sucesso na geração de materiais didáticos, correção de atividades e suporte ao aluno, atuando como tutores adaptativos [Mai et al. 2024, Luo 2024].

Diante dessa realidade, este trabalho parte do seguinte problema: a sobrecarga de trabalho docente, associada à escassez de materiais personalizados e à limitação da interação individualizada entre professores e estudantes. Considerando esse cenário, o objetivo da proposta é reduzir tal carga de trabalho por meio da geração automatizada de guias e planos de estudo personalizados, promovendo um apoio pedagógico mais eficaz e adaptado às necessidades específicas de cada aluno.

Para alcançar esse objetivo, propõe-se a utilização de *Large Language Models (LLMs)* combinados à orquestração de agentes especializados, capazes de interpretar os dados fornecidos pelos próprios estudantes e, a partir disso, personalizar a orientação pedagógica. A metodologia adotada, portanto, integra tecnologias emergentes com vistas ao desenvolvimento de um sistema capaz de automatizar a criação desses artefatos pedagógicos, otimizando o processo educacional e oferecendo suporte efetivo à prática docente.

2. Fundamentação Teórica

Segundo Zabala [Zabala 1998], instrumentos de orientação pedagógica, como os guias de estudo, promovem a autonomia discente ao estruturarem a aprendizagem por meio de objetivos, conteúdos e atividades previamente organizados. De acordo com Zimmerman [Zimmerman 2002], o planejamento e o monitoramento da aprendizagem são componentes centrais da autorregulação — definida como um conjunto de estratégias cognitivas, comportamentais e motivacionais utilizadas pelos alunos para planejar, monitorar e avaliar seu próprio aprendizado de forma autônoma e eficaz.

Large Language Models (LLMs), como o GPT-4 e o LLaMA, têm ampliado as possibilidades de personalização da aprendizagem, viabilizando tutores virtuais e assistentes pedagógicos [Mai et al. 2024, Luo 2024]. Estudos destacam benefícios como explicações contextualizadas, apoio à escrita e estruturação de planos de ensino. Um exemplo é o *GPTutor*, que elabora trilhas de estudo personalizadas com base no perfil cognitivo do aluno [Chen et al. 2024].

Entretanto, esses modelos apresentam limitações relevantes, como a geração de respostas imprecisas, presença de vieses nos dados de treinamento e desafios éticos relacionados à transparência e confiabilidade. Assim, destaca-se a importância da mediação crítica por parte do professor, garantindo que essas tecnologias sejam aplicadas com responsabilidade pedagógica.

A orquestração de agentes baseada em *LLMs*, viabilizada por frameworks como o CrewAI, permite a construção de sistemas compostos por agentes especializados que atuam de forma coordenada na solução de tarefas complexas [Groq Inc. 2024, Winland et al. 2024].

No campo da educação, essa abordagem tem sido aplicada ao desenvolvimento de tutores inteligentes, como o *DSA Tutor*, que integra agentes voltados à explicação conceitual, proposição de exercícios e suporte motivacional [Neil 2024]. Essa estrutura contribui para a personalização do ensino e pode reduzir a sobrecarga docente por meio da automação de etapas específicas do processo pedagógico.

3. Metodologia

Este estudo caracteriza-se como uma pesquisa aplicada, de natureza experimental, com abordagem quantitativa. Os usuários acessaram a proposta (**KMGuide**) e, após utilizá-la, preencheram um questionário de avaliação da ferramenta.

O questionário utilizado foi baseado no *Technology Acceptance Model* (TAM), proposto por Davis [Davis 1989], amplamente adotado na área de sistemas de informação. Os construtos avaliados foram: *Utilidade Percebida* (UP), *Facilidade de Uso Percebida* (FUP), *Atitude em Relação ao Uso* e *Intenção de Uso* (IU). Também foram incluídos itens sobre *Variáveis Externas* (VE), como clareza da interface e navegação.

As assertivas do questionário foram estruturadas em escala de Likert de 5 pontos (1 = discordo totalmente; 5 = concordo totalmente). Para a análise estatística, foram utilizadas medidas descritivas — média, mediana e desvio padrão — a fim de identificar tendências e consistência nas percepções dos participantes.

A amostra foi composta por 16 estudantes regularmente matriculados no curso técnico em Informática de uma instituição pública. A participação foi voluntária, mediante aceite de termo de consentimento livre e esclarecido. Os dados foram coletados de forma anônima, em ambiente de laboratório escolar, durante o mês de março de 2025, respeitando os princípios éticos da pesquisa com seres humanos.

A partir dos dados coletados, foi avaliada a aceitação do sistema **KMGuide** e sua percepção de utilidade e usabilidade no contexto do ensino técnico, utilizando os parâmetros do modelo TAM.

4. Proposta: O Sistema KMGuide

A Figura 1 apresenta a tela principal da aplicação, evidenciando os elementos de entrada e saída de dados.

O fluxo de interação ocorre em três etapas principais:

1. O aluno preenche o formulário com seus dados e preferências de estudo;
2. O sistema processa as informações;

Gerador de Material de Estudos

Motivação

Mensagem Motivacional

Você está no caminho certo! Continue seus estudos com dedicação e esforço, pois cada pequeno passo que você dá hoje será fundamental para o seu sucesso no futuro. Acredite em si mesmo e em suas capacidades, pois você é capaz de alcançar tudo o que se propõe. Estudar não é apenas uma obrigação, mas uma oportunidade de crescer, aprender e se desenvolver como pessoa. Cada desafio que você supera e cada objetivo que você alcança o tornará mais forte e confiante.

Lembre-se de que a disciplina e o foco são fundamentais para alcançar seus objetivos. Frases inspiradoras como "O sucesso não é final, o fracasso não é fatal: é a coragem de continuar que conta" e "Acredite em si mesmo e você será invencível" devem ser seu lema. Além disso, é importante lembrar que "o estudo é a chave para o sucesso" e que "a educação é o caminho para o futuro". Portanto, mantenha-se motivado, estabeleça metas claras e trabalhe incansavelmente para alcançá-las.

Não desista jamais! O caminho para o sucesso pode ser longo e cheio de desafios, mas com determinação e perseverança, você pode superar qualquer obstáculo. Acredite em si mesmo, nos seus sonhos e na sua capacidade de realizar grandes coisas. Lembre-se de que cada pequena conquista é um passo importante em direção ao seu sucesso. Você é capaz, você é forte e você é digno de alcançar tudo o que deseja. Continue em frente, não perca o foco e nunca desista de seus objetivos. Você vai fazer uma grande diferença no mundo e alcançar grandes coisas!

Guia de Estudos

Guia de Estudos: Matemática

Introdução

A matemática é uma disciplina fundamental na educação, proporcionando ferramentas essenciais para entender e descrever o mundo ao nosso redor. Dentro da matemática, as funções desempenham um papel crucial, pois

Figura 1. Tela principal da aplicação

3. O aluno recebe o guia ou plano de estudo personalizado.

O funcionamento do sistema **KMGuide** fundamenta-se na coleta ativa de informações fornecidas pelo aluno, por meio de um formulário digital estruturado. Esse formulário reúne variáveis essenciais para a construção de planos de estudo personalizados, permitindo ao sistema traçar um perfil básico de organização e foco do estudante. As principais entradas atualmente contempladas são:

- **Disciplina:** área do conhecimento em que o plano de estudos será estruturado;
- **Assuntos:** conteúdos centrais que o aluno deseja ou precisa estudar dentro da disciplina;
- **Tópicos:** detalhamentos mais específicos dos assuntos, como subtemas ou competências;
- **Tempo diário disponível:** quantidade média de horas ou minutos que o aluno pretende dedicar por dia ao estudo;
- **Quantidade de dias disponíveis:** número total de dias nos quais o plano será executado.

Para fins de replicação e análise, um exemplo do guia de estudos em formato PDF, gerado automaticamente pelo **KMGuide**, está disponível em: https://github.com/K-Galvao-Filho/csbc25-kmguide/blob/main/Modelo-Guia_de_Estudo.pdf.

A partir dessas informações inseridas pelo aluno, o sistema realiza o mapeamento do perfil de estudo e elabora uma proposta de plano personalizada, organizando os tópicos de forma distribuída ao longo do tempo disponível. A lógica de construção baseia-se na correspondência entre a carga horária declarada, o número de tópicos e a duração estimada para sua abordagem, considerando a progressão de complexidade.

4.1. Arquitetura

O **KMGuide** foi concebido como uma solução modular, com foco na personalização do processo de ensino-aprendizagem. Sua arquitetura é composta por quatro módulos

principais: (1) entrada de dados do aluno, (2) orquestração dos agentes, (3) geração do conteúdo e (4) entrega do artefato ao usuário. A Figura 2 apresenta a visão geral do sistema.

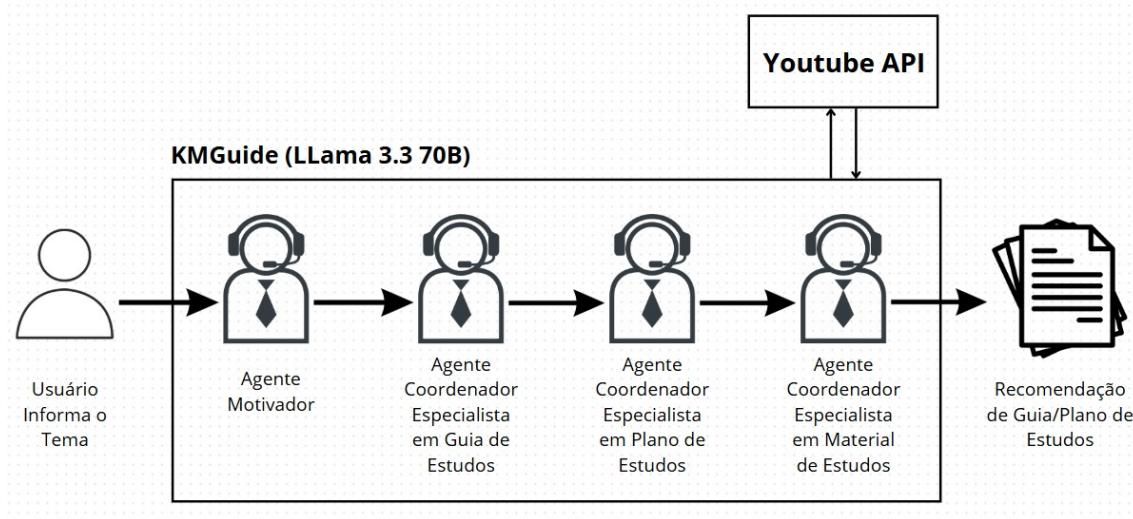


Figura 2. Arquitetura multiagente do sistema KMGuide

A escolha das tecnologias que compõem o **KMGuide** foi orientada por critérios de simplicidade, agilidade na prototipação e compatibilidade com ferramentas de análise de dados. A seguir, destacam-se os principais componentes da implementação:

O *CrewAI* é um framework voltado à orquestração de agentes inteligentes especializados. No **KMGuide**, ele estrutura fluxos de trabalho em que diferentes agentes colaboram na geração de recomendações pedagógicas.

A *GROQ* é uma plataforma de alto desempenho empregada para acelerar o processamento de grandes volumes de dados, sendo utilizada na execução do modelo *LLama 3.3-70B-Versatile*, o qual realiza a geração dos artefatos textuais com base nas entradas do usuário.

Já o *Gradio* é uma biblioteca voltada ao desenvolvimento da interface gráfica web, permitindo a interação direta do usuário com o sistema por meio do navegador, com ênfase em acessibilidade e usabilidade.

A geração do plano é intermediada por agentes inteligentes orquestrados pelo *CrewAI*, responsáveis por interpretar as entradas, selecionar os conteúdos pertinentes e estruturar a recomendação. Essa arquitetura oferece flexibilidade para evoluções futuras, como a inclusão de novos agentes, expansão dos dados de entrada ou integração com sistemas educacionais institucionais. A separação entre os módulos garante modularidade e favorece a manutenção incremental do sistema. Já o *Gradio* é uma biblioteca utilizada para o desenvolvimento da interface gráfica, baseada na web, que permite interação direta com os usuários via navegador, com ênfase em acessibilidade e usabilidade.

4.2. Prompts

A seguir, apresenta-se o conteúdo dos *prompts* utilizados pelos agentes. O agente especialista em planos de estudos é responsável por estruturar o cronograma com base nos

dados fornecidos pelo aluno. Sua atuação integra um fluxo coordenado pela biblioteca *CrewAI*, que orquestra múltiplos agentes especializados, garantindo coerência linguística e adequação pedagógica na geração do conteúdo.

Prompt do Agente Motivador:

Escreva uma mensagem motivacional para o estudante, formatada em Markdown.

A mensagem deve conter:

Mensagem Motivacional

- Um parágrafo inicial incentivando o estudante a seguir seus estudos.
- Frases inspiradoras para manter o foco e a disciplina.
- Um fechamento encorajador, reforçando a importância do esforço e da dedicação.

O texto deve ser positivo, motivador e adequado para estudantes de ensino médio.

Prompt do Agente Coordenador especialista em Guia de Estudo:

Crie um Guia de Estudos para {disciplina}, abordando {assunto} e os tópicos {topicos}.

O guia deve seguir a seguinte estrutura e formatação:

Guia de Estudos: {disciplina}

Introdução

- Texto introdutório justificado sobre o tema, destacando sua importância e contexto.

Conceitos Fundamentais

- Explicação detalhada dos principais conceitos abordados, com exemplos práticos.
- Utilize listas desordenadas para estruturar os conceitos.

Aplicações Práticas

- Explique como o tema se aplica no mundo real.
- Utilize exemplos concretos e listas para organizar as aplicações.

Técnicas de Aprendizado e Dificuldades Comuns

- Apresente métodos eficazes para aprender o tema.

- Liste dificuldades comuns dos alunos e estratégias para superá-las.

Indicação de Materiais Gratuitos

- Forneça sugestões de livros, vídeos e artigos gratuitos sobre o tema.

- Apresente os materiais em formato de lista com títulos e links quando possível.

O conteúdo deve ser didático, acessível para alunos do ensino médio e utilizar texto justificado sempre que possível.

Prompt do Agente Coordenador especialista em Plano de Estudo:

Crie um Plano de Estudos para {disciplina}, cobrindo {assunto} e os tópicos {topicos}.

O aluno tem {horas} horas por dia e {dias} dias para estudar.

O plano deve seguir esta estrutura e formatação:

Plano de Estudos: {disciplina}

Introdução

- Apresentação do objetivo do plano de estudos.
- Importância da organização para otimizar o aprendizado.

Distribuição Equilibrada dos Tópicos

- Divisão dos conteúdos de forma proporcional ao tempo disponível.
- Sugerir uma agenda diária/semanal equilibrada.

Técnicas Ativas de Aprendizado

- Explicação de estratégias eficazes para o estudo, incluindo:
 - Resumos
 - Flashcards
 - Mapas mentais
 - Resolução de exercícios
- ### Revisões Programadas
- Definir períodos estratégicos para revisão de conteúdos.
 - Sugestão de técnicas como repetição espaçada e autoavaliação.
- ### Monitoramento do Progresso
- Métodos para acompanhar a evolução do estudo.
 - Uso de checklists ou aplicativos para organização.
- ### Sugestões para Pausas e Evitar Sobreexaço Mental
- Importância das pausas regulares para manter a produtividade.
 - Sugestão de técnicas como a Técnica Pomodoro.
 - Dicas para manter o bem-estar mental durante os estudos.
- O plano deve ser didático, bem estruturado e adaptável para alunos do ensino médio.

Prompt do Agente Coordenador especialista em Materiais de estudo (YouTube):

Lista do Youtube: {entradaYoutube}

Você receberá uma lista de vídeos extraída da API do YouTube. Sua tarefa é classificar e organizar os vídeos por categorias, formatando-os em Markdown. As categorias devem ser baseadas no título do vídeo.

Vídeos sobre {assunto}

Formato de saída

- Para cada vídeo, a saída deve seguir o formato abaixo:
[Título] (URL)\n\n _Descrição_\n\n
- Se um vídeo não tiver descrição, substituir por: Sem descrição disponível.
- Se houver mais de um vídeo, repetir a estrutura para cada um.
- Certifique-se de que a formatação Markdown esteja correta e bem organizada.
- Caso a lista de vídeos não contenha resultados relevantes, pode haver a inserção automática de um vídeo genérico (exemplo: \url{https://www.youtube.com/watch?v=dQw4w9WgXcQ}), utilizado como marcador de ausência de vídeos sobre o tema buscado.

Nesses casos, a saída deve ser:

##Não foram encontrados vídeos sobre o assunto

Além do uso individual de cada agente, o **KMGuide** realiza a orquestração entre eles por meio do *CrewAI*, que define uma ordem lógica de execução: primeiro o agente coordenador de estudo organiza os tópicos com base nos dados fornecidos; em seguida, os demais agentes complementam o artefato, incluindo materiais, mensagens motivacionais e cronogramas. Esse fluxo modular possibilita adaptar os resultados a diferentes perfis de aluno, promovendo flexibilidade e escalabilidade no uso pedagógico da ferramenta.

5. Avaliação

Esta seção apresenta a avaliação da aceitação do sistema **KMGuide**, com base no *Technology Acceptance Model* (TAM), conforme Davis [Davis 1989] e abordagens complementares [Marangunić and Granić 2015].

A análise dos dados foi organizada em quatro construtos: *Utilidade Percebida* (UP), *Facilidade de Uso Percebida* (FUP), *Variáveis Externas* (VE) e *Intenção de Uso*

(IU). Para cada um, foram calculadas estatísticas descritivas (média, mediana e desvio padrão), permitindo identificar tendências nas percepções dos estudantes quanto ao sistema. Os resultados estão organizados na Tabela 1.

Tabela 1. Estatísticas – TAM

| Sigla | Descrição | Média | Mediana | DP |
|-------|--|-------|---------|------|
| UP | Usar o KMGuide é útil para meus estudos | 4,44 | 5,00 | 0,73 |
| UP | Aprendi a estudar melhor após o uso do KMGuide | 4,00 | 4,00 | 0,73 |
| FUP | Aprender a usar o KMGuide foi fácil para mim | 4,38 | 5,00 | 0,89 |
| FUP | O acesso à ferramenta KMGuide é simples | 4,69 | 5,00 | 0,60 |
| VE | Navegação clara e fácil de achar | 4,50 | 4,50 | 0,52 |
| VE | Boa interface do KMGuide | 4,25 | 4,00 | 0,77 |
| IU | É melhor usar o KMGuide para estudar | 4,19 | 4,00 | 0,66 |
| IU | Pretendo usar o KMGuide para planejar estudos | 4,38 | 5,00 | 0,81 |

A *Utilidade Percebida* refere-se à percepção de que o uso do sistema contribui efetivamente para o desempenho nos estudos [Davis 1989]. Os resultados indicam avaliações majoritariamente positivas, com médias elevadas que sugerem que o **KMGuide** foi reconhecido como um instrumento de apoio à organização e à melhoria da aprendizagem.

A *Facilidade de Uso Percebida* diz respeito à simplicidade percebida na utilização do sistema. Os dados mostram que os estudantes consideraram a ferramenta acessível e fácil de utilizar, com destaque para a facilidade de acesso e uso inicial.

As *Variáveis Externas* avaliam elementos relacionados à navegação e à interface. Os resultados sugerem que a clareza visual e a organização da ferramenta influenciam positivamente na aceitação do sistema.

A *Intenção de Uso* reflete a predisposição dos usuários a continuar utilizando o KMGuide no futuro. As médias obtidas superaram 4 pontos, sugerindo uma forte tendência à adoção contínua do sistema entre os participantes.

5.1. Consistência Interna do Instrumento de Coleta

A confiabilidade do questionário foi verificada por meio do coeficiente alfa de Cronbach (α), utilizado para medir a consistência interna de escalas com múltiplos itens. Conforme Zach [Zach 2023], baseado em Dantas et al. [Dantas et al. 2019], valores de $\alpha \geq 0,70$ são considerados aceitáveis para estudos em ciências sociais.

Tabela 2. Alfa de Cronbach – Construtos TAM

| Construto Avaliado | Alfa (α) | Intervalo de Confiança (95%) |
|-----------------------------|-------------------|------------------------------|
| Utilidade Percebida | 0,81 | [0,64 – 0,90] |
| Facilidade de Uso Percebida | 0,92 | [0,87 – 0,95] |
| Variáveis Externas | 0,87 | [0,77 – 0,93] |
| Intenção de Uso | 0,73 | [0,49 – 0,85] |

Todos os construtos apresentaram níveis satisfatórios de consistência interna. Destaca-se o construto *Facilidade de Uso*, com alfa de 0,92, indicando excelente confiabilidade. Apesar de a *Intenção de Uso* ter registrado o menor valor ($\alpha = 0,73$), ele ainda se encontra dentro dos parâmetros recomendados.

Os dados obtidos reforçam a validade do questionário aplicado e conferem robustez estatística às análises realizadas. A aplicação do alfa de Cronbach sustenta a confiabilidade das inferências sobre a aceitação do **KMGuide** no contexto educacional analisado.

6. Trabalhos Relacionados

Esta seção apresenta estudos recentes sobre sistemas de recomendação educacional, com foco em personalização da aprendizagem por meio de tecnologias como *LLMs*, *fuzzy logic* e modelos híbridos. A Tabela 3 resume e compara as propostas com o sistema **KMGuide** desenvolvido neste estudo.

Tabela 3. Comparativo entre o KMGuide e sistemas relacionados

| Sistema / Citação / Ano | Público-alvo | Tecnologias utilizadas | Funcionalidades principais | Metodologia de avaliação |
|--|--|---|--|--|
| Modelo Multi-Algoritmo [Ma et al. 2023] (2023) | Alunos de matemática online (ensino fundamental) | Regras de associação, PSO, perfil multidimensional do aluno | Recomenda sequência e recursos de estudo personalizados | Simulações com e sem plano personalizado, análise de desempenho e eficiência |
| LearnMate [Wang et al. 2025] (2025) | Estudantes online (vários níveis) | LLM e agentes de IA | Geração de plano de estudos e suporte textual em tempo real | Avaliação qualitativa dos planos gerados, sem testes com usuários |
| Tutor Inteligente Fuzzy [Chrysafiadi et al. 2023] (2023) | Alunos de graduação (programação) | Lógica fuzzy, ITS, adaptação por desempenho | Feedback adaptativo, personalização da dificuldade | Pré/pós-testes, análise estatística, questionários de usabilidade |
| KMGuide (este estudo) | Alunos do ensino técnico em Informática | LLM, <i>LLama 3.3-70B</i> , <i>CrewAI</i> , <i>GROQ</i> e <i>Gradio</i> | Geração de guia ou plano de estudos com base em dados do aluno | Avaliação quantitativa com aplicação do modelo TAM a 16 estudantes |

Wang et al. [Wang et al. 2025] propõem o uso de *LLMs*, como o GPT-4o, para promover a personalização do aprendizado e oferecer suporte em tempo real em ambientes educacionais online. O sistema *LearnMate* gera planos com base em metas, ritmo e preferências do estudante, integrando visualizações interativas. Apesar de inovador, o estudo não foi validado com usuários finais, limitando suas evidências empíricas.

Ma et al. [Ma et al. 2023] apresentam um modelo híbrido de recomendação de trilhas de aprendizagem, combinando regras de associação e otimização por enxame de partículas (PSO). A proposta considera estilo cognitivo, intensidade de estudo e mapas conceituais. Os testes demonstraram ganhos significativos de eficiência.

Chrysafiadi et al. [Chrysafiadi et al. 2023] propõem um Sistema Tutor Inteligente baseado em lógica *fuzzy*, com personalização de conteúdo de acordo com o desempenho do aluno. A avaliação com 140 estudantes mostrou que a adaptação dinâmica aumentou a motivação, a usabilidade percebida e os resultados de aprendizagem.

O **KMGuide**, por sua vez, apresenta como diferencial o uso coordenado de agentes inteligentes especializados por meio da plataforma *CrewAI*, aliados ao poder de processamento da *GROQ* e à simplicidade de uso proporcionada pela interface *Gradio*. O sistema permite que o próprio estudante insira seus dados de forma guiada, gerando automaticamente planos de estudo organizados e contextualizados. Diferente de propostas baseadas apenas em geração textual, o **KMGuide** estrutura os artefatos pedagógicos com base em um fluxo orquestrado, promovendo maior consistência, personalização e replicabilidade.

Além disso, este trabalho se diferencia por realizar uma avaliação quantitativa robusta com estudantes reais, utilizando o modelo TAM e validando a experiência de uso sob múltiplas dimensões.

7. Ameaças à Validade

Este estudo apresenta algumas limitações que devem ser consideradas quanto à validade interna e externa dos resultados obtidos.

Do ponto de vista da validade interna, a principal limitação refere-se ao tamanho da amostra ($n = 16$), restrita a estudantes de um único curso técnico em Informática. Essa limitação reduz a possibilidade de generalização dos resultados mesmo dentro do próprio segmento da educação técnica. Além disso, a experiência com o sistema ocorreu em um único momento, o que pode ter influenciado as percepções positivas iniciais sem garantir sua sustentabilidade ao longo do tempo.

Quanto à validade externa, destaca-se a restrição do ambiente de avaliação, que foi realizado em laboratório institucional, com infraestrutura adequada. Isso não assegura que o mesmo desempenho da ferramenta será mantido em contextos com limitações técnicas, como dispositivos móveis mais antigos ou acesso instável à internet.

Outra limitação reside na ausência de comparação prática entre o **KMGuide** e outras ferramentas educacionais existentes, o que dificulta inferências sobre sua eficácia relativa. Ainda que os resultados sejam promissores, eles não permitem afirmar com precisão que o sistema supera alternativas similares.

Por fim, não foram incorporados mecanismos de feedback direto do aluno sobre o conteúdo gerado, o que restringe a adaptabilidade do sistema às preferências e dificuldades individuais em tempo real.

Como trabalho futuro, recomenda-se a ampliação da amostra para incluir estudantes de outros cursos técnicos e instituições distintas, além da realização de estudos longitudinais que avaliem a aceitação e o impacto do sistema ao longo de um período estendido. Também se sugere a inclusão de testes comparativos com outras plataformas e a implementação de canais de feedback contínuo para fortalecer a personalização e adaptabilidade da ferramenta.

8. Conclusão

Este estudo apresentou o **KMGuide**, um sistema de recomendação baseado em inteligência artificial voltado à personalização do planejamento de estudos no ensino técnico. A proposta busca mitigar a sobrecarga docente e promover maior autonomia discente

por meio da geração automatizada de guias e planos de estudo, utilizando *Large Language Models (LLMs)* e orquestração de agentes inteligentes com o apoio das plataformas *CrewAI*, *GROQ* e *Gradio*.

A avaliação com estudantes do curso técnico em Informática indicou aceitação positiva da ferramenta, com destaque para os construtos de utilidade percebida, facilidade de uso e intenção de uso. A análise estatística demonstrou consistência interna satisfatória do instrumento aplicado, conferindo robustez aos resultados obtidos.

Como diferencial, o sistema se apoia em uma arquitetura modular baseada na orquestração de agentes especializados, permitindo a geração estruturada de artefatos pedagógicos personalizados. A clareza da interface e a simplicidade da interação também foram apontadas como pontos fortes.

Como trabalhos futuros, propõe-se a ampliação da amostra para outras instituições e áreas do conhecimento, a realização de estudos longitudinais, a inclusão de mecanismos de feedback adaptativo e a comparação com outras ferramentas educacionais. Além disso, a validação externa do sistema em diferentes contextos de uso poderá reforçar sua aplicabilidade e eficácia no ambiente escolar real.

A convergência entre inteligência artificial e educação aponta para um campo promissor, e ferramentas como o **KMGuide** podem contribuir significativamente para práticas pedagógicas mais eficazes, personalizadas e sustentáveis.

9. Disponibilidade dos Artefatos

Um exemplo do guia de estudos em PDF gerado pelo sistema, assim como o código-fonte do protótipo, estão disponíveis no repositório: <https://github.com/K-Galvao-Filho/csbc25-kmguide>

Referências

- [Bhatt et al. 2025] Bhatt, S. M., Verbert, K., and Van Den Noortgate, W. (2025). Teacher-centric educational recommender systems in K12 practice: Usage and evaluation. *Heliyon*, 11(2):e42012.
- [Chen et al. 2024] Chen, E., Lee, J.-E., Lin, J., and Koedinger, K. (2024). GPTutor: Great personalized tutor with Large Language Models for personalized learning content generation. *arXiv preprint arXiv:2407.09484*.
- [Chrysafiadi et al. 2023] Chrysafiadi, K., Virvou, M., Tsihrintzis, G. A., and Papadopoulos, G. A. (2023). Evaluating the user's experience, adaptivity and learning outcomes of a fuzzy-based intelligent tutoring system for computer programming for academic students in greece. *Education and Information Technologies*, 28:6453–6483.
- [Dantas et al. 2019] Dantas, E., Costa, A. A. M., Vinicius, M., Perkusich, M. B., de Almeida, H. O., and Perkusich, A. (2019). An effort estimation support tool for agile software development: An empirical evaluation. In *Proceedings of the 31st International Conference on Software Engineering and Knowledge Engineering (SEKE)*, pages 82–116.
- [Davis 1989] Davis, F. D. (1989). Perceived usefulness, perceived ease of use, and user acceptance of information technology. *MIS Quarterly*, 13(3):319–340.

- [Ferreira 2023] Ferreira, L. C. (2023). Pesquisa mostra que 71% dos professores estão estressados. Agência Brasil (Notícia).
- [Groq Inc. 2024] Groq Inc. (2024). The future of AI is agentic... and GROQ. White paper.
- [Luo 2024] Luo, Y. (2024). The use of chatgpt in education: A new path to personalized instruction. *Science Insights Education Frontiers*, 25(1).
- [Ma et al. 2023] Ma, Y., Wang, L., Zhang, J., Liu, F., and Jiang, Q. (2023). A personalized learning path recommendation method incorporating multi-algorithm. *Applied Sciences*, 13(10):5946.
- [Mai et al. 2024] Mai, D. T. T., Da, C. V., and Hanh, N. V. (2024). The use of ChatGPT in teaching and learning: a systematic review through SWOT analysis approach. *Frontiers in Education*, 9.
- [Marangunić and Granić 2015] Marangunić, N. and Granić, A. (2015). Technology acceptance model: A literature review from 1986 to 2013. *Universal Access in the Information Society*, 14(1):81–95.
- [Nascimento et al. 2023] Nascimento, A. L., Miranda, A. K. P., da Silva, L. S., Lima, I. Â. d. S. B., Pereira, C. L., Santos, I. V. M., and Feitosa, P. d. C. (2023). Ser docente na pandemia: vivência, sobrecarga e desafios de professores do ensino básico, técnico e tecnológico. *Saúde Coletiva (Barueri)*, 13(149):9417–9427.
- [Neil 2024] Neil, D. (2024). CrewAI based DSA Tutor: Personalized learning with multi-agent systems. Analytics Vidhya Blog.
- [Ozamiz-Etxebarria et al. 2023] Ozamiz-Etxebarria, N., Legorburu, I. M., Lipnicki, D. M., and Idoiaga, N. (2023). Prevalence of burnout among teachers during the covid-19 pandemic: A meta-analysis. *International Journal of Environmental Research and Public Health*, 20(6):4866.
- [Silva et al. 2023] Silva, F. L. d., Slodkowski, B. K., Silva, K. K. A. d., and Cazella, S. C. (2023). A systematic literature review on educational recommender systems for teaching and learning: research trends, limitations and opportunities. *Education and Information Technologies*, 28:3289–3328.
- [Wang et al. 2025] Wang, X. J., Lee, C., and Mutlu, B. (2025). Learnmate: Enhancing online education with llm-powered personalized learning plans and support. Extended Abstracts of the CHI Conference on Human Factors in Computing Systems (CHI EA '25), April 26-May 1, 2025, Yokohama, Japan.
- [Winland et al. 2024] Winland, V., Syed, M., and Gutowska, A. (2024). What is CrewAI? IBM Technology Blog.
- [Zabala 1998] Zabala, A. (1998). *A prática educativa: como ensinar*. Artmed.
- [Zach 2023] Zach, A. (2023). A simple explanation of internal consistency. <https://www.statology.org/internal-consistency/>. Acesso em: 23 mar. 2025.
- [Zimmerman 2002] Zimmerman, B. J. (2002). Becoming a self-regulated learner: An overview. *Theory into Practice*, 41(2):64–70.