

PLATAFORMA EDUCACIONAL DE RECOMENDAÇÃO DE CONTEÚDO COM USO DE LLMs E LÓGICA FUZZY

EDUCATIONAL CONTENT RECOMMENDATION PLATFORM USING LLMS AND FUZZY LOGIC

PLATAFORMA EDUCACIONAL DE RECOMENDAÇÃO DE CONTEÚDO COM USO DE LLMS E LÓGICA

Geovani Lopes Sampaio¹
Raimundo Correa de Oliveira²
Ernande Ferreira Melo³
Kaique Olegar Amaro dos Santos⁴

RESUMO: Esse artigo buscou propor uma plataforma educacional que utiliza Modelos de Linguagem de Grande Escala (LLMs) e Lógica Fuzzy para recomendar conteúdo de forma personalizada. A metodologia empregada envolve o uso de LLMs para análise, sumarização de materiais didáticos e extração de palavras-chave, enquanto a Lógica Fuzzy classifica o nível do aluno com base em seu desempenho em atividades de gameificação, como QUIZ e Palavras Cruzadas, considerando parâmetros como pontuação, tentativas, dificuldade e tempo. Os principais resultados indicaram que as LLMs foram eficazes na sumarização de conteúdo e na geração de palavras-chave para buscar material complementar relevante. O sistema Fuzzy conseguiu classificar o desempenho dos alunos, permitindo o direcionamento adaptativo do conteúdo. Conclui-se que a integração dessas tecnologias oferece um suporte dinâmico e adaptativo ao aprendizado, personalizando a experiência educacional ao fornecer conteúdo alinhado às necessidades e ao nível de conhecimento do estudante, superando abordagens genéricas e o excesso de informação.

2518

Palavras-chave: Sistemas de Recomendação. LLMs (Modelos de Linguagem de Grande Escala). Lógica Fuzzy.

ABSTRACT: This article sought to propose an educational platform that uses Large Language Models (LLMs) and Fuzzy Logic to recommend content in a personalized way. The methodology employed involves the use of LLMs for analysis, summarization of didactic materials, and keyword extraction, while Fuzzy Logic classifies the student's level based on their performance in gamification activities, such as QUIZ and Crosswords, considering parameters like score, attempts, difficulty, and time. The main results indicated that LLMs were effective in content summarization and keyword generation for searching relevant supplementary material. The Fuzzy system successfully classified student performance, allowing for adaptive content direction. It is concluded that the integration of these technologies offers dynamic and adaptive support for learning, personalizing the educational experience by providing content aligned with the student's needs and knowledge level, overcoming generic approaches and information overload.

Keywords: Recommendation Systems. LLMs (Large Language Models). Fuzzy Logic.

¹Discente, Universidade do Estado do Amazonas.

²Docente (Dr), Universidade do Estado do Amazonas.

³Docente (Dr). Universidade do Estado do Amazonas.

⁴Discente. Universidade do Estado do Amazonas.

RESUMEN: Este artículo buscó proponer una plataforma educativa que utiliza Modelos de Lenguaje de Gran Escala (LLMs) y Lógica Difusa para recomendar contenido de forma personalizada. La metodología empleada implica el uso de LLMs para el análisis, resumen de materiales didácticos y extracción de palabras clave, mientras que la Lógica Difusa clasifica el nivel del estudiante basándose en su desempeño en actividades de gamificación, como cuestionarios (QUIZ) y crucigramas, considerando parámetros como puntuación, intentos, dificultad y tiempo. Los principales resultados indicaron que los LLMs fueron eficaces en la sumariazación de contenido y en la generación de palabras clave para buscar material complementario relevante. El sistema de Lógica Difusa clasificó con éxito el rendimiento de los estudiantes, permitiendo una orientación adaptativa del contenido. Se concluye que la integración de estas tecnologías ofrece un soporte dinámico y adaptativo para el aprendizaje, personalizando la experiencia educativa al proporcionar contenido alineado con las necesidades y el nivel de conocimiento del estudiante, superando los enfoques genéricos y la sobrecarga de información.

Palabras clave: Sistemas de Recomendación. LLMs (Modelos de Lenguaje de Gran Escala). Lógica Difusa.

INTRODUÇÃO

Com a aplicação bem-sucedidas do ChatGPT o desafio atual na área de IA é a descoberta de aplicações que utilizem modelos LLMs como parte inteligente destas aplicações. Para isso é necessária uma mudança na cultura de desenvolvimento de sistemas. As LLMs são IAs treinadas e prontas para utilização, dependendo do que se quer fazer. Eventualmente você pode querer desenvolver seu próprio modelo de LLM, para uma aplicação específica. A integração de LLMs com outras ferramentas amplia o seu campo de aplicações. Atualmente LLMs podem acessar bancos de dados SQL e dados não estruturados, fazer inferência sobre documentos diversos, buscar palavras chaves em textos, permitem adição de extensões como por exemplo as RAGs (Retrieval-Augmented Generation), entre outras[1][2].

2519

A lógica fuzzy[3] introduz a ideia de graus de verdade, representados em um intervalo de $[0, 1]$. Essa abordagem é útil em situações em que os conceitos são vagos ou difíceis de definir com precisão, como é o caso de avaliar o nível de alunos em relação a conteúdos educacionais.

Por outro lado, sistemas de recomendações de conteúdos educacionais [4][5] é uma aplicação recorrente devido sua importância no contexto do desenvolvimento de estudantes sendo também uma ferramenta de apoio ao professor. Ao longo do desenvolvimento deste artigo vamos mostrar que LLMs acompanhada de outras ferramentas como Sistema Fuzzy podem ser uma abordagem mais simples e complementar, para a recomendação de conteúdos educacionais uma vez que ambas processam linguagem natural Além disso do ponto de vista pedagógico abordagem a conteúdos educacionais requerem o uso de metodologia ativas, neste

caso, a gameificação dos conteúdos educacionais, que geram parâmetros para a avaliação e recomendação de novos conteúdos.

MÉTODOS

Sistemas de Recomendação são algoritmos ou sistemas que filtram e priorizam informações para fornecer ao usuário conteúdo personalizados de acordo com necessidades ou comportamentos. Sua popularidade cresceu com as recomendações bem-sucedidas de filmes, vídeos, livros, propagandas de produtos de consumo, entre outros. Por outro lado, quando aplicado a conteúdos educacionais são necessárias outras abordagens começando pelo conceito. Os Sistemas de Recomendação de Conteúdos Educacionais[4], são plataformas ou ferramentas baseadas em algoritmos de recomendação cujo objetivo é melhorar o processo de ensino e aprendizagem, bem como aumentar o engajamento de estudantes dentro do sistema. Esses sistemas analisam dados sobre os usuários, como suas preferências, desempenho, restrições e histórico de aprendizado, para recomendar conteúdos, alinhados com as suas necessidades e objetivos. Para os instrutores, professores ou tutores esses sistemas podem contribuir para suas práticas pedagógicas por meio de recomendações que aprimoram o planejamento e auxiliam na filtragem de recursos educacionais, além da geração de novos conteúdos. Quanto aos alunos, por meio do reconhecimento de preferências e restrições educacionais, os sistemas de recomendação podem contribuir para seu desempenho acadêmico e motivação, indicando conteúdos de aprendizagem personalizado [5]. Neste sentido preferências, motivação e desempenho estão relacionados com práticas pedagógicas mais especificamente com metodologias ativas[6]. Dentre as metodologias ativas, está a gameificação dos conteúdos ensinados que resultam em avaliação do nível atual do aluno, possibilitando a recomendação de conteúdo.

2520

GAMEIFICAÇÃO

Na metodologia de gameificação o ensino de assuntos mais complexos ou de pouco interesse entre os estudantes pode se tornar mais atraente com a realização de jogos. A metodologia de gameificação usa ferramentas e pensamentos de games para envolver os alunos e motivá-los a aprender[7]. Também é possível criar uma competição nova para exercício de habilidades, com regras e etapas bem definidas, além de recompensas para os vencedores. Os jogos têm o grande poder de gerar engajamento, interação, criatividade, resolução de problemas

e melhoria da comunicação e da colaboração com os colegas. Eles também são divertidos e, por isso, tornam a experiência de aprendizagem mais leve e memorável. Algumas características da gamificação são [7][8]:

Pontuação: é um exemplo de gamificação que está presente em diversas áreas de nossas vidas, nos programas de fidelidade, em programas de cartão de crédito, programas como o Km de vantagens e em testes escolares.

Recompensa: é a característica intrínseca do ser humano gostar de reconhecimento e recompensa por seu esforço, pois sentimos a necessidade de provas concretas de que determinado objetivo foi atingido.

Competição: A competição, assim como a recompensa é algo que está em nosso dia a dia e que se trabalhada da maneira correta desenvolve diversas habilidades e competências.

Não é objetivo deste trabalho focar em jogos, aqui são citados quatro jogos desenvolvidos em um Projeto de P&D, Plataforma Pense Bem com conteúdo do nano ano do ensino fundamental, observando as recomendações da BNCC (Base Nacional Comum Curricular) [9].

Os conhecidos jogos são QUIZ, Palavras Cruzadas, Caça Palavras, e Criptograma. Para recomendação de conteúdo são avaliados para cada realização de um jogo, os seguintes parâmetros:

- a) Pontuação (número de acertos)
- b) Número de tentativas
- c) Grau de dificuldade do conteúdo
- d) Tempo de jogo

SISTEMA FUZZY

A lógica fuzzy é uma extensão da lógica clássica que permite trabalhar com incertezas e subjetividades. Diferente da lógica tradicional, que classifica proposições como verdadeiras ou falsas, a lógica fuzzy introduz a ideia de graus de verdade, representados em um intervalo de $[0, 1]$. Essa abordagem é útil em situações em que os conceitos são vagos ou difíceis de definir com precisão. A lógica fuzzy tem por objetivo principal fazer com que as decisões tomadas pela máquina se aproximem cada vez mais das decisões humanas, de representação linguística. [10][11]. Um sistema fuzzy que implementa a lógica fuzzy é descrito na Figura 1, Inicialmente o sistema recebe valores quantitativos do mundo real, realiza o processo de Fuzzificação, transformando valores numéricos em variáveis linguísticas: considere o problema de classificar

o nível de um aluno que terminou um jogo de conteúdo educacional, um QUIZ, por exemplo, onde são avaliados os seguintes parâmetros:

Pontuação (número de acertos)

Número de tentativas

Grau de dificuldade do conteúdo

Tempo de jogo

Para cada parâmetro podemos definir uma classificação, neste caso, como baixo, medio e alto e fazer a Fuzzificação, gerando as curvas mostradas na Figura 2. As curvas mostram que para cada parâmetro, por exemplo pontuação, podemos ter valores classificados em mais de um subconjunto, no caso a pontuação 25 pertence às curvas de baixo com grau de pertinência aproximadamente 0.9 e medio com grau de pertinência em torno de 0.3. A inferência para definir a avaliação do nível do aluno no conteúdo jogado, é feita pela aplicação de regras compostas, basicamente, pela avaliação do grau de pertinência, através de operações de união e interseção sobre o conjunto de parâmetros fuzzificados, como mostra na Tabela 1. Ao final da inferência temos a classificação do nível do aluno para o conteúdo jogado. A Figura 3 mostra a saída do sistema fuzzy, para uma entrada de valores relativos[10][11]:

Pontuação (número de acertos):100

Número de tentativas: 20

Grau de dificuldade do conteúdo:60

Tempo de jogo: 30

Neste caso a avaliação dos parâmetros de entrada gera uma classificação de nível médio com valor numérico defuzzificado em torno de 60, ver reta vertical na Figura 3.

Figura 1. Sistema Fuzzy: recebe valores quantitativos do mundo real, constrói curvas de Fuzzificação usando variáveis linguísticas, infere e defuzzifica, gerando uma classificação

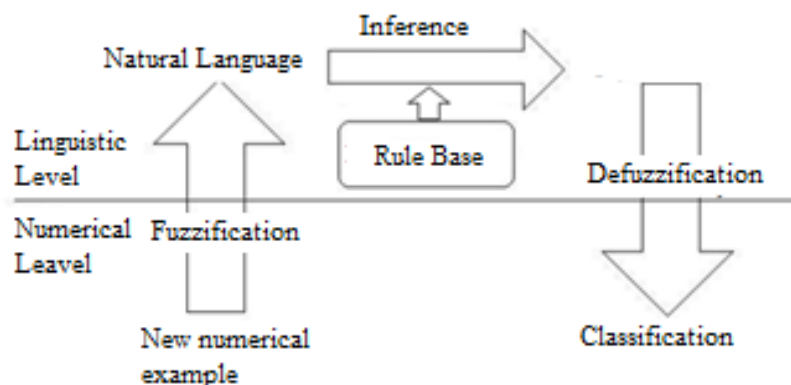


Figura 2 exemplo de curvas fuzzy resultantes do processo de fuzzificação


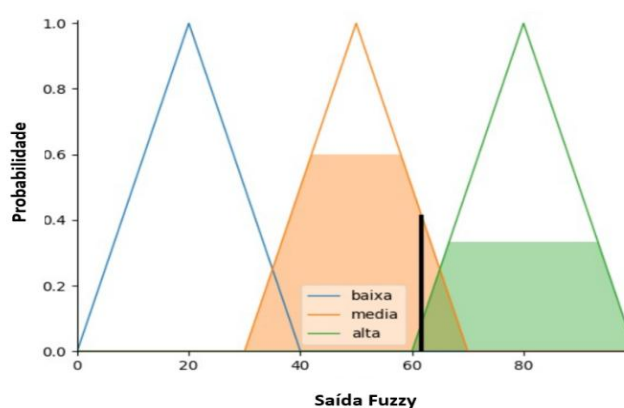


Tabela 1. Regras fuzzy selecionadas para o sistema de recomendação.

Regra	Descrição
Regra 0	Se pontuação é <i>baixa</i> e tempo é <i>alta</i> e dificuldade média é <i>baixa</i> e tentativas é <i>alta</i> , então Nível é <i>baixa</i> .
Regra 4	Se pontuação é <i>média</i> e tempo é <i>média</i> e dificuldade média é <i>baixa</i> e tentativas é <i>média</i> , então Nível é <i>média</i> .
Regra 13	Se pontuação é <i>baixa</i> e tempo é <i>média</i> e dificuldade média é <i>média</i> e tentativas é <i>média</i> , então Nível é <i>média</i> .
Regra 32	Se pontuação é <i>média</i> e tempo é <i>baixa</i> e dificuldade média é <i>média</i> e tentativas é <i>média</i> , então Nível é <i>alta</i> .
Regra 35	Se pontuação é <i>média</i> e tempo é <i>baixa</i> e dificuldade média é <i>alta</i> e tentativas é <i>baixa</i> , então Nível é <i>alta</i> .

Figura 3 – Saída fuzzy para a classificação do nível do aluno no conteúdo jogado. A barra vertical preta representa a saída fuzzy para os parâmetros de entrada dados



SISTEMA DE RECOMENDAÇÃO PROPOSTO

O Sistema de Recomendação proposto neste artigo tem por objetivo recomendar conteúdo para alunos do nano ano do ensino fundamental, observando as recomendações da

BNCC (Base Nacional Comum Curricular) [9]. A Figura 4 mostra a representação esquemática do sistema proposto.

- 1). Os conteúdos a serem aprendidos estão organizados em disciplinas, e-books, capítulos e seções.
- 2) O aluno joga um dos jogos (QUIZ, Palavras Cruzadas, Caça Palavras, e Criptograma).
- 3). É feita a classificação do nível do aluno pelo sistema Fuzzy
- 4) O aluno volta a jogar a próxima seção do capítulo
- 5). No final das seções o aluno pode jogar com o conteúdo de todo o capítulo levando em consideração a sua classificação em cada seção
- 6). Ao final do jogo do capítulo, é feita a avaliação pelo sistema fuzzy que será registrado como ranking para fins de competição
- 7). Em qualquer seção é disponibilizado para o aluno a busca de conteúdos educacionais complementares na internet através da sumarização dos conteúdos ou palavras chaves feitas por uma LLM, como mostra na Tabela 2.

MÓDULO DESCRIÇÃO DE CONTEÚDO

2524

A Figura 4 mostra a inserção de LLMs em diversos momentos do uso do sistema, O módulo LLM desenvolvido tem como função a análise automática de conteúdos didáticos, extraíndo tópicos específicos que melhor descrevem uma seção. Isso permite transformar documentos extensos em uma lista clara de subtópicos. A geração de subtópicos é realizada a partir do uso de LLMs, tais modelos possuem uma habilidade de sumarização de textos.

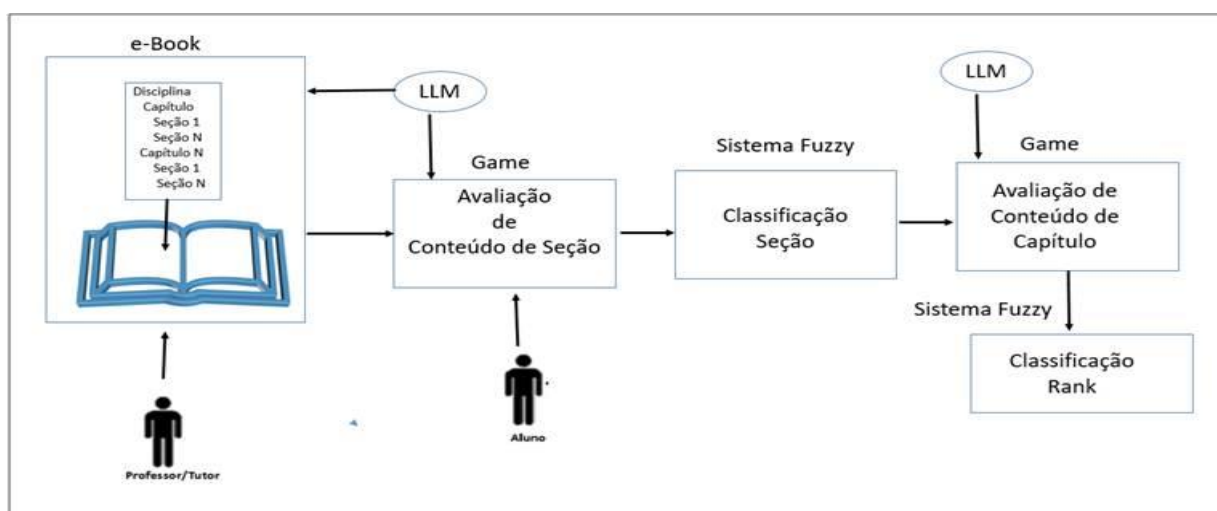


Figura 4. Sistema de Recomendação de conteúdo educacional proposto.

A capacidade de sumarização das LLMs é especialmente útil em contextos educacionais, onde a quantidade de material disponível pode ser vasta e fragmentada. Esse processo não apenas facilita a assimilação do conhecimento, mas também otimiza a navegação por conteúdo extensos, permitindo que usuários encontrem rapidamente os pontos mais importantes de um documento e tenha a opção de busca por conteúdos complementares, na internet.

Foram escolhidos três modelos de LLMs: DeepSeek, LLAMA 3 e Qwen2.5 com o intuito de abordagens distintas, e definir a que realizar uma sumarização ou extração de palavras-chaves, mais precisa e adequada às necessidades do sistema de recomendação de conteúdos externos ou complementares.

O template de prompt utilizado para a geração de tópicos pelos modelos é dado no Quadro 1. Nele, são passados o contexto, que trata do conteúdo de ciências e do tópico que representa o seu tema principal tratado naquele trecho de conteúdo.

O resultado para os modelos para uma seção do conteúdo está disposto na Tabela 3, onde é possível observar que os modelos tiveram desempenho parecido durante a execução do experimento.

Quadro 1 - Prompt para geração de tópicos.

Prompt
Baseado no conteúdo a seguir: (Aqui são inseridos os documentos como contextos para o modelo)
Descreva o seguinte tópico em tópicos mais específicos que tratam de assuntos de ciências: (Aqui é inserido o tópico que representa o tema principal do contexto dado acima)
Não descreva os tópicos gerados, ou faça outras perguntas, apenas liste os tópicos.

Tabela 3 - Resultado da sumarização de texto feito por LLMs para uma seção do conteúdo.

Modelo	Tópicos sumarizados
DeepSeek	<ul style="list-style-type: none">- Formação de átomos durante o Big Bang- Nucleossíntese primordial- Formação de hidrogênio e hélio no universo inicial- Fusão nuclear em estrelas- Formação de elementos mais pesados como ferro e oxigênio- Ciclo de vida das estrelas e formação de elementos- Papel da gravidade na compressão de nebulosas.

Llama 3	<ul style="list-style-type: none"> - Formação dos átomos - Nucleossíntese primordial - Elementos químicos mais simples (hidrogênio e hélio) - Primeiros átomos como bolhas de sabores em uma sopa cósmica - Nebulosas e gravidade - Formação das primeiras estrelas (protoestrelas) - Fusão nuclear nas estrelas - Processo da fusão nuclear
Qwen	<ul style="list-style-type: none"> - Formação de átomos no Big Bang - Nucleossíntese primordial - Ligação química entre prótons e elétrons formando primeiros átomos - Nebulosas e a formação de protoestrelas através da gravidade - Fusão nuclear em estrelas - Ciclo de vida das estrelas com foco em ligações químicas e formação de moléculas mais complexas

A Tabela 4 mostra um exemplo de conteúdo a ser pesquisado por palavras chaves resultante da sumarização do texto sobre Ciclo de vida das estrelas em um conteúdo de. Ciências para alunos do nono ano de ensino fundamental. O texto é extraído do e-book, conforme ilustrado na Figura 4.

Tabela 4. Exemplo (amostra) do processo de sumarização com LLM.

Texto	Prompt	Sumarização
<p>Ciclo de vida das estrelas</p> <p>As estrelas podem seguir por diferentes destinos como consequência da massa que apresentam. Estrelas menores, aquelas coxassa 0,08 vezes menor ao Sol, não conseguem iniciar a fusão de hidrogênio e, portanto, não contribuem para a formação de novos elementos. Estrelas maiores, no entanto, passam por vários estágios. Influenciadas pelos seus tamanhos, podendo chegar aos estágios de gigante vermelha (aumentando de tamanho); estágio de supernova, uma explosão que ajuda a espalhar os elementos formados dentro da estrela, sendo também essenciais para construir elementos ainda mais pesados. Mas, caso não tenha massa o suficiente, será formada no fim uma anã branca, que é o caso do nosso sol.</p>	<p>Sumarize o seguinte texto em tópicos descritivos que tratam de assuntos de ciências.</p>	<ul style="list-style-type: none"> - Fusão nuclear em estrelas - Ciclo de vida das estrelas com foco em ligações químicas e formação de moléculas mais complexas

RESULTADOS

A Tabela 5 mostra a classificação de um aluno que leu o conteúdo de três seções. Para cada seção ele jogou um dos jogos disponíveis, gerando, para cada seção um nível/pontuação. Ao final de todas as seções que compõem um Capítulo, o aluno joga novamente, sendo que as questões do jogo são selecionadas com base no nível de cada seção conforme Quadro 5. Observamos nesta tabela que no caso da segunda e terceira linhas. Embora a pontuação de 30% tenha gerado um nível baixo e a pontuação de 20% gere um nível medio, os outros parâmetros de avaliação equilibram a análise.

Os resultados estão dentro de valores esperados, do ponto de vista da percepção e da lógica Fuzzy.

Tabela 5 - Classificação de um aluno que leu o conteúdo de três seções. Para cada seção ele jogou um dos jogos disponíveis, gerando, para cada seção os parâmetros que resultaram no nível/pontuação, mostrados na tabela

Parâmetro	Nível do usuário/aluno na seção	Pontuação
Acerto: 80% Tempo: 75/% Dificuldade: 50% Tentativas: 40%	Alto	80
Acerto: 30% Tempo: 75/% Dificuldade: 20% Tentativas: 85%	Baixo	32
Acerto: 20% Tempo: 30/% Dificuldade: 90% Tentativas: 40%	Medio	41

BUSCA POR CONTEÚDOS EXTERNOS

Utilizando a sumarização mostrada na Tabela 4, aplicamos um modelo LLM (llama3.2) para obter as palavras chaves do texto sumarizado, conforme Tabela 6 fizemos busca na internet, resultando na seleção de conteúdos externos através dos links mostrados no Quadro 7. Com base na sumarização apresentada na Tabela 4, um modelo LLM (llama3.2) foi aplicado para extrair as palavras-chave do texto sumarizado, conforme demonstrado na Tabela 6. Em seguida, realizou-se uma busca na internet, resultando na seleção de conteúdos externos por meio dos links fornecidos no Quadro 7.

Tabela 6 - Exemplo (amostra) do processo de geração de palavras chaves para busca na Internet

Texto Sumarizado	Prompt	Palavras chaves
<ul style="list-style-type: none"> - Fusão nuclear em estrelas - Ciclo de vida das estrelas com foco em ligações químicas e formação de moléculas mais complexas 	Extrair todas as palavras chaves do texto sumarizado	fusão nuclear, ciclo de vida, estrelas, ligação química, formacao de moleculas

Tabela 7 - Relação de Links gerados para busca de conteúdos externos usando as palavras chaves da

Links
https://mundoeducacao.uol.com.br/fisica/ciclo-vida-das-estrelas.htm https://brasilescola.uol.com.br/geografia/evolucao-estrelar.htm http://www.if.ufrgs.br/~fatima/ead/estrelas.htm https://brasilescola.uol.com.br/quimica/fusao-nuclear.htm https://www.scielo.br/j/rbef/a/G3khcGXvJwWGMpFfwmsKtbv/ http://www.inpe.br/ciaa2018/arquivos/pdfs

CONCLUSÃO

A maioria das plataformas de conteúdo educacional adota uma abordagem genérica para a distribuição de materiais, negligenciando as particularidades de cada estudante, tais como seus interesses, dificuldades e estilo de aprendizagem. Ademais, a vasta quantidade de recursos disponíveis pode ocasionar sobrecarga informacional, tornando a navegação e a identificação de materiais relevantes uma tarefa complexa e ineficaz. A metodologia apresentada neste trabalho proporciona um suporte dinâmico e adaptativo ao aprendizado, assegurando que o aluno receba conteúdos pertinentes ao seu nível de conhecimento e às suas necessidades específicas.

A integração entre Large Language Models (LLMs) e lógica Fuzzy possibilita um refinamento contínuo das recomendações, promovendo uma experiência de aprendizado personalizada. A capacidade de adaptar as recomendações com base no desempenho do aluno, nos conteúdos estudados e nos erros cometidos contribui significativamente para aprimorar a eficiência e a relevância das sugestões educacionais. Como proposta para trabalhos futuros, torna-se necessário filtrar conteúdos externos mais adequados ao nível do aluno, desenvolver

um módulo específico para professores/tutores e avaliar a viabilidade de substituir o Sistema Fuzzy por LLMs.

REFERÊNCIAS

- [1] ZHU M, et al. DeepReview: Improving LLM-based Paper Review with Human-like Deep Thinking Process. arXiv, 2025.
- [2] YAO Y, et al. A survey on large language model (LLM) security and privacy: The Good, The Bad, and The Ugly. Human-Centric Computing and Information Sciences, 2024; 14: 11.
- [3] AZEEM MF. Fuzzy Inference System: Theory and Applications. Saarbrücken: LAP LAMBERT Academic Publishing, 2012; 88p.
- [4] CAMPOS A, et al. Mapeamento de soluções tecnológicas em sistemas de recomendação educacionais em âmbito brasileiro. RENOTE: Novas Tecnologias na Educação, 2018; 16: 1-10.
- [5] MARTINEZ SG, LHADJ AH. Educational Recommender Systems: A Pedagogical-Focused Perspective. Advances in Intelligent Systems and Computing, 2013; 234: 66-73.
- [6] SILVA JAM, et al. Metodologias Ativas: Em busca de uma Caracterização e Definição. Interface - Comunicação, Saúde, Educação, 2021; 25: e200600.
- [7] WERNECK VR. Sobre o processo de construção do conhecimento: o papel do ensino e da pesquisa. Ensaio: Avaliação e Políticas Públicas em Educação, 2006; 14: 173-196.
- [8] ZICHERMANN G, CUNNINGHAM C. Gamification by Design: Implementing game mechanics in web and mobile apps. Canada: O'Reilly Media Inc., 2011.
- [9] GONÇALVES AM, DEITOS RA. GENERAL COMPETENCIES OF THE NATIONAL COMMON CURRICULAR BASE (BNCC): THEORETICAL AND IDEOLOGICAL FOUNDATIONS. Eccos Revista Científica, 2024; 52: e10678.
- [10] MELO EF, et al. Automatic Increment in a Knowledge Base by means of Fuzzy System with Supervised Machine Learning. International Journal of Development Research, 2020; 10: 18530.
- [11] SIVANANDAM SN, et al. Introduction to Fuzzy Logic using MATLAB. Berlin Heidelberg: Springer-Verlag, 2007.