

UNIVERSIDADE FEDERAL DE JUIZ DE FORA
INSTITUTO DE CIÊNCIAS EXATAS
BACHARELADO EM CIÊNCIA DA COMPUTAÇÃO

SisREAd: Sistema de Recomendação para REA

Gabriel do Carmo Silva

JUIZ DE FORA
JULHO, 2026

SisREAd: Sistema de Recomendação para REA

GABRIEL DO CARMO SILVA

Universidade Federal de Juiz de Fora

Instituto de Ciências Exatas

Departamento de Ciência da Computação

Bacharelado em Ciência da Computação

Orientador: Victor Ströele de Andrade Menezes

JUIZ DE FORA

JULHO, 2026

SISREAD: SISTEMA DE RECOMENDAÇÃO PARA REA

Gabriel do Carmo Silva

MONOGRAFIA SUBMETIDA AO CORPO DOCENTE DO INSTITUTO DE CIÊNCIAS EXATAS DA UNIVERSIDADE FEDERAL DE JUIZ DE FORA, COMO PARTE INTEGRANTE DOS REQUISITOS NECESSÁRIOS PARA A OBTENÇÃO DO GRAU DE BACHAREL EM CIÊNCIA DA COMPUTAÇÃO.

Aprovada por:

Victor Ströele de Andrade Menezes
Doutor em Engenharia de Sistemas e Computação - COPPE/UFRJ

Liamara Scortegagna
Doutora em Engenharia de Produção - UFSC

Regina Maria Maciel Braga Villela
Doutora em Engenharia de Sistemas e Computação - COPPE/UFRJ

JUIZ DE FORA
9 DE JULHO, 2026

Resumo

Esse trabalho aborda a criação de um Sistema de Recomendação (SR) para Recursos Educacionais Abertos (REA), visando aprimorar a busca por REA em diversos Repositórios de Recursos Educacionais Abertos (RREA). O sistema foi desenvolvido para recomendar REA adequados às necessidades do usuário, com base em um Modelo Conceitual. O método consiste na coleta de dados de perfil, interesses e metas de aprendizagem do usuário, que são processados por um algoritmo responsável por buscar e classificar REA em dois RREA e em uma plataforma de vídeos educacionais, utilizando um banco de dados. O SR foi desenvolvido com Laravel, Livewire e SQLite, com integração ao Ollama, e visa demonstrar alta eficiência, fornecendo resultados alinhados às necessidades do usuário.

Palavras-chave: Sistema de Recomendação, Recursos Educacionais Abertos, Meta de aprendizagem

Abstract

This work addresses the creation of a Recommender System (RS) for Open Educational Resources (OER) aimed at improving the search for OER across various Open Educational Resource Repositories (OERR). The system was developed to recommend adapted OER, based on a Conceptual Model. The method consists of collecting the user's profile, interests, and learning goal data, processing them with an algorithm that searches for and classifies OER across two OERRs and an educational video platform, and storing the results in a database. The RS was developed with Laravel, Livewire, and SQLite, alongside an integration with Ollama, and aims to demonstrate high efficiency by providing results aligned with the user's needs.

Keywords: Recommender System, Open Educational Resources, Learning goal.

Agradecimentos

À minha família, pelo encorajamento e apoio.

Ao professor Victor Ströele pela orientação, amizade e principalmente, pela paciência, sem a qual este trabalho não se realizaria.

Aos meus amigos e colegas, por tornar a caminhada mais proveitosa e leve.

Aos professores do Departamento de Ciência da Computação pelos seus ensinamentos e aos funcionários do curso, que durante esses anos, contribuíram de algum modo para o nosso enriquecimento pessoal e profissional.

Conteúdo

Lista de Figuras	6
Lista de Tabelas	7
1 Introdução	8
2 Fundamentação Teórica	12
2.1 Sistemas de Recomendação	12
2.2 Recursos Educacionais Abertos	13
2.3 Repositórios de Recursos Educacionais Abertos	14
2.4 Metas de Aprendizagem e EMAPRE-U	15
2.5 Modelos de Linguagem aplicados à Educação	16
2.6 Finais do Capítulo	18
3 Trabalhos Relacionados	19
4 Metodologia	22
4.1 Caracterização da Pesquisa	22
4.2 Arquitetura do Sistema	22
4.3 Fluxo de Recomendação	23
4.4 Integração com Repositórios Externos	24
4.5 Classificação por Meta de Aprendizagem	25
4.6 Recomendação para Usuários Não Cadastrados	29
4.7 Tecnologias Utilizadas	29
4.8 Processo de recomendação dos REAs	30
4.9 Classificação dos recursos	30
4.10 Identificação da meta de aprendizagem dos recursos	31
4.11 Determinação das características pedagógicas	32
4.12 Critério de destaque dos recursos (Highlight)	32
4.13 Métricas coletadas durante as buscas	33
5 Resultados	35
5.1 Interfaces do sistema	35
5.1.1 Tela do colaborador	41
5.2 Avaliação do Sistema	42
5.3 Verificação da classificação automática por meta de aprendizagem	46
5.3.1 Construção da classificação de referência	46
5.3.2 Desempenho do modelo automático	48
5.4 Desempenho e escalabilidade da arquitetura	50
5.4.1 Eficiência do motor de busca e redução de ruído	51
5.4.2 Custo computacional e latência	52
5.4.3 Confiabilidade da inferência local	53
6 Considerações Finais e Trabalhos Futuros	55
6.1 Declaração de uso de IA	57

Bibliografia	59
A Tabela Completa de Classificações	62

Lista de Figuras

4.1	Modelo conceitual do SisREAd	23
4.2	Questionário EMAPRE-U	25
5.1	Tela inicial do sistema	36
5.2	Tela de registro do sistema	36
5.3	Tela de login do sistema	37
5.4	Tela inicial após login	37
5.5	Tela inicial após resposta ao questionário	38
5.6	Tela para buscar REAs	39
5.7	Resultado de busca para o perfil Ensino Médio, interesse Algoritmos e meta Performance-Evitacão	39
5.8	Resultado de busca para o perfil Ensino Superior, interesse Reconhecimento de padrões e meta Aprender	40
5.9	Interface de resultados e avaliação da busca	40
5.10	Opções de avaliação e caixa de texto para comentários	41
5.11	Interface para mostrar resultados e espaço para avaliar a busca	42
5.12	Distribuição das respostas do questionário de avaliação do SisREAd	44
5.13	Matriz de confusão da classificação de metas de aprendizagem produzida pelo modelo <i>Llama 3.1</i> , comparada à classificação de referência (padrão-ouro).	49
5.14	Média de itens retornados vs. recomendados por repositório	51
5.15	Composição do tempo de resposta (em segundos)	52
5.16	Taxa global de estabilidade na classificação por IA	53

Lista de Tabelas

3.1	Comparação entre os trabalhos relacionados e o SisREAd	21
4.1	Distribuição das questões do EMAPRE-U por meta de aprendizagem . . .	27
5.1	Matriz de contingência utilizada no cálculo do coeficiente Kappa de Cohen	48
A.1	Comparação entre a Classificação Manual e a gerada pelo LLM	62

1 Introdução

A transformação digital na educação tem ampliado significativamente as possibilidades de acesso ao conhecimento, especialmente por meio de plataformas digitais e de recursos educacionais disponibilizados online. Nesse cenário, os Recursos Educacionais Abertos (REA) destacam-se como materiais de ensino, aprendizagem e pesquisa disponibilizados em domínio público ou sob licenças abertas, permitindo o acesso, a reutilização, a adaptação e a redistribuição, de acordo com UNESCO (2023). Esses recursos abrangem diferentes formatos (textos, vídeos, jogos educacionais, simuladores, cursos e objetos de aprendizagem) e são amplamente utilizados em diversos contextos educacionais, tendo como principal contribuição a democratização do acesso ao conhecimento, com maior flexibilidade pedagógica e práticas mais acessíveis e inclusivas. No contexto da Educação em Computação, os REA desempenham um papel relevante no desenvolvimento de habilidades, como o Pensamento Computacional, uma competência essencial para a formação acadêmica e profissional em uma sociedade cada vez mais orientada pela tecnologia.

Com a crescente quantidade de recursos disponíveis em ambiente digital, surgiram plataformas específicas para o armazenamento e a disponibilização desses materiais, conhecidas como Repositórios de Recursos Educacionais Abertos (RREA), para Clements, Pawlowski e Manouselis (2015), que concentram uma grande variedade de recursos classificados por tema, nível educacional e formato. Logo, os Recursos Educacionais Abertos constituem a representação material do conhecimento, enquanto os repositórios de REA desempenham um papel fundamental como meio de compartilhamento, organização e disseminação desse conhecimento, segundo Balbino e Barbosa (2025). Embora essa abundância represente uma vantagem em termos de acesso, ela também traz o desafio da seleção adequada: a diversidade de opções pode dificultar a busca e tornar complexo, para o usuário, encontrar materiais compatíveis com seus interesses, objetivos de aprendizagem e nível educacional. Paralelamente, os Sistemas de Recomendação (SR) têm sido amplamente utilizados para filtrar grandes volumes de informação e oferecer sugestões personalizadas, segundo Ricci, Rokach e Shapira (2015); no campo educacional,

podem contribuir para a personalização do ensino, auxiliando estudantes na identificação de recursos mais adequados ao seu perfil. Segundo Oliveira et al. (2025), a utilização de sistemas de recomendação em ambientes educacionais tem se tornado cada vez mais difundida nos últimos anos, devido ao avanço da digitalização do ensino.

Apesar da ampla disponibilidade de REA, a busca por recursos adequados ainda enfrenta limitações significativas. A simples recuperação por meio de consultas textuais nem sempre é suficiente para atender às necessidades dos aprendizes, uma vez que características como objetivos de aprendizagem, preferências e perfil do usuário influenciam a relevância dos materiais, para Rima et al. (2022). A ausência de mecanismos que considerem esses aspectos pode levar à apresentação de resultados pouco relevantes, aumentando o tempo de seleção e reduzindo a efetividade do processo de aprendizagem. Segundo Rima et al. (2022), a incorporação de características dos usuários é um dos elementos centrais para aumentar a relevância e a efetividade dos sistemas de recomendação de Recursos Educacionais Abertos.

A necessidade de mecanismos inteligentes de recomendação personalizada de REA justifica o desenvolvimento deste trabalho, pois a aplicação de Sistemas de Recomendação no contexto educacional pode reduzir a sobrecarga informacional e otimizar o acesso a conteúdos relevantes. Ao mapear as lacunas da área, Urdaneta-Ponte, Mendez-Zorrilla e Oleagordia-Ruiz (2021) assinalam nas conclusões que os trabalhos futuros devem priorizar o desenvolvimento de sistemas que usem técnicas inteligentes e avaliem seu desempenho computacional, algo que o presente trabalho tem como objetivo ao desenvolver um sistema de recomendação cuja funcionalidade e estabilidade foram testadas através de comandos automatizados.

Adicionalmente, a incorporação de informações sobre metas de aprendizagem representa uma oportunidade de tornar o processo mais preciso e adaptado às características individuais dos usuários. Segundo Capuano et al. (2011), experiências de aprendizagem personalizadas podem ser geradas a partir da combinação entre o perfil do aprendiz e suas metas, o que permite recomendações mais alinhadas aos seus objetivos educacionais. Dessa forma, este trabalho busca contribuir para a área de Sistemas de Recomendação Educacionais por meio de uma solução capaz de integrar múltiplos critérios de recomenda-

ção em um único ambiente, desenvolvida ao longo das etapas de levantamento bibliográfico, modelagem conceitual, implementação, integração com fontes externas, classificação baseada em metas de aprendizagem e avaliação experimental.

A partir dessa motivação, este trabalho orienta-se pela seguinte questão de pesquisa principal: *é possível conceber um sistema de recomendação de Recursos Educacionais Abertos que faça uso do perfil, interesse e metas de aprendizagem do usuário, para obter a classificação automática por um modelo de linguagem, de modo a produzir recomendações personalizadas com viabilidade técnica?* Dessa questão principal derivam-se duas questões secundárias:

- **QS1:** é viável integrar, em um único sistema, múltiplas fontes de REA com classificação por meta de aprendizagem, mantendo estabilidade e custo computacional aceitáveis?
- **QS2:** um modelo de linguagem de grande porte executado localmente é capaz de classificar REA segundo metas de realização com concordância próxima à de avaliadores humanos?

Diante desse contexto, o objetivo geral deste trabalho é desenvolver o SisREAD, um Sistema de Recomendação de Recursos Educacionais Abertos. Como objetivos específicos, pretende-se:

- coletar informações de perfil, interesse e metas de aprendizagem dos usuários;
- realizar buscas automatizadas em diferentes Repositórios de Recursos Educacionais Abertos;
- classificar os recursos encontrados com base em critérios pedagógicos e motivacionais;
- integrar modelos de linguagem locais ao processo de recomendação;
- avaliar a eficiência do sistema em termos de tempo de resposta e de relevância das recomendações.

Como principais contribuições, este trabalho apresenta: (i) a concepção e a implementação de uma arquitetura de recomendação que integra, em um único ambiente, a busca em dois repositórios de REA (Aquarela, MEC RED) e uma plataforma de vídeos (Eduplay), a identificação de metas de aprendizagem por meio da escala validada EMAPRE-U e a classificação automática de recursos; (ii) testes bem-sucedidos de que um modelo de linguagem de grande porte executado localmente é capaz de classificar REA segundo metas de realização com concordância próxima à humana, sustentada por um protocolo de validação com dois anotadores independentes e uma classificação de referência consolidada; e (iii) a caracterização do custo computacional e da estabilidade da inferência local, evidenciando o compromisso entre a qualidade da classificação pedagógica e a latência do sistema. Em conjunto, essas contribuições oferecem uma alternativa de baixo custo para a recomendação personalizada de recursos educacionais, dispensando o uso de APIs comerciais de inteligência artificial.

Quanto à sua organização, o trabalho está estruturado em cinco capítulos. Após esta introdução, o Capítulo 2 apresenta a fundamentação teórica, abordando Recursos Educacionais Abertos, Sistemas de Recomendação e metas de aprendizagem. O Capítulo 3 descreve os Trabalhos Relacionados a este e discute os principais pontos de divergência e apresenta uma tabela comparativa entre este trabalho e os citados. O Capítulo 4 descreve a metodologia, incluindo a arquitetura do sistema, as tecnologias empregadas e o processo de recomendação adotado, bem como o desenvolvimento e a implementação do SisREAd e sua integração com fontes externas. O Capítulo 5 apresenta e discute os resultados obtidos com o uso do sistema. Por fim, o Capítulo 6 traz as finais, as limitações encontradas e as propostas de trabalhos futuros.

2 Fundamentação Teórica

Este capítulo apresenta os principais conceitos teóricos que fundamentam o desenvolvimento do SisREAd. Inicialmente, são discutidos os SR e sua relevância no tratamento da sobrecarga informacional. Em seguida, abordam-se os REA e os repositórios responsáveis por sua disponibilização. Posteriormente, discute-se o papel das metas de aprendizagem e da escala EMAPRE-U no contexto educacional. Por fim, é apresentado o uso de Modelos de Linguagem aplicados à recomendação educacional.

2.1 Sistemas de Recomendação

Com o crescimento exponencial da internet e da disponibilidade de conteúdos digitais, a quantidade de informações acessíveis aos usuários aumentou significativamente. Embora esse cenário amplie o acesso ao conhecimento, ele também gera um problema conhecido como sobrecarga informacional, caracterizado pela dificuldade de localizar informações relevantes em meio a um grande volume de opções, afirmam Roy e Dutta (2022), Sohail, Siddiqui e Ali (2017), Ricci, Rokach e Shapira (2015).

Nesse contexto, os SR surgem como ferramentas computacionais voltadas à filtragem e personalização de informações. Seu objetivo principal é auxiliar os usuários a identificar itens potencialmente relevantes com base em características, preferências ou comportamentos observados, de acordo com Burke (2002), Bobadilla et al. (2013).

Segundo Burke (2002), um SR pode ser definido como qualquer sistema capaz de produzir recomendações individualizadas ou de conduzir o usuário a objetos úteis em um grande conjunto de alternativas. Para Bobadilla et al. (2013), esses sistemas consistem em aplicações que sugerem itens com base nos interesses dos usuários. Já Ricci, Rokach e Shapira (2015) os definem como ferramentas e técnicas de software que fornecem sugestões personalizadas.

Os sistemas de recomendação podem ser classificados em diferentes abordagens. Embora a literatura apresente diversas técnicas, incluindo métodos baseados em conheci-

mento, demográficos, contextuais e abordagens híbridas, as estratégias mais amplamente utilizadas e estudadas são a filtragem colaborativa, a filtragem baseada em conteúdo e os sistemas híbridos, segundo Shapira, Rokach e Ricci (2022). Assim, este trabalho discorre sobre essas principais abordagens:

- **Filtragem colaborativa:** realiza recomendações com base em padrões de comportamento de usuários semelhantes;
- **Filtragem baseada em conteúdo:** recomenda itens semelhantes àqueles previamente consumidos ou preferidos pelo usuário;
- **Sistemas híbridos:** combinam múltiplas estratégias de recomendação.

No contexto educacional, os SR assumem um papel estratégico ao possibilitar experiências de aprendizagem personalizadas. Ao considerar fatores como nível educacional, preferências e objetivos de aprendizagem, esses sistemas podem oferecer recomendações mais adequadas às necessidades específicas dos estudantes.

2.2 Recursos Educacionais Abertos

Os Recursos Educacionais Abertos (REA) representam uma importante iniciativa voltada à democratização do acesso ao conhecimento. De acordo com a UNESCO, trata-se de materiais de ensino, aprendizagem e pesquisa disponibilizados em domínio público ou sob licenças abertas, permitindo o acesso, a adaptação, a reutilização e a redistribuição, afirma UNESCO (2023).

Embora todo REA seja um recurso educacional digital, nem todo recurso educacional digital (RED) pode ser considerado um REA. Os RED compreendem materiais educacionais disponibilizados em formato digital, como livros eletrônicos, videoaulas, objetos de aprendizagem, simuladores, jogos educacionais e cursos on-line. Entretanto, apenas aqueles disponibilizados em domínio público ou sob licenças abertas são classificados como Recursos Educacionais Abertos. Segundo Santos (2012), a adoção de licenças abertas é o elemento que caracteriza um REA, uma vez que garante aos usuários o direito de acessar, utilizar, copiar, adaptar, remixar e compartilhar esses recursos de forma

legal, favorecendo a circulação do conhecimento e a produção colaborativa de materiais educacionais.

Segundo OECD (2007), os REA foram concebidos com o objetivo de ampliar a disseminação do conhecimento e reduzir as barreiras ao acesso à educação.

Uma das principais características dos REA é a flexibilidade pedagógica, que permite adaptações a diferentes contextos educacionais e perfis de estudantes.

No contexto da Educação em Computação, os REA têm relevância ainda maior, pois favorecem o desenvolvimento de competências técnicas e cognitivas por meio de recursos interativos e adaptáveis.

2.3 Repositórios de Recursos Educacionais Abertos

Os Repositórios de Recursos Educacionais Abertos (RREA) são plataformas digitais responsáveis por armazenar, organizar e disponibilizar REA para consulta e reutilização, para Clements, Pawlowski e Manouselis (2015).

Esses ambientes funcionam como catálogos digitais que permitem buscas por tema, área de conhecimento, formato e nível educacional.

Alguns dos exemplos de repositórios de REA são:

- MEC RED. Disponível em <<https://plataformaintegrada.mec.gov.br>>;
- Aquarela. Disponível em <<https://aquarela.app.br/>>;
- MERLOT. Disponível em <<https://www.merlot.org/merlot/>>;
- eduSource. Disponível em <<https://www.edusource.ca/>>.

Apesar da relevância dessas plataformas, a grande diversidade de recursos pode dificultar a busca por materiais adequados. Muitos repositórios realizam buscas baseadas exclusivamente em palavras-chave, sem considerar características específicas dos usuários.

Essa limitação evidencia a necessidade de mecanismos inteligentes de recomendação capazes de personalizar o processo de seleção.

2.4 Metas de Aprendizagem e EMAPRE-U

A motivação acadêmica é um fator determinante no processo de aprendizagem. Nesse contexto, as metas de aprendizagem são os objetivos que orientam o engajamento do estudante em atividades educacionais.

Os estudos sobre metas de realização indicam que os estudantes podem direcionar seus esforços para diferentes objetivos ao longo do processo de aprendizagem. Entre os modelos mais influentes da área destaca-se a estrutura 2×2 proposta por Elliot e McGregor (2001), composta pelas metas de domínio-aproximação, domínio-evitação, desempenho-aproximação e desempenho-evitação. Os autores, como Elliot e McGregor (2001), demonstraram que essas metas representam construtos independentes e estão associadas a diferentes antecedentes motivacionais e resultados acadêmicos, como ansiedade, desempenho em avaliações e engajamento nas atividades de aprendizagem.

Porém, neste trabalho, adotou-se o modelo tricotômico. Segundo Pereira et al. (2022), as metas de realização podem ser classificadas em:

- **Meta Aprender:** foco no domínio do conteúdo, na compreensão e no desenvolvimento de competências. Para Landis e Koch (1977), o foco recai sobre o desenvolvimento genuíno de competências e a compreensão profunda do conteúdo, valorizando a investigação, a descoberta e a autonomia do estudante, com o processo de aprender prevalecendo sobre o resultado.
- **Performance-Aproximação:** busca demonstrar desempenho superior em relação aos demais. Segundo Landis e Koch (1977), o foco recai sobre a demonstração de competência e a obtenção de resultados visíveis, por meio da aplicação prática, da construção de produtos com critérios claros de êxito e de dinâmicas de gamificação e de desafio.
- **Performance-Evitação:** preocupação em evitar erros, fracassos ou avaliações negativas. O foco recai sobre evitar a exposição ao erro e assegurar a segurança cognitiva, por meio de nivelamento teórico, materiais introdutórios, estruturas altamente guiadas e baixo risco de falha, afirmam Landis e Koch (1977).

Para aplicação no ensino superior, Santos, Alcará e Zenorini (2013) propuseram a Escala de Avaliação da Motivação para a Aprendizagem de Universitários (EMAPRE-U), um instrumento validado para identificar as principais metas motivacionais de estudantes universitários.

O problema de *cold-start* é um desafio persistente em sistemas de recomendação educacionais de abordagem colaborativa, afirmam Urdaneta-Ponte, Mendez-Zorrilla e Oleagordia-Ruiz (2021). Como solução, a literatura sugere enriquecer o perfil do utilizador com parâmetros multidimensionais, como estilos de aprendizagem e preferências pedagógicas, para Urdaneta-Ponte, Mendez-Zorrilla e Oleagordia-Ruiz (2021). A utilização da EMAPRE-U neste trabalho permite incorporar aspectos motivacionais ao processo de recomendação, tornando as sugestões mais alinhadas ao perfil de aprendizagem do usuário. Dessa forma, além de considerar características como perfil educacional e interesse temático, o sistema também leva em conta os objetivos que orientam o comportamento de estudo do usuário.

Segundo Sousa e Coelho (2023), há indícios de relações entre a prática docente e as discussões presentes na literatura sobre a satisfação das necessidades básicas e a motivação para aprender. Entretanto, observa-se que, no contexto investigado, a atuação dos professores concentrou-se principalmente em duas variáveis: a fixação dos conteúdos trabalhados e a participação dos alunos nas atividades e tarefas propostas em sala de aula.

Nesse sentido, evidencia-se a importância de ampliar as reflexões sobre aspectos relacionados à motivação e à satisfação das necessidades básicas de aprendizagem. Tais fatores devem ser considerados tanto no planejamento pedagógico quanto na condução das aulas, uma vez que exercem influência significativa sobre o processo de aprendizagem. A compreensão mais aprofundada dessas variáveis pode contribuir para o desenvolvimento de práticas pedagógicas mais eficazes e alinhadas às necessidades dos estudantes.

2.5 Modelos de Linguagem aplicados à Educação

Os avanços recentes em Inteligência Artificial impulsionaram o uso de Modelos de Linguagem de Grande Escala (LLMs) em diferentes domínios, incluindo a educação.

Os Modelos de Linguagem de Grande Escala representam um avanço significativo na área de Processamento de Linguagem Natural (PLN). Esses modelos utilizam técnicas de aprendizado profundo, especialmente arquiteturas baseadas em transformadores, para identificar e compreender padrões complexos presentes em grandes volumes de dados linguísticos. Uma de suas principais características é a capacidade de processar extensas quantidades de informações, incluindo textos não estruturados, permitindo a identificação de relações semânticas entre palavras, expressões e conceitos. Além de dados textuais, os LLMs também podem ser aplicados ao processamento de outros tipos de conteúdo, como imagens, áudio, vídeos e dados multimodais, possibilitando a compreensão das relações existentes entre diferentes formas de informação. Como resultado, esses modelos ampliaram significativamente a capacidade dos sistemas computacionais de interpretar e gerar linguagem natural de maneira semelhante à comunicação humana, segundo Hadi et al. (2023).

No contexto educacional, para Kasneci et al. (2023), podem ser aplicados em tarefas como:

- tutoria automatizada;
- geração de conteúdo;
- análise semântica;
- classificação pedagógica de recursos;
- planejamento de aulas;
- personalização do ensino;
- apoio à avaliação da aprendizagem.

Segundo Kasneci et al. (2023), os LLMs podem auxiliar professores na criação de experiências de aprendizagem personalizadas, fornecendo materiais e feedback adaptados às necessidades específicas dos estudantes. Além disso, esses modelos podem contribuir para o planejamento de aulas, elaboração de atividades e geração de avaliações adequadas a diferentes níveis de conhecimento.

Os autores, como Kasneci et al. (2023), também destacam aplicações relacionadas ao ensino de línguas, produção textual, pesquisa acadêmica, formação continuada de professores e apoio aos processos de avaliação da aprendizagem.

Considerando esse potencial, neste trabalho os modelos de linguagem são empregados na classificação de REA de acordo com metas de aprendizagem. A utilização de modelos executados localmente por meio do Ollama, uma ferramenta gratuita e de código aberto que permite executar Grandes Modelos de Linguagem (LLMs) diretamente no seu computador, (disponível em <<https://ollama.com/>>) possibilita a análise dos recursos recuperados e sua associação às metas mais compatíveis, contribuindo para recomendações mais contextualizadas.

Diversos estudos têm investigado o potencial dos Modelos de Linguagem de Grande Escala (LLM) no contexto educacional, destacando aplicações que vão desde a personalização do ensino até o apoio à avaliação da aprendizagem, segundo Kasneci et al. (2023).

2.6 Finais do Capítulo

Os conceitos apresentados neste capítulo fornecem a base teórica necessária para o desenvolvimento do SisREAd.

A integração entre Sistemas de Recomendação, Recursos Educacionais Abertos, metas de aprendizagem e Modelos de Linguagem constitui o alicerce conceitual da proposta desenvolvida neste trabalho.

A partir dessa fundamentação, o capítulo seguinte apresenta e compara trabalhos relacionados a este.

3 Trabalhos Relacionados

Este capítulo apresenta trabalhos relacionados ao SisREAd, organizados segundo as dimensões que caracterizam a proposta: a integração de múltiplos Repositórios de Recursos Educacionais Abertos (RREA), a consideração de objetivos ou metas de aprendizagem no processo de recomendação, a classificação automática dos recursos e a avaliação empírica das soluções. Ao final, um quadro comparativo posiciona o SisREAd em relação a esse conjunto.

Os trabalhos apresentados a seguir estão disponíveis no Google Acadêmico¹, e foram encontrados após uma busca nessa plataforma por trabalhos da área.

Entre os trabalhos que incorporam o propósito de aprendizagem ao processo de recomendação, destaca-se a linha conduzida por Villalba et al. (2017), que propõe um recomendador de REA baseado na taxonomia SOLO para identificar, a partir do verbo que expressa a intenção pedagógica do professor, os processos cognitivos associados e, assim, sugerir recursos adequados. Essa abordagem foi posteriormente estendida por Villalba-Condori et al. (2022), que conceberam uma plataforma de busca multirrótulo capaz de unificar informações de diferentes repositórios de REA por meio de técnicas de *web scraping*, classificando os recursos segundo a taxonomia SOLO com um classificador multirrótulo baseado em *Multilayer Perceptron* (MLP) e relatando acurácia de até 85% na recuperação de recursos pertinentes. Em direção semelhante, o sistema MOORS, de Hajri, Bourda e Popineau (2019), recomenda REA em cursos online, combinando o perfil do estudante com o do curso do tipo *Massive Open Online Course* (MOOC) e apoiando-se em princípios de *Linked Open Data* para calcular recomendações a partir dos metadados dos recursos.

Outra vertente relevante reúne sistemas voltados a abordagens híbridas e à escalabilidade. Tarus, Niu e Yousif (2017) propõem um recomendador híbrido para *e-learning* que integra uma ontologia de domínio à mineração de padrões sequenciais do comportamento dos estudantes, combinando conhecimento estruturado e histórico de navegação.

¹<https://scholar.google.com/>

Já Dahdouh et al. (2019) concentram-se no desafio de escala, implementando um recomendador de *e-learning* de larga escala sobre as plataformas distribuídas Spark e Hadoop, com foco no desempenho computacional do processamento de grandes volumes de dados educacionais.

No tema da classificação automática de recursos, Carvalho et al. (2022) investigam a classificação automática de vídeos educacionais a partir dos comentários dos usuários, empregando técnicas de Aprendizado de Máquina sobre dados do YouTube. Ainda no contexto brasileiro, Júnior, Araújo e Dorça (2023) propõem uma abordagem de recomendação personalizada de materiais educacionais por filtragem baseada em conteúdo em Ambientes Virtuais de Aprendizagem, explorando recursos da Web (como YouTube e Wikipédia) e considerando estilos de aprendizagem na seleção dos materiais.

A relação entre REA e objetivos de aprendizagem também tem sido estudada sob a ótica das taxonomias pedagógicas e da qualidade dos repositórios. Ortiz et al. (2020) analisam os objetivos de aprendizagem referenciados nos metadados de Objetos Educacionais com base na Taxonomia Digital de Bloom e investigam como os professores se apropriam dos recursos disponíveis na PhET Colorado². Medeiros et al. (2021), por sua vez, realizam uma análise comparativa entre repositórios brasileiros de REA voltados à educação básica, avaliando sua qualidade como apoio ao ensino. Em um plano mais amplo, revisões sistemáticas como as de Sandoussi et al. (2022), Silva et al. (2023) e Urdaneta-Ponte, Mendez-Zorrilla e Oleagordia-Ruiz (2021) consolidam o estado da arte e convergem em algumas lacunas recorrentes: a predominância de soluções centradas em repositórios únicos, a necessidade de sistemas híbridos que incorporem técnicas inteligentes, a importância de enriquecer o perfil do usuário com parâmetros multidimensionais e a recomendação de que tais sistemas sejam avaliados de forma rigorosa quanto ao desempenho.

A Tabela 3.1 sintetiza a comparação entre os principais sistemas de recomendação discutidos e o SisREAd, considerando cinco dimensões: a integração de múltiplos repositórios, a consideração de metas ou objetivos de aprendizagem, o uso de classificação automática por Inteligência Artificial, a execução local de baixo custo (sem dependência

²<https://phet.colorado.edu/pt/>

de APIs comerciais) e a realização de testes.

Tabela 3.1: Comparação entre os trabalhos relacionados e o SisREAd

Trabalho	Múltiplos repos.	Metas/obj. aprendiz.	Classif. por IA	Local/ baixo custo	Aval. empírica
Villalba et al. (2017, 2022)	Sim	Sim ¹	Sim ²	Não	Sim
MOORS (Hajri et al., 2019)	Não	Parcial	Não	Não	Sim
Tarus et al. (2017)	Não	Não	Sim ³	Não	Sim
Dahdouh et al. (2019)	Não	Não	Sim ³	Não	Sim
Pereira Júnior et al. (2023)	Parcial	Parcial ⁴	Sim ³	Não	Sim
SisREAd (este trabalho)	Sim	Sim⁵	Sim⁶	Sim	Sim

¹ Propósito de aprendizagem (taxonomia SOLO, cognitiva). ² Classificador MLP multirrótulo.

³ Técnicas de Aprendizado de Máquina/ontologia, sem LLM. ⁴ Estilos de aprendizagem.

⁵ Metas de realização (motivacionais), via escala EMAPRE-U. ⁶ Modelo de linguagem (LLM) de execução local.

A análise comparativa evidencia que, embora diversos trabalhos abordem, isoladamente, as dimensões consideradas, nenhum deles as reúne na forma proposta pelo SisREAd. O trabalho de Villalba-Condori et al. (2022) é o que mais se aproxima, por unificar múltiplos repositórios e classificar os recursos segundo um propósito de aprendizagem. Entretanto, fundamenta-se na taxonomia SOLO, de natureza cognitiva, e em um classificador MLP, e não no aspecto motivacional das metas de realização nem em modelos de linguagem. Os demais sistemas, por sua vez, ou se restringem a repositórios únicos, ou não incorporam objetivos de aprendizagem, ou empregam classificação automática sem recorrer a LLMs. O diferencial do SisREAd está justamente na combinação dessas dimensões: a integração de dois repositórios de REA e uma plataforma de vídeos, a incorporação de metas de realização identificadas por um instrumento validado (EMAPRE-U), a classificação automática por meio de um modelo de linguagem executado localmente e, portanto, de baixo custo, e testes tanto da qualidade da classificação quanto do desempenho e da estabilidade da arquitetura.

4 Metodologia

Este capítulo apresenta os procedimentos metodológicos adotados para o desenvolvimento do SisREAd. São descritas a caracterização da pesquisa, a arquitetura da solução proposta, o fluxo de recomendação implementado, as tecnologias empregadas e os critérios utilizados para avaliação do sistema.

4.1 Caracterização da Pesquisa

Este trabalho caracteriza-se como uma pesquisa aplicada, de natureza tecnológica e abordagem experimental, uma vez que propõe o desenvolvimento e a avaliação de uma solução computacional voltada à recomendação personalizada de Recursos Educacionais Abertos.

Quanto aos objetivos, a pesquisa tem caráter exploratório e descritivo. Exploratório por investigar a aplicação conjunta de Sistemas de Recomendação, metas de aprendizagem e Modelos de Linguagem no contexto educacional; e descritivo por apresentar e analisar o funcionamento do sistema desenvolvido.

4.2 Arquitetura do Sistema

O SisREAd foi desenvolvido com base em uma arquitetura Model-View-Controller (MVC) orientada à separação entre interface, lógica de negócio, integração externa e persistência de dados.

A Figura 4.1 apresenta o modelo conceitual da solução.




Figura 4.1: Modelo conceitual do SisREAd

A arquitetura é composta pelas seguintes partes:

- **Entrada:** responsável pela coleta das informações fornecidas pelo usuário;
- **Recomendação:** responsável pela busca, filtragem e ordenação dos recursos;
- **Classificação:** realiza a categorização dos recursos com base em metas de aprendizagem, para os REAs obtidos após busca especificamente no Aquarela;
- **Persistência:** armazena dados de busca e sugestões de recursos;
- **Apresentação:** responsável pela exibição dos resultados.

4.3 Fluxo de Recomendação

As entradas obrigatórias do sistema são:

- **Perfil:** nível educacional do usuário, de Educação Infantil a Ensino Superior;
- **Interesse:** área temática desejada para busca de recursos.

Opcionalmente, usuários cadastrados podem responder ao questionário EMAPRE-U para identificação de sua meta predominante de aprendizagem.

A partir dessas informações, o sistema executa o processo de recomendação conforme o fluxo ilustrado no modelo conceitual.

Inicialmente, uma consulta é realizada nas APIs externas integradas ao sistema. Os recursos retornados passam por um processo de filtragem e classificação, sendo posteriormente ordenados de acordo com sua relevância para o perfil informado.

4.4 Integração com Repositórios Externos

O SisREAd realiza buscas automatizadas em três fontes principais:

- **Aquarela**;
- **MEC RED**;
- **Eduplay**. Disponível em <<https://eduplay.rnp.br>>.

O repositório Aquarela permite recuperação de recursos por meio de consultas textuais, retornando resultados compatíveis com palavras-chave informadas, afirma Balbino, Deus e Barbosa (2023).

De acordo com MEC (2024), a plataforma MEC RED reúne recursos provenientes de múltiplas iniciativas educacionais brasileiras, disponibilizando metadados como tipo do recurso, descrição e área temática.

O Eduplay foi incorporado como fonte complementar de vídeos educacionais.

As consultas são realizadas dinamicamente a partir do campo de interesse informado pelo usuário.

Um dos pontos críticos identificados na literatura de sistemas de recomendação educacionais, como em Urdaneta-Ponte, Mendez-Zorrilla e Oleagordia-Ruiz (2021), é a centralização das buscas em repositórios únicos, o que limita a variedade de materiais oferecidos. Para mitigar essa limitação e oferecer um serviço de recomendação mais abrangente, o SisREAd foi projetado para explorar de forma distribuída uma variedade de fontes heterogêneas, integrando as APIs do Aquarela, MEC RED e Eduplay.

4.5 Classificação por Meta de Aprendizagem

Para usuários cadastrados, o sistema incorpora informações motivacionais ao processo de recomendação.

Após o preenchimento do questionário EMAPRE-U, ilustrado na Figura 4.2, o sistema identifica a meta predominante do usuário entre:

- Aprender;
- Performance-Aproximação;
- Performance-Evituação.

Uma razão pela qual eu faço minhas tarefas escolares é por gostar delas.

☐ Discordo Completamente

☐ Discordo

☐ Não sei

☐ Concordo

☐ Concordo Completamente

Uma razão importante pela qual faço minhas tarefas escolares é porque eu gosto de aprender coisas novas.

☐ Discordo Completamente

☐ Discordo

☐ Não sei

☐ Concordo

☐ Concordo Completamente

Quanto mais difícil a matéria, mais eu gosto de tentar compreender.

☐ Discordo Completamente

☐ Discordo

☐ Não sei

☐ Concordo

☐ Concordo Completamente

Figura 4.2: Questionário EMAPRE-U

A identificação da meta de aprendizagem do usuário é realizada por meio da aplicação digital do questionário EMAPRE-U, instrumento validado para avaliação da motivação acadêmica em estudantes universitários, para Santos, Alcará e Zenorini (2013).

O questionário é composto por 28 afirmações distribuídas em três dimensões motivacionais: Meta Aprender, Meta Performance-Aproximação e Meta Performance-Evituação, segundo Pereira et al. (2022).

Cada afirmação é respondida pelo usuário em escala Likert de cinco pontos, variando de 1 a 5, representando diferentes níveis de concordância.

Após o preenchimento, o sistema realiza o cálculo da média aritmética das respostas associadas a cada dimensão motivacional.

Formalmente, para cada meta de aprendizagem m , o escore é calculado pela Equação 4.1:

$$M_m = \frac{\sum_{i=1}^n r_i}{n} \quad (4.1)$$

em que:

- M_m representa a média da meta de aprendizagem;
- r_i corresponde à resposta atribuída à questão i ;
- n representa o número de questões pertencentes à dimensão analisada.

Ao final do processamento, a meta dominante do usuário é definida como a que apresenta o maior valor médio entre as três dimensões avaliadas. Esse resultado é persistido no banco de dados e, posteriormente, utilizado como critério adicional no processo de recomendação personalizada de Recursos Educacionais Abertos. A Tabela 4.1, como demonstrada em Pereira et al. (2022), apresenta a distribuição das questões do questionário EMAPRE-U conforme suas respectivas dimensões motivacionais.

No caso dos recursos oriundos do Aquarela, as informações textuais de cada recurso, como título, tipo de dado, descrição e metadados, são enviadas a um Modelo de Linguagem executado localmente por meio do Ollama. O modelo recebe um prompt com a descrição, o formato e os metadados do recurso e retorna a meta de aprendizagem mais compatível. A recomendação final prioriza recursos cuja classificação coincide com a meta identificada para o usuário.

Para os recursos provenientes da plataforma MEC RED, o processo de recomendação é realizado por meio de uma abordagem heurística baseada em regras previamente definidas. Diferentemente dos recursos obtidos a partir do repositório Aquarela, cuja classificação utiliza inferência realizada por Modelo de Linguagem, os recursos do MEC RED

Tabela 4.1: Distribuição das questões do EMAPRE-U por meta de aprendizagem

Meta de Aprendizagem	Questões Associadas
Meta Aprender (MA)	1. Quando vou mal em uma prova, estudo mais para a próxima; 2. Eu não desisto facilmente diante de uma tarefa difícil; 3. Faço minhas tarefas escolares porque estou interessado(a) nelas; 4. Gosto dos trabalhos escolares com os quais aprendo algo, mesmo que cometa algum erro; 5. Uma razão pela qual eu faço minhas tarefas escolares é por gostar delas; 6. Uma razão importante pela qual faço minhas tarefas escolares é porque eu gosto de aprender coisas novas; 7. Quanto mais difícil a matéria, mais eu gosto de tentar compreender; 8. Eu gosto mais das tarefas quando elas me fazem pensar; 9. Gosto quando uma matéria me faz sentir vontade de aprender mais; 10. Uma importante razão pela qual eu estudo pra valer é porque eu quero aumentar meus conhecimentos; 11. Gosto de tarefas difíceis e desafiadoras; 12. Sou perseverante, mesmo quando uma tarefa me frustra.
Meta Performance-Aproximação (MPA)	13. Para mim, é importante fazer as coisas melhor que os demais; 14. É importante, para mim, fazer as coisas melhor que os meus colegas; 15. Na minha turma, eu quero me sair melhor que os demais; 16. Sinto-me bem-sucedido na aula quando sei que meu trabalho foi melhor que o dos meus colegas; 17. Gosto de mostrar aos meus colegas que sei as respostas; 18. Para mim, é importante conseguir concluir tarefas que meus colegas não conseguem; 19. Sucesso na escola é fazer as coisas melhor que os outros; 20. Gosto de participar dos trabalhos em grupo sempre que eu posso ser o líder; 21. Ser o primeiro da classe é o que me leva a estudar.
Meta Performance-Evituação (MPE)	22. Não respondo aos questionamentos feitos pelo professor por medo de falar alguma besteira; 23. Não participo dos debates em sala de aula porque não quero que os colegas riam de mim; 24. Não me posiciono nas discussões em sala de aula, pois acho que vou falar alguma coisa que os outros vão achar ruim; 25. Não participo das aulas quando tenho dúvidas no conteúdo que está sendo trabalhado; 26. Uma razão pela qual eu não participo da aula é evitar parecer ignorante; 27. Não questiono o professor quando tenho dúvidas na matéria para não correr o risco de parecer menos inteligente que meus colegas; 28. Não participo das aulas para evitar que meus colegas e professores me achem pouco inteligente.

são filtrados com base nos metadados estruturados disponibilizados pela própria API, especialmente o atributo referente ao tipo de objeto educacional (*object_type*).

A lógica implementada estabelece associações entre determinados formatos de recursos e as metas de aprendizagem identificadas pelo sistema, considerando as características pedagógicas de cada tipo de material.

Para usuários classificados com **Meta Aprender (MA)**, são priorizados recursos que favorecem exploração conceitual, aprofundamento teórico e aprendizagem investigativa, como e-books, videoaulas, objetos interativos, simuladores e cursos estruturados.

Para usuários classificados com **Meta Performance-Aproximação (MPA)**, são priorizados recursos orientados à resolução prática de problemas, atividades avaliativas e materiais que estimulem desempenho e comparação de resultados, como exercícios, desafios, avaliações e atividades práticas.

Para usuários classificados com **Meta Performance-Evituação (MPE)**, são priorizados recursos que favorecem estudo autônomo, consulta individual e revisão gradual do conteúdo, como materiais explicativos, objetos de apoio e conteúdos de revisão.

Essa associação é implementada diretamente na composição dinâmica das requisições enviadas à API do MEC RED, por meio da inclusão de parâmetros específicos de filtragem no campo *object_type*. Dessa forma, o sistema restringe os resultados retornados aos formatos previamente associados à meta predominante do usuário.

Além da meta de aprendizagem, o sistema também aplica filtros com base no nível educacional informado pelo usuário, garantindo que os recursos recuperados sejam compatíveis com o perfil acadêmico do usuário.

No caso do Eduplay, os recursos são recomendados prioritariamente para usuários classificados com Meta Aprender.

Devido às restrições e particularidades de cada API e repositório, é sempre necessário adicionar uma nova interface de integração e sua respectiva lógica de processamento quando se tem como objetivo adicionar uma nova fonte de recursos neste Sistema de Recomendação.

4.6 Recomendação para Usuários Não Cadastrados

Quando o usuário opta por não realizar o cadastro, o sistema utiliza uma base de referência interna armazenada no banco de dados.

Essa base contém registros previamente classificados contendo:

- perfil educacional;
- interesse;
- tipo de recurso.

A ordenação das recomendações segue três níveis de prioridade:

1. correspondência simultânea entre perfil, interesse e tipo de recurso;
2. correspondência entre perfil e interesse;
3. correspondência apenas por interesse.

Esse mecanismo busca oferecer recomendações relevantes mesmo na ausência de informações motivacionais.

4.7 Tecnologias Utilizadas

O desenvolvimento do SisREAd foi realizado utilizando tecnologias voltadas à construção de aplicações Web modernas.

O back-end foi implementado com Laravel³, framework PHP baseado no padrão MVC. A camada de interface foi desenvolvida com Livewire⁴, permitindo a construção de componentes reativos diretamente em PHP. Para persistência de dados foi utilizado SQLite⁵, escolhido por sua simplicidade de configuração e leveza.

A integração com Modelos de Linguagem foi realizada por meio do Ollama, que torna possível baixar, atualizar e gerenciar um LLM. Por meio dele, utilizou-se o LLM *llama3.1*.

³<https://laravel.com/>

⁴<https://livewire.laravel.com/>

⁵<https://sqlite.org/>

4.8 Processo de recomendação dos REAs

O sistema recomenda REAs com base na combinação de diferentes critérios informados pelo usuário. Os principais parâmetros utilizados são o Perfil, que representa o nível educacional desejado, o Interesse, que representa o tema de busca, e, quando disponível, a Meta de Aprendizagem obtida por meio do questionário EMAPRE-U.

Para ampliar a quantidade e a diversidade dos recursos retornados, o sistema consulta simultaneamente diferentes plataformas que retornam REAs, atualmente compostas por repositórios do MEC RED, da Aquarela e do portal de conteúdo audiovisual Eduplay. Cada um possui características próprias de busca e de disponibilização de metadados, o que exige tratamentos específicos na coleta e na classificação dos resultados.

Inicialmente, as consultas são enviadas às APIs dos repositórios selecionados. Os resultados retornados são processados e convertidos em uma estrutura de dados padronizada, permitindo que recursos provenientes de diferentes fontes sejam apresentados de forma uniforme ao usuário.

4.9 Classificação dos recursos

Após a obtenção dos resultados, cada recurso passa por um processo de classificação que determina seu nível de aderência aos parâmetros informados pelo usuário. Quando a busca é realizada sem considerar uma meta de aprendizagem, a classificação ocorre com base em dois critérios:

- Compatibilidade entre o nível educacional do recurso e o Perfil informado;
- Compatibilidade entre o tipo de conteúdo do recurso e os tipos de recursos previamente cadastrados em uma tabela da base de dados de REAs do sistema, incrementável pelo usuário.

A partir dessa análise, os recursos recebem uma das seguintes classificações:

- **both:** o recurso atende simultaneamente ao perfil educacional e ao tipo de conteúdo desejado;

- **profile:** o recurso atende apenas ao perfil educacional;
- **interest:** o recurso não atende integralmente aos critérios anteriores, mas está relacionado ao interesse pesquisado.

Quando há uma meta de aprendizagem associada ao usuário, passa a ser considerado um terceiro critério. Nesse cenário, os recursos também são analisados quanto à sua adequação à meta predominante identificada pelo questionário EMAPRE-U. As classificações passam então a assumir os seguintes valores:

- **meta_both:** atende à meta de aprendizagem e também aos demais critérios de perfil e tipo de conteúdo;
- **meta_one:** atende à meta de aprendizagem e parcialmente aos demais critérios;
- **meta:** atende à meta de aprendizagem, mas não necessariamente aos demais critérios.

Essa estratégia permite que o sistema preserve recursos potencialmente relevantes mesmo quando não atendem perfeitamente a todos os filtros definidos pelo usuário.

4.10 Identificação da meta de aprendizagem dos recursos

A identificação da meta de aprendizagem dos recursos varia conforme o repositório consultado. No caso do MEC RED e do Eduplay, a própria estratégia de consulta já utiliza filtros compatíveis com a meta de aprendizagem selecionada, permitindo que os recursos retornados sejam previamente alinhados às características desejadas.

Já para os recursos provenientes do Aquarela, é realizada uma etapa adicional de classificação utilizando um Modelo de Linguagem de Grande Escala (LLM). Para cada recurso recuperado, o sistema analisa o título, a descrição e o tipo de dado do REA e solicita ao modelo a identificação da meta predominante entre:

- Meta Aprender;

- Performance-Aproximação;
- Performance-Evituação.

A classificação retornada pelo modelo é então comparada à meta do usuário, o que permite determinar o nível de compatibilidade do recurso com o perfil motivacional identificado pelo questionário EMAPRE-U.

4.11 Determinação das características pedagógicas

Além da classificação por perfil, interesse e meta de aprendizagem, o sistema também associa características pedagógicas aos recursos recuperados. Essas características incluem:

- Interatividade;
- Nível de interatividade;
- Estilo de aprendizagem predominante;
- Estratégia de aprendizagem.

No repositório Aquarela, essas informações são obtidas a partir do atributo *dtype*. Recursos classificados como interativos apresentam características associadas à aprendizagem ativa, enquanto os expositivos apresentam características relacionadas à aprendizagem reflexiva e passiva. Nos demais repositórios, essas informações são inferidas a partir da natureza dos conteúdos e dos filtros aplicados durante a consulta.

4.12 Critério de destaque dos recursos (Highlight)

Com o objetivo de facilitar a identificação dos recursos mais relevantes, o sistema utiliza um mecanismo visual de destaque denominado *highlight*.

Os recursos destacados são aqueles que apresentam maior aderência aos critérios informados pelo usuário durante a busca. Dessa forma, um recurso recebe *highlight* quando pertence às categorias de recomendação consideradas mais relevantes para o contexto da consulta.

Quando a busca não utiliza meta de aprendizagem, os recursos classificados como *both* recebem destaque prioritário, pois atendem simultaneamente ao perfil educacional informado e aos tipos de conteúdo desejados.

Quando a busca utiliza meta de aprendizagem, o destaque é atribuído prioritariamente aos recursos classificados como *meta_both*, uma vez que estes apresentam compatibilidade simultânea com a meta de aprendizagem do usuário, o perfil educacional selecionado e os tipos de conteúdo desejados.

Os recursos classificados como *profile*, *interest*, *meta* e *meta_one* continuam sendo exibidos ao usuário, porém sem o mesmo nível de destaque visual, pois apresentam menor aderência ao conjunto completo de critérios considerados na recomendação.

Essa estratégia permite que os recursos potencialmente mais adequados sejam identificados rapidamente pelo usuário, sem que recursos parcialmente compatíveis sejam descartados da lista de resultados.

4.13 Métricas coletadas durante as buscas

Além da recomendação de recursos, o sistema registra diversas métricas referentes à execução das buscas. Entre as informações armazenadas encontram-se:

- Tempo total da busca;
- Tempo gasto nas consultas às APIs dos repositórios;
- Quantidade de chamadas realizadas às APIs;
- Quantidade de recursos retornados;
- Quantidade de recursos classificados como relevantes;
- Quantidade de falhas ou tempos limite ocorridos durante as consultas;
- Quantidade de chamadas ao modelo de linguagem utilizado para classificar os recursos.

Essas métricas permitem avaliar o desempenho do sistema e analisar o comportamento do processo de recomendação durante os experimentos apresentados nas próximas seções.

5 Resultados

Este capítulo descreve os resultados obtidos após o desenvolvimento do sistema. Os resultados são apresentados de modo a responder às questões de pesquisa definidas no Capítulo 1. A Seção de verificação da classificação automática endereça a QS2, ao mensurar a concordância entre o modelo de linguagem e avaliadores humanos, enquanto a seção de desempenho e escalabilidade da arquitetura endereça a QS1, ao avaliar a integração dos repositórios, o custo computacional e a estabilidade da inferência local. Em conjunto, ambas sustentam a resposta à questão principal.

5.1 Interfaces do sistema

Esta seção apresenta as interfaces do SisREAd, descrevendo suas funcionalidades e objetivos a partir do fluxo de uso do sistema, desde o acesso inicial até a busca, recomendação e avaliação dos REAs.

O ponto de entrada do sistema é a tela inicial, ilustrada na Figura 5.1. Nela, o usuário encontra as opções Colaborador, Usuário, Deixar feedback, Login e Registrar, podendo receber recomendações com ou sem a criação de uma conta. Caso opte por não se cadastrar, a meta de aprendizagem não é considerada no processo de recomendação. Do lado esquerdo da tela, é exibida uma lista com as pesquisas de Perfil e Interesse mais frequentemente submetidas no sistema.




Figura 5.1: Tela inicial do sistema

Para utilizar a funcionalidade baseada na meta de aprendizagem, o usuário precisa criar uma conta por meio da tela de registro, apresentada na Figura 5.2, na qual preenche suas informações de cadastro. O acesso posterior é feito pela tela de login, exibida na Figura 5.3.

Figura 5.2: Tela de registro do sistema




Figura 5.3: Tela de login do sistema

Após o login, o usuário é direcionado à tela ilustrada na Figura 5.4, na qual pode optar por responder ao questionário EMAPRE-U, para identificar sua meta de aprendizagem predominante, ou prosseguir diretamente para a busca de REAs apenas por Perfil e Interesse, sem responder ao questionário. A interface de resposta ao questionário, apresentada na Figura 4.2, tem como objetivo determinar a meta de aprendizagem dominante por meio das perguntas listadas na Tabela 4.1, relacionadas ao modo como o usuário se sente mais confortável para aprender e estudar.




Figura 5.4: Tela inicial após login

Concluído o questionário, o sistema exibe a meta de aprendizagem dominante

abaixo do nome do usuário, conforme a Figura 5.5. Como observado nesta, não há possibilidade de responder o questionário novamente e ter uma nova meta de aprendizagem cadastrada. Esse valor é obtido pela Equação 4.1, processada a partir das respostas marcadas e submetidas. No exemplo apresentado, a meta dominante identificada é a Performance-Evitação.




Figura 5.5: Tela inicial após resposta ao questionário

A busca e a recomendação de REAs são realizadas na interface da Figura 5.6, composta por dois campos: Perfil, referente ao nível educacional de preferência do usuário, e Interesse, referente ao assunto desejado. Essa interface está disponível tanto para usuários cadastrados quanto para os que acessam o sistema sem conta. As Figuras 5.7 e 5.8 apresentam resultados de busca em diferentes configurações: a primeira corresponde ao perfil Ensino Médio, com interesse em Algoritmos, para um usuário cuja meta dominante é Performance-Evitação; a segunda, ao perfil Ensino Superior, com interesse em Reconhecimento de padrões, para um usuário cuja meta dominante é Aprender.

SisREAD

Sistema de Recomendação para REA

Perfil

Ensino superior

Interesse

Pensamento computacional

Voltar

Buscar

Figura 5.6: Tela para buscar REAs

Tabela de REAs encontrados nos repositórios:

AVALIE	TÍTULO	ITEM	REPOSITÓRIO	TIPO DE INTERATIVIDADE	NÍVEL DE INTERATIVIDADE	ESTILO DE APRENDIZAGEM	ESTRATÉGIA	META	LINK
✓ ✕	Plano de Aula - Pensamento Computacional para os Anos Iniciais do Ensino Fundamental.		MECRED	Expositivo	Baixo / Muito baixo	Sensorial / Reflexivo / Auditivo/Visual	Passiva / Concreta / Visual/Verbal		
✓ ✕	Plano de Aula - Pensamento Computacional para os Anos Iniciais do Ensino Fundamental.		MECRED	Expositivo	Baixo / Muito baixo	Sensorial / Reflexivo / Auditivo/Visual	Passiva / Concreta / Visual/Verbal		
✓ ✕	Plano de Aula - Pensamento Computacional para os Anos Iniciais do Ensino Fundamental.		MECRED	Expositivo	Baixo / Muito baixo	Sensorial / Reflexivo / Auditivo/Visual	Passiva / Concreta / Visual/Verbal		
✓ ✕	Educação Digital na BNCC Computação - PodCast		MECRED	Expositivo	Baixo / Muito baixo	Sensorial / Reflexivo / Auditivo/Visual	Passiva / Concreta / Visual/Verbal		
✓ ✕	Lili e o Portal dos Dados: Planos de Aula Integrados à BNCC para o Ensino Fundamenta		MECRED	Expositivo	Baixo / Muito baixo	Sensorial / Reflexivo / Auditivo/Visual	Passiva / Concreta / Visual/Verbal		

Figura 5.7: Resultado de busca para o perfil Ensino Médio, interesse Algoritmos e meta Performance-Evituação

Tabela de REAs encontrados nos repositórios:									
AVALIE	TÍTULO	ITEM	REPOSITÓRIO	TIPO DE INTERATIVIDADE	NÍVEL DE INTERATIVIDADE	ESTILO DE APRENDIZAGEM	ESTRATÉGIA	META	LINK
✓ ✕	Plano de Aula: O sistema respiratório	Arquivo PDF	Aquarela	Não especificado	Não especificado	Não especificado	Não especificado		https://aquarelaapi.dev.br/api/reas/
✓ ✕	Reconhecimento da união homoafetiva	Video	Eduplay	Ativo	Alto / Muito alto	Intuitivo / Ativo / Auditivo/Visual	Ativa / Abstrata / Visual/Verbal		https://eduplay.mp.br/app/video/11
✓ ✕	Alguns Padrões GoF	Video	Eduplay	Ativo	Alto / Muito alto	Intuitivo / Ativo / Auditivo/Visual	Ativa / Abstrata / Visual/Verbal		https://eduplay.mp.br/app/video/11
✓ ✕	Alguns Padrões GRASP	Video	Eduplay	Ativo	Alto / Muito alto	Intuitivo / Ativo / Auditivo/Visual	Ativa / Abstrata / Visual/Verbal		https://eduplay.mp.br/app/video/11
✓ ✕	Padrões em Frequências	Video	Eduplay	Ativo	Alto / Muito alto	Intuitivo / Ativo / Auditivo/Visual	Ativa / Abstrata / Visual/Verbal		https://eduplay.mp.br/app/video/11
✓ ✕	Padrões de Software	Video	Eduplay	Ativo	Alto / Muito alto	Intuitivo / Ativo / Auditivo/Visual	Ativa / Abstrata / Visual/Verbal		https://eduplay.mp.br/app/video/11
✓ ✕	...	...	...	...	...	Intuitivo /	Ativa /		

Figura 5.8: Resultado de busca para o perfil Ensino Superior, interesse Reconhecimento de padrões e meta Aprender

Por fim, o sistema disponibiliza um mecanismo de avaliação da busca, ilustrado na Figura 5.9. Nessa área, o usuário pode atribuir uma nota de uma a cinco estrelas, sendo também exibidos o número total de REAs retornados e a quantidade de REAs retornados por segundo. Caso a busca seja avaliada com três ou menos estrelas, o sistema abre um conjunto de opções para que o usuário indique os motivos da insatisfação. Independentemente da nota atribuída, há ainda uma caixa de texto livre para comentários, como mostra a Figura 5.10.

Número de REA retornados na busca: 101

Eficiência: 1.28

O tempo de pesquisa foi de 79.02 segundos.

Como foi a sua experiência?

★ ★ ★ ★ ★

Toque em uma estrela para avaliar

Figura 5.9: Interface de resultados e avaliação da busca

Obrigado! Você avaliou com 2 estrelas.

O que se destacou?

☐ Os conteúdos recomendados não estão de acordo com o assunto pedido.

☐ Os conteúdos recomendados não estão de acordo com o nível educacional pedido.

☐ A busca demorou tempo demais para ser executada.

☐ A abordagem dos conteúdos não são condizentes com o questionário respondido.

☐ Vieram conteúdos repetitivos.

☐ A ordem de prioridade da amostragem dos conteúdos não é coerente.

Deixe um comentário (opcional)

Conte mais detalhes sobre sua experiência...

Enviar Avaliação

Figura 5.10: Opções de avaliação e caixa de texto para comentários

5.1.1 Tela do colaborador

Como mostrado na Figura 5.11, há a possibilidade para o usuário, inserindo todas as informações necessárias, adicionar REAs na base de dados, um parâmetro a mais para a busca realizada por usuários sem cadastro. Como nesse caso não há a meta de aprendizagem para garantir uma recomendação personalizada, há a presença de uma tabela incrementável de REAs na base de dados da aplicação, onde é feito um comparativo do tipo de dado do REA vindo dos repositórios, com os REAs adicionados nessa tabela. Caso haja correspondência de tipo de dado com algum REA dessa tabela, ele possivelmente será mais recomendável para o usuário sem cadastro.

A sua inserção melhorará a base de referência para a busca, que não retornará os REAs inseridos aqui, mas os usará como referência para a busca nos repositórios.

Nome completo

Nome completo

Função

Professor

Instituição

Instituição

Título do REA

Introdução ao Pensamento computacional

Referência

Autor

Perfil

Ensino superior

Interesse

Pensamento computacional

Item

Trilha de aprendizagem

Voltar **Inserir**

Figura 5.11: Interface para mostrar resultados e espaço para avaliar a busca

Após a apresentação das interfaces do sistema, é importante descrever o funcionamento interno do processo de recomendação e de classificação dos REAs, detalhando como os recursos são recuperados, analisados e apresentados ao usuário.

5.2 Avaliação do Sistema

Com o objetivo de avaliar a percepção dos usuários em relação ao SisREAd, foi aplicado um questionário composto por 14 afirmações sobre usabilidade, desempenho, qualidade das recomendações, personalização e intenção de uso futuro. As respostas foram registradas por meio de uma escala Likert de cinco pontos, variando entre “Discordo totalmente” e “Concordo totalmente”.

A avaliação foi realizada com 11 participantes vinculados ao Departamento de Ciência da Computação da Universidade Federal de Juiz de Fora (UFJF). A escolha desse

público se deu pela facilidade de acesso aos participantes e pela familiaridade deles com ambientes digitais e sistemas de informação. Em relação à faixa etária, observou-se predominância de jovens adultos: aproximadamente 63,6% dos participantes possuíam entre 18 e 24 anos, 27,3% entre 25 e 34 anos e 9,1% entre 35 e 44 anos. Quanto à escolaridade, 36,4% possuíam Ensino Superior Incompleto, 36,4% Ensino Superior Completo e 27,3% cursavam ou possuíam Pós-Graduação, perfil compatível com o público-alvo do sistema, que busca auxiliar estudantes e profissionais em atividades de aprendizagem e pesquisa.

Também foi analisada a forma de utilização do sistema durante a avaliação. Dos participantes, 63,6% utilizaram o SisREAd sem realizar cadastro, empregando apenas a busca por Perfil e Interesse, enquanto os demais 36,4% criaram uma conta e utilizaram também o mecanismo de personalização baseado na identificação da meta de aprendizagem pelo questionário EMAPRE-U. Essa distribuição permitiu avaliar tanto o fluxo simplificado quanto o fluxo completo de recomendação. A Figura 5.12 apresenta a distribuição das respostas obtidas para cada afirmação avaliada.

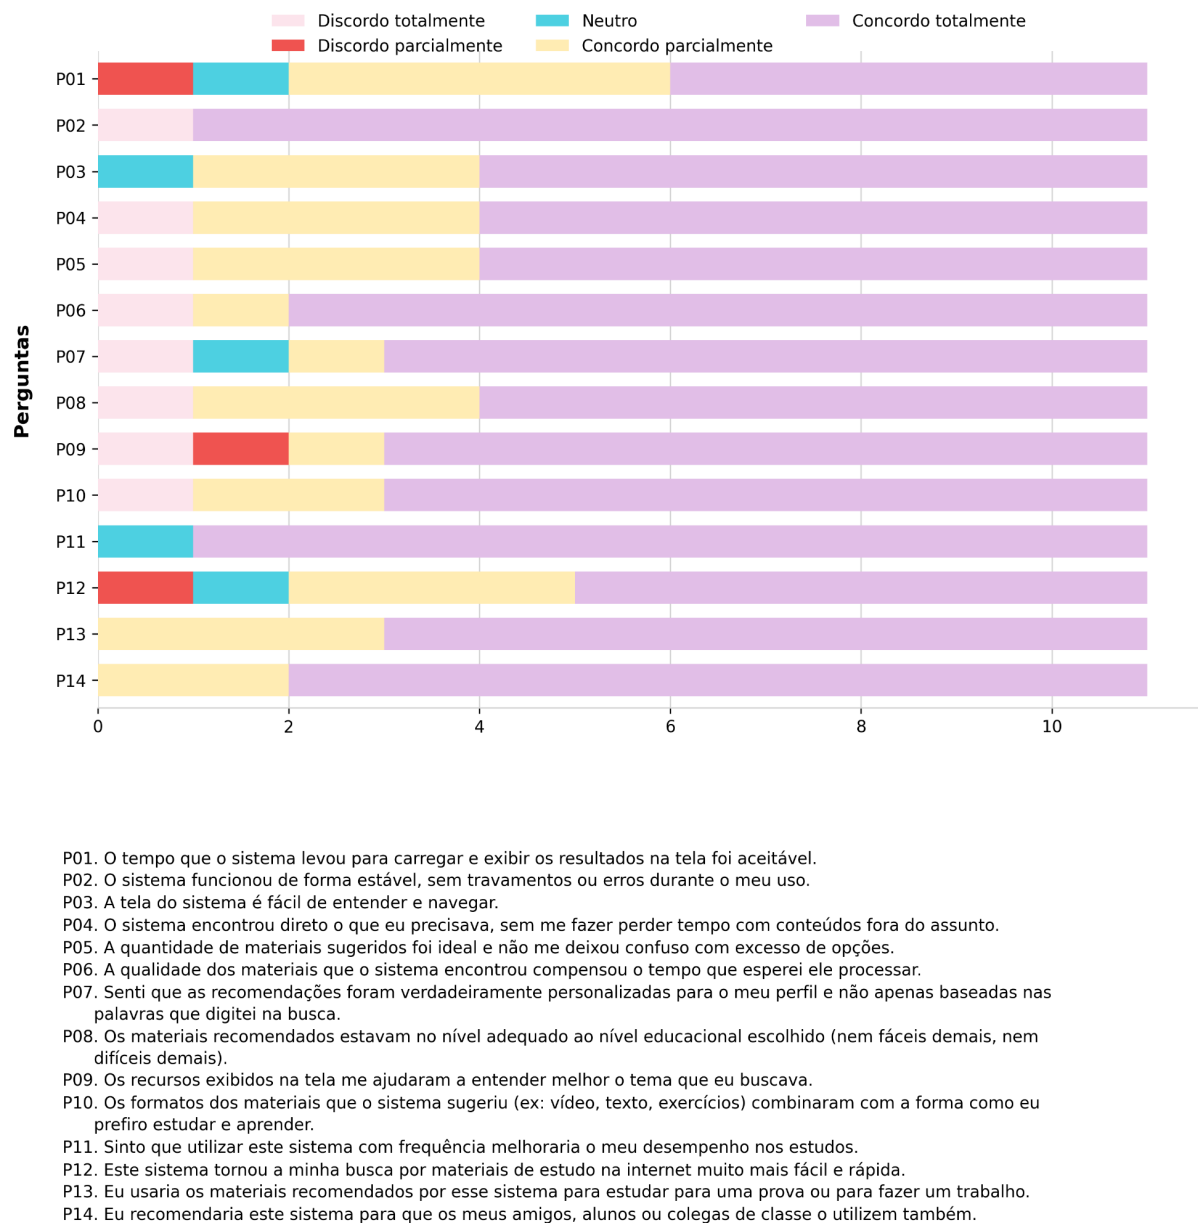


Figura 5.12: Distribuição das respostas do questionário de avaliação do SisREAd

De maneira geral, os resultados indicam uma percepção positiva dos participantes, com predominância das respostas “Concordo totalmente” e “Concordo parcialmente” em praticamente todas as questões. Quanto ao desempenho, 81,9% avaliaram positivamente o tempo de carregamento dos resultados (P01) — 45,5% concordando totalmente e 36,4% parcialmente —, e 90,9% concordaram totalmente que o sistema funcionou sem travamentos ou erros (P02). No aspecto de usabilidade, 63,6% concordaram totalmente que a interface é fácil de entender e navegar (P03) e a mesma proporção concordou total-

mente que o sistema encontrou diretamente os conteúdos procurados (P04), com 27,3% de concordância parcial em ambas.

Em relação à qualidade das recomendações, 63,6% concordaram totalmente que a quantidade de materiais sugeridos foi adequada, sem excesso de opções (P05), e 81,8% concordaram totalmente que a qualidade dos materiais compensou o tempo de processamento (P06). No que se refere à personalização, um dos principais diferenciais do sistema, 72,7% concordaram totalmente que os recursos apresentados estavam alinhados ao seu perfil, e não apenas às palavras-chave digitadas (P07). Sobre a adequação pedagógica, 63,6% concordaram totalmente que os materiais eram compatíveis com o nível educacional selecionado (P08), 72,7% afirmaram que os recursos contribuíram para melhor compreensão do tema (P09) e a mesma proporção concordou totalmente que os formatos sugeridos estavam alinhados à forma como preferem estudar (P10).

A percepção de utilidade educacional apresentou resultados expressivos: 90,9% concordaram totalmente que o uso frequente do SisREAd poderia melhorar seu desempenho nos estudos (P11), sugerindo que os usuários enxergaram valor prático na ferramenta. Quanto à capacidade de facilitar a busca por materiais (P12), 54,5% concordaram totalmente e 27,3% parcialmente. A intenção de uso futuro reforça a aceitação da proposta: 72,7% afirmaram que utilizariam os materiais recomendados para estudar ou desenvolver trabalhos (P13) e 81,8% declararam que recomendariam o sistema a amigos, colegas ou alunos (P14).

Nas respostas abertas, os participantes destacaram a praticidade na busca por materiais de estudo e a rapidez no acesso a conteúdo relevante. Entre as sugestões de melhoria, mencionaram a possibilidade de buscar materiais em inglês mediante habilitação pelo usuário e a modernização da interface, com uma estética visual mais contemporânea.

De forma geral, os resultados sugerem que o SisREAd foi bem recebido, destacando-se nos aspectos de estabilidade, personalização, adequação dos recursos e potencial de apoio à aprendizagem. É importante ressaltar, contudo, duas limitações da avaliação: a amostra reduzida, composta por 11 participantes vinculados ao contexto acadêmico da Computação, e o fato de 63,6% deles terem utilizado o sistema sem cadastro, ou seja, sem exercitar a funcionalidade de meta de aprendizagem, que constitui o principal diferencial

da proposta. Um participante que respondeu "Discordo" ou "Discordo completamente" em boa parte das perguntas observou que pode ser adicionada "uma mensagem informando que não há disponibilidade de recurso sobre o item pesquisado", pois não encontrou o que procurava.

5.3 Verificação da classificação automática por meta de aprendizagem

Esta seção avalia a capacidade do modelo de linguagem de classificar REAs de acordo com a meta de aprendizagem predominante. A avaliação foi conduzida em duas etapas: primeiro, a construção de uma classificação de referência (*padrão-ouro*) a partir do julgamento de dois avaliadores humanos, este autor e seu orientador; em seguida, a comparação dos rótulos preditos pelo modelo com essa referência, por meio de uma matriz de confusão e das métricas de *precision*, *recall* e F1.

5.3.1 Construção da classificação de referência

O corpus é composto por uma amostra de 62 REAs provenientes do repositório Aquarela, selecionado de modo a abranger diversidade de formatos e abordagens pedagógicas, incluindo trilhas de aprendizagem, planos de aula, jogos, exercícios práticos e materiais teóricos. O objetivo foi reunir um conjunto sólido para avaliar a intencionalidade pedagógica e motivacional subjacente ao *design* de cada recurso. Para que a rotulagem refletisse o que cada recurso efetivamente propõe, e não apenas seu título ou metadados, os avaliadores tiveram acesso ao conteúdo integral de cada REA, incluindo a descrição, o conteúdo textual, os materiais em PDF e os subrecursos que compõem as trilhas de aprendizagem.

Para categorizar o perfil motivacional de cada recurso, adotou-se o modelo tri-cotômico das Metas de Realização. A classificação manual baseou-se em uma análise qualitativa de três elementos fornecidos pela API da plataforma:

1. **Título e Descrição:** leitura atenta para identificar os verbos de ação e o foco do material (ex.: “explorar” e “construir” vs. “exercícios” e “noções”).

2. **Tipo de Conteúdo (tipoConteudo):** avaliação do formato pedagógico (ex.: um “Jogo” ou “Exercício” enfatiza regras e pontuação, enquanto uma “Trilha de Aprendizagem” incentiva a investigação profunda).
3. **Identificador Estrutural (dtype):** confirma a estrutura de dados do recurso.

Com base nesses elementos, cada REA foi classificado em uma das três metas: **Meta Aprender**, **Performance-Aproximação** ou **Performance-Evitação**. A classificação foi conduzida de forma independente por dois avaliadores, o autor deste trabalho e seu orientador, que atribuíram individualmente uma meta a cada um dos 62 recursos, sem acesso à decisão um do outro.

A confiabilidade da classificação de referência foi aferida pelo coeficiente Kappa de Cohen (κ), apropriado para mensurar a concordância entre dois avaliadores em escala nominal, descontando a parcela de concordância esperada ao acaso, conforme definido na Equação 5.1, em que P_o é a proporção de concordância observada e P_e é a proporção de concordância esperada ao acaso, estimada a partir das distribuições marginais dos dois avaliadores.

$$\kappa = \frac{P_o - P_e}{1 - P_e} \quad (5.1)$$

Dos 62 recursos, houve concordância plena em 54, resultando em $P_o = 0,871$. A concordância esperada ao acaso foi $P_e = 0,338$, e o coeficiente κ pode ser obtido conforme especificado na Equação 5.2.

$$\kappa = \frac{0,871 - 0,338}{1 - 0,338} = 0,805 \quad (5.2)$$

O valor obtido ($\kappa = 0,805$; erro-padrão aproximado de 0,064; intervalo de confiança de 95% aproximado de [0,68; 0,93]) indica concordância forte entre os avaliadores. Pela classificação qualitativa de Landis e Koch (1977), o resultado situa-se na fronteira entre a concordância “substancial” (0,61–0,80) e a “quase perfeita” (0,81–1,00). A Tabela 5.1 apresenta a matriz de confusão das duas diferentes classificações da amostra de REA.

A diagonal principal concentra os 54 casos de concordância. As 8 divergências distribuem-se de forma adjacente: em 4 recursos, o Avaliador 1 atribuiu *Performance-*

Tabela 5.1: Matriz de contingência utilizada no cálculo do coeficiente Kappa de Cohen

Avaliador 1 \ Avaliador 2	Meta Aprender	Performance- Aproximação	Performance- Evitação	Total
Meta Aprender	22	0	0	22
Performance-Aproximação	4	17	0	21
Performance-Evitação	0	4	15	19
Total	26	21	15	62

Aproximação, enquanto o Avaliador 2 atribuiu *Meta Aprender*, e, em outros 4, o Avaliador 1 atribuiu *Performance-Evitação*, enquanto o Avaliador 2 atribuiu *Performance-Aproximação*. Não houve divergência entre as categorias extremas (*Meta Aprender* e *Performance-Evitação*): os avaliadores nunca discordaram de forma radical, restringindo-se a discordâncias na fronteira entre orientações motivacionais vizinhas.

A natureza dessas divergências é, ela própria, informativa: a maior dificuldade de delimitação está na fronteira da *Performance-Aproximação* com as categorias vizinhas, isto é, entre “construir um produto com êxito demonstrável”, “investigar e descobrir de forma autônoma” e “assimilar conteúdo introdutório com baixo risco”. Essa zona de ambiguidade conceitual deve ser considerada na interpretação dos erros do classificador automático, uma vez que é razoável esperar que o modelo também encontre maior dificuldade justamente nas fronteiras em que dois anotadores humanos divergem. As 8 divergências foram reconciliadas por consenso entre os avaliadores, resultando na classificação de referência final, utilizada na etapa seguinte para mensurar o desempenho do modelo.

5.3.2 Desempenho do modelo automático

A avaliação quantitativa do classificador foi realizada por meio de uma matriz de confusão, que permite identificar não apenas o número de classificações corretas, mas também os padrões de erro do modelo ao distinguir as metas de aprendizagem. A Figura 5.13 apresenta a matriz de confusão obtida a partir da comparação entre a classificação de referência consolidada e os rótulos produzidos pelo modelo *Llama 3.1*.

A maior parte das classificações concentra-se na diagonal principal, indicando elevada concordância entre a referência humana e a classificação automática. Dos 62 REAs analisados, 53 foram classificados corretamente, resultando em acurácia de aproximada-




Figura 5.13: Matriz de confusão da classificação de metas de aprendizagem produzida pelo modelo *Llama 3.1*, comparada à classificação de referência (padrão-ouro).

mente 85,48%. O desempenho por categoria foi o seguinte:

- **Meta Aprender:** melhor desempenho individual, com *precision* de 96%, *recall* de 88% e F1 de 92%. Dos 26 recursos da referência nessa categoria, 23 foram corretamente identificados.
- **Performance-Aproximação:** *precision* de 73%, *recall* de 90% e F1 de 81%. O *recall* elevado indica que o modelo recuperou a maior parte dos recursos da categoria, embora tenha rotulado incorretamente alguns recursos de outras categorias como Performance-Aproximação.
- **Performance-Evituação:** *precision* de 92%, *recall* de 73% e F1 de 81%. Quando o modelo atribuiu essa categoria, geralmente acertou; entretanto, deixou de reconhecer parte dos recursos que, de fato, pertenciam a ela.

Considerando o desempenho agregado entre as classes, o modelo obteve precisão média (*macro precision*) de 0,87, revocação média (*macro recall*) de 0,84 e *F1-score macro* de 0,85. Essas métricas são particularmente relevantes em problemas multiclasse, pois avaliam o classificador de forma equilibrada entre todas as categorias, reduzindo o impacto de eventuais diferenças na distribuição das classes; nesse sentido, o *F1-score macro* oferece

uma visão mais abrangente da capacidade de generalização do modelo do que a acurácia isolada.

A análise dos erros revela que a principal fonte de divergência ocorreu entre *Performance-Evituação* e *Performance-Aproximação*: dos 15 recursos classificados como *Performance-Evituação* na referência, 4 foram preditos como *Performance-Aproximação* pelo modelo. Além disso, 3 recursos da categoria Meta Aprender também foram atribuídos a *Performance-Aproximação*. Esses resultados sugerem uma tendência do modelo a associar atividades práticas, exercícios e propostas de aplicação do conhecimento à meta de desempenho por aproximação, comportamento que, vale notar, recai sobre a mesma fronteira conceitual em que os dois avaliadores humanos haviam divergido.

Em síntese, a combinação de acurácia de 85,48% com *F1-score macro* de 0,85 indica que o modelo reproduz, com boa confiabilidade, as classificações realizadas por avaliadores humanos. Esse resultado sustenta o uso de Modelos de Linguagem de Grande Porte (LLMs) como alternativa viável para apoiar a classificação automática de REAs, com potencial de reduzir o esforço manual de catalogação e favorecer a escalabilidade do processo em repositórios de recursos educacionais.

Esses resultados respondem à QS2, pois observa-se que um modelo de linguagem de grande porte, executado localmente, mostrou-se capaz de classificar REA segundo metas de realização, com concordância próxima à humana. O desempenho obtido (acurácia de 85,48%) é comparável ao relatado por Villalba-Condori et al. (2022), que alcançaram cerca de 85% de acurácia ao classificar recursos segundo a taxonomia SOLO com um classificador MLP. A proposta do SisREAd distingue-se, contudo, por classificar segundo metas de realização, de natureza motivacional, e por empregar um modelo de linguagem de execução local, em vez de um classificador treinado especificamente para a tarefa.

5.4 Desempenho e escalabilidade da arquitetura

Nesta seção, são apresentados e discutidos os dados extraídos das métricas de utilização do sistema de recomendação. Para validar empiricamente a robustez e a escalabilidade da arquitetura proposta, foi desenhado um cenário experimental de estresse combinatório baseado nas diretrizes pedagógicas do sistema. Por meio de um comando automatizado

via console (*Artisan CLI*), o sistema simulou de forma sequencial a requisição de 26 pares únicos de perfis de usuários (da Educação Infantil ao Ensino Superior) cruzados com seus respectivos temas de interesse do Pensamento Computacional. Cada par foi submetido a quatro variações de metas de realização (ausente, aprender, performance-aproximação e performance-evitação), totalizando 104 cenários de teste controlados.

Considerando que cada cenário aciona os três repositórios integrados (Aquarela, MEC RED e Eduplay) por meio de rotinas assíncronas em segundo plano, a base avaliada compreende o monitoramento detalhado de 312 execuções completas de busca, classificação semântica e filtragem. A análise está dividida em três eixos: a eficiência na filtragem dos REAs, o custo computacional atrelado a essa filtragem e a confiabilidade da arquitetura de Inteligência Artificial operando de forma local.

5.4.1 Eficiência do motor de busca e redução de ruído

A principal premissa de um sistema de recomendação educacional é mitigar a sobrecarga cognitiva do docente, entregando apenas materiais estritamente alinhados ao seu planejamento. A Figura 5.14 confronta o volume bruto de REAs devolvidos pelas APIs dos repositórios com o volume líquido filtrado e efetivamente recomendado pelo sistema.




Figura 5.14: Média de itens retornados vs. recomendados por repositório

O comportamento dos dados revela que o Aquarela possui a API mais verbosa,

retornando o maior volume bruto por requisição; ainda assim, o sistema descarta a maior parte desses itens, aprovando apenas a fração que atende aos critérios de perfil, interesse e meta pedagógica. No Eduplay, observa-se filtragem semelhante: por ser composto exclusivamente por vídeos, nem todas as metas de aprendizagem se adequam aos seus conteúdos. No MEC RED, o volume de retorno é menor e praticamente não há descarte posterior, pois os filtros por tipo de conteúdo, que são definidos a partir das associações entre formatos e metas de aprendizagem encontradas na literatura, são enviados já na própria requisição. Em conjunto, esses resultados evidenciam a eficiência do sistema como filtro semântico: ao reduzir drasticamente o ruído, a ferramenta poupa o tempo que o educador gastaria analisando dezenas de resultados irrelevantes.

5.4.2 Custo computacional e latência

A introdução de um LLM para analisar metadados impõe, naturalmente, um custo computacional maior do que o de uma busca tradicional por palavras-chave. A Figura 5.15 decompõe o tempo de resposta do sistema entre a latência de rede (comunicação com as APIs externas) e o tempo de processamento local do LLM (*Llama 3.1*, utilizado através do Ollama).




Figura 5.15: Composição do tempo de resposta (em segundos)

Observa-se que o tempo de resposta da API (na base das barras) é relativamente

baixo e estável nos três repositórios, raramente ultrapassando poucos segundos. O verdadeiro gargalo está no processamento semântico, em correlação direta com a seção anterior: como o Aquarela retorna o maior volume de itens brutos para análise, o tempo exigido para que a IA processe e classifique esses REAs dispara, tornando-se a fatia dominante da espera. Embora esse comportamento exija do usuário um tempo superior ao padrão *web* convencional, ele se justifica pelo ganho qualitativo da classificação pedagógica, inviável de obter por meio de uma busca determinística simples.

5.4.3 Confiabilidade da inferência local

Para viabilizar a escalabilidade da ferramenta sem incorrer em custos com APIs comerciais de IA, o sistema foi projetado para executar as inferências localmente. Contudo, o processamento intensivo de Processamento de Linguagem Natural (PLN) em *hardware* restrito pode gerar instabilidades. A Figura 5.16 mapeia o panorama global de estabilidade técnica durante a classificação dos REAs pelo LLM.




Figura 5.16: Taxa global de estabilidade na classificação por IA

O gráfico considera os 3.288 REAs processados pelo *Llama 3.1* ao longo das 104 execuções que acionaram a API do Aquarela, as únicas, dentre as 312 totais, que recorrem ao LLM. Diante desse volume, a ocorrência de erros de processamento ou perda de contexto (*timeouts* do Ollama ao executar o LLM) representa uma fração irrisória. Cabe esclarecer que esta métrica afere a *estabilidade da execução*, isto é, a finalização

bem-sucedida da inferência, e não a correção do rótulo retornado — aspecto já avaliado na Seção 5.3.2. Ainda assim, a baixa taxa de falhas atesta a viabilidade técnica de operar a classificação por LLM de forma local.

O conjunto de evidências formado pela redução de ruído na filtragem, pelo custo de latência caracterizado e pela estabilidade da inferência local responde à QS1: é viável integrar, em um único sistema, dois repositórios de REA e uma plataforma de vídeos com classificação por meta de aprendizagem, mantendo estabilidade e um custo computacional aceitável, ainda que superior ao de uma busca convencional. Esse resultado dialoga com a recomendação de Urdaneta-Ponte, Mendez-Zorrilla e Oleagordia-Ruiz (2021), que apontam a avaliação rigorosa do desempenho computacional como lacuna recorrente em recomendadores educacionais.

6 Considerações Finais e Trabalhos Futuros

Este trabalho apresentou o desenvolvimento do SisREAd, um Sistema de Recomendação para Recursos Educacionais Abertos. A proposta surgiu da dificuldade que estudantes e docentes enfrentam para localizar materiais adequados diante da grande quantidade de recursos dispersos em diferentes repositórios, frequentemente acessíveis apenas por buscas baseadas em palavras-chave, que desconsideram o perfil e os objetivos de aprendizagem do usuário.

Para responder a essa lacuna, foi desenvolvida uma solução capaz de integrar, em um único ambiente, informações sobre o perfil educacional, os interesses temáticos e as metas de aprendizagem. O sistema realiza buscas simultâneas em três fontes heterogêneas (Aquarela, MEC RED e Eduplay), padroniza os resultados e aplica mecanismos de classificação e ordenação para personalizar as recomendações. Cada um dos objetivos específicos propostos foi contemplado: a coleta de perfil, interesse e metas motivacionais por meio do questionário EMAPRE-U; a busca automatizada em múltiplos repositórios; a classificação dos recursos segundo critérios pedagógicos e motivacionais; a integração de um modelo de linguagem executado localmente; e a avaliação empírica do sistema quanto ao desempenho e à percepção de relevância.

Dois aspectos distinguem a proposta. O primeiro é o uso da escala EMAPRE-U, instrumento validado, para incorporar aspectos motivacionais ao processo de recomendação, indo além do casamento por palavras-chave. O segundo é a classificação automática dos recursos do repositório Aquarela por meio de um Modelo de Linguagem de Grande Porte (LLM) executado localmente via Ollama, o que viabiliza a categorização pedagógica sem custos com APIs comerciais.

Os resultados sustentam empiricamente a viabilidade da abordagem e permitem responder às questões de pesquisa formuladas. Quanto à QS2, a referência humana construída por dois avaliadores independentes apresentou concordância forte ($\kappa = 0,805$ de Cohen), e o modelo *Llama 3.1* reproduziu essa referência com acurácia de 85,48% e *F1-score macro* de 0,85. Quanto à QS1, o teste de estresse com 312 execuções demonstrou

integração estável dos repositórios, com filtragem eficaz do volume bruto e baixa taxa de falhas na inferência local, a um custo de latência caracterizado e justificado pelo ganho de classificação pedagógica. A inferência local mostrou-se tecnicamente estável, com índice irrisório de falhas mesmo sob processamento intensivo. Na avaliação com usuários, a percepção foi predominantemente positiva, com destaque para a estabilidade da aplicação, a adequação dos recursos e o potencial de apoio aos estudos. Em conjunto, essas evidências respondem afirmativamente à questão principal: é possível conceber um sistema que integre perfil, interesses e metas de aprendizagem, combinando múltiplos repositórios e uma classificação realizada por um LLM local, com viabilidade técnica.

Apesar desses resultados, o trabalho apresenta limitações que devem ser explicitadas. A qualidade das recomendações depende diretamente da qualidade e da padronização dos metadados disponibilizados pelos repositórios, sobre os quais o sistema não tem controle. A classificação por LLM, embora satisfatória no conjunto, concentra seus erros na fronteira entre as metas de Performance-Aproximação e Performance-Evituação, justamente a região em que os próprios avaliadores humanos divergiram. Atualmente, aplica-se apenas aos recursos do Aquarela, enquanto o MEC RED e o Eduplay utilizam regras heurísticas baseadas no tipo de conteúdo. Há, ainda, um custo de latência relevante, pois o processamento semântico local eleva o tempo de resposta acima do padrão de uma busca convencional, o que constitui um compromisso explícito entre qualidade da classificação e tempo de espera. Por fim, a avaliação de percepção foi conduzida com uma amostra reduzida (11 participantes do contexto acadêmico da Computação), e a maioria utilizou o sistema sem cadastro, sem exercitar a personalização por meta de aprendizagem, o que limita o alcance das conclusões justamente sobre o principal diferencial da proposta. Além disso, apesar do repositório Aquarela ser voltado à educação básica, não foi feito um teste de percepção com professores desse âmbito.

A partir dessas limitações, delineiam-se as direções de trabalho futuro. Pretende-se ampliar o número de repositórios integrados e estender a classificação por meta de aprendizagem também às fontes atualmente tratadas por heurísticas, conferindo uniformidade ao processo. No tocante ao modelo, é importante investigar o uso de LLMs menores, quantizados ou ajustados (*fine-tuned*) para o domínio educacional, com o obje-

tivo de preservar a qualidade obtida com o *Llama 3.1* reduzindo a latência da inferência local. Quanto à avaliação, planeja-se conduzir estudos com amostras maiores e mais diversas, incluindo professores e estudantes dos níveis educacionais atendidos, e incorporar métricas objetivas de relevância (como precisão e revocação das recomendações) que complementem a percepção subjetiva dos usuários.

Como trabalhos futuros, propõe-se a adição de novos repositórios e fontes de recursos integrados ao sistema, inclusive o YouTube⁶, uma grande fonte de conteúdos educacionais e muito difundido nos tempos atuais para este meio, de modo a aumentar a diversidade de materiais disponíveis para recomendação. Também se pretende aprimorar a interface do usuário, incorporando princípios de UX (*User Experience*) e UI (*User Interface*), com foco principalmente na responsividade. Além disso, pretende-se conceder ao usuário a possibilidade de responder o questionário EMAPRE-U novamente e substituir sua meta de aprendizagem cadastrada inicialmente.

Por fim, espera-se que o SisREAd contribua para a área de Sistemas de Recomendação Educacionais, demonstrando que a combinação de instrumentos motivacionais validados com modelos de linguagem de execução local é um caminho viável e de baixo custo, conforme demonstrado no código do projeto⁷ para favorecer o acesso a Recursos Educacionais Abertos mais alinhados às características e necessidades individuais dos estudantes.

6.1 Declaração de uso de IA

Durante a elaboração deste trabalho, foram utilizadas ferramentas de Inteligência Artificial (IA) como ChatGPT⁸ e Google Gemini⁹ unicamente como suporte para a revisão e o aprimoramento da escrita, como correções gramaticais, recomendações para maior clareza, estruturação do texto e adequação à linguagem acadêmica.

É importante destacar que o autor deste trabalho foi responsável por todas as etapas da pesquisa, desde a concepção da proposta até a análise dos resultados, sem

⁶<https://www.youtube.com/>

⁷<https://github.com/GabrielCarmoSilva/sistema-de-recomendacao-reas>

⁸<https://chatgpt.com/>

⁹<https://gemini.google.com/?hl=pt-BR>

utilizar ferramentas de IA para gerar tais contribuições científicas.

O emprego de ferramentas de IA limitou-se ao auxílio linguístico e gramatical da monografia, mantendo a autoria intelectual, a responsabilidade científica e a integridade acadêmica do estudo.

Bibliografia

- BALBINO, F. C.; BARBOSA, E. F. Práticas educacionais abertas mediadas por tecnologia na formação inicial docente: em direção à disseminação e efetivação da cultura aberta na educação básica. *Revista Brasileira de Informática na Educação*, v. 33, p. 472–507, 2025.
- BALBINO, F. C.; DEUS, W. S. d.; BARBOSA, E. F. A dynamic open educational resources repository to enhance primary and secondary education. In: *2023 IEEE International Conference on Advanced Learning Technologies (ICALT)*. [S.l.]: IEEE, 2023. p. 4–8.
- BOBADILLA, J. et al. Recommender systems survey. *Knowledge-Based Systems*, Elsevier, v. 46, p. 109–132, 2013.
- BURKE, R. Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, Springer, v. 12, p. 331–370, 2002.
- CAPUANO, N. et al. A recommender system for learning goals. In: *World Summit on Knowledge Society*. [S.l.]: Springer, 2011. p. 515–521.
- CARVALHO, H. C. F. B. et al. Classificação automática de vídeos educacionais por meio de comentários apoiada por técnicas de aprendizado de máquina: uma análise experimental utilizando o youtube. *Revista Brasileira de Informática na Educação*, v. 30, p. 1–24, 2022.
- CLEMENTS, K.; PAWLOWSKI, J.; MANOUSELIS, N. Open educational resources repositories literature review – towards a comprehensive quality approaches framework. *Computers in Human Behavior*, Elsevier, v. 51, p. 1098–1106, 2015.
- DAHDOUH, K. et al. Large-scale e-learning recommender system based on spark and hadoop. *Journal of Big Data*, v. 6, n. 1, p. 1–23, 2019.
- ELLIOT, A. J.; MCGREGOR, H. A. A 2× 2 achievement goal framework. *Journal of personality and social psychology*, American Psychological Association, v. 80, n. 3, p. 501, 2001.
- HADI, M. U. et al. Large language models: a comprehensive survey of its applications, challenges, limitations, and future prospects. *Authorea preprints*, v. 1, n. 3, p. 1–26, 2023.
- HAJRI, H.; BOURDA, Y.; POPINEAU, F. Personalized recommendation of open educational resources in moocs. In: *Computer Supported Education (CSEDU 2018)*. [S.l.]: Springer, Cham, 2019. (Communications in Computer and Information Science, v. 1022), p. 166–190.
- JÚNIOR, C. X. P.; ARAÚJO, R. D.; DORÇA, F. A. Uma abordagem para recomendação personalizada de materiais educacionais por meio de filtragem baseada em conteúdo em ambientes virtuais de aprendizagem. *Revista Brasileira de Informática na Educação*, v. 31, p. 731–758, 2023.

- KASNECI, E. et al. Chatgpt for good? on opportunities and challenges of large language models for education. *Learning and individual differences*, Elsevier, v. 103, p. 102274, 2023.
- LANDIS, J. R.; KOCH, G. G. The measurement of observer agreement for categorical data. *biometrics*, JSTOR, p. 159–174, 1977.
- MEC. *Plataforma MEC de Recursos Educacionais Digitais*. 2024. Disponível em: <<https://plataformaintegrada.mec.gov.br/sobre>>. Acesso em: 31 ago. 2024.
- MEDEIROS, R. et al. Uma análise comparativa entre repositórios de recursos educacionais abertos para a educação básica. In: *Anais do XXXII Simpósio Brasileiro de Informática na Educação (SBIE)*. [S.l.]: SBC, 2021. p. 213–224.
- OECD. *Giving Knowledge for Free*. 2007. <<https://www.oecd-ilibrary.org/content/publication/9789264032125-en>>. 149 p.
- OLIVEIRA, A. A. d. et al. Sistema de recomendação de cursos extracurriculares para estudantes. 126, 2025.
- ORTIZ, J. O. d. S. et al. Recursos educacionais abertos: Uma análise dos objetivos de aprendizagem referenciados pela taxonomia digital de bloom. In: *Anais do XXXI Simpósio Brasileiro de Informática na Educação (SBIE)*. [S.l.]: SBC, 2020.
- PEREIRA, J. S. et al. Escala de motivação para aprendizagem em universitários: versão breve. *Estudos e Pesquisas em Psicologia*, Universidade do Estado do Rio de Janeiro, v. 22, n. 2, p. 773–793, 2022.
- RICCI, F.; ROKACH, L.; SHAPIRA, B. Recommender systems: introduction and challenges. In: *Recommender Systems Handbook*. [S.l.]: Springer, 2015. p. 1–34.
- RIMA, S. et al. Systematic literature review on open educational resources recommender systems. *International Journal of Interactive Mobile Technologies*, v. 16, n. 18, 2022.
- ROY, D.; DUTTA, M. A systematic review and research perspective on recommender systems. *Journal of Big Data*, Springer, v. 9, n. 1, p. 59, 2022.
- SANDOUSI, R. et al. Systematic literature review on open educational resources recommender systems. *International Journal of Interactive Mobile Technologies (iJIM)*, v. 16, n. 18, p. 44–77, 2022.
- SANTOS, A. A. A.; ALCARÁ, A. R.; ZENORINI, R. P. C. Estudos psicométricos da escala de motivação para a aprendizagem de universitários (emapre). *Fractal*, v. 25, n. 3, p. 531–546, 2013.
- SANTOS, A. I. d. Educação aberta: histórico, práticas e o contexto dos recursos educacionais abertos. In: SANTANA, B.; ROSSINI, C.; PRETTO, N. D. L. (Ed.). *Recursos Educacionais Abertos: práticas colaborativas e políticas públicas*. Salvador; São Paulo: EDUFBA; Casa da Cultura Digital, 2012. p. 71–89.
- SHAPIRA, B.; ROKACH, L.; RICCI, F. Recommender systems handbook. Springer, 2022.

- SILVA, F. L. da et al. A systematic literature review on educational recommender systems for teaching and learning: research trends, limitations and opportunities. *Education and Information Technologies*, v. 28, n. 3, p. 3289–3328, 2023.
- SOHAIL, S. S.; SIDDIQUI, J.; ALI, R. Classifications of recommender systems: A review. *Journal of Engineering Science & Technology Review*, v. 10, n. 4, 2017.
- SOUSA, F. A. de; COELHO, M. N. O perfil motivacional de professores e a qualidade motivacional dos alunos do ensino médio na disciplina de física. *Revista Brasileira de Ensino de Ciências e Matemática*, v. 6, n. 1, 2023.
- TARUS, J. K.; NIU, Z.; YOUSIF, A. A hybrid knowledge-based recommender system for e-learning based on ontology and sequential pattern mining. *Future Generation Computer Systems*, v. 72, p. 37–48, 2017.
- UNESCO. *Open Educational Resources*. 2023. <<https://www.unesco.org/en/open-educational-resources?hub=78>>. Acesso em: 10 jan. 2023.
- URDANETA-PONTE, M. C.; MENDEZ-ZORRILLA, A.; OLEAGORDIA-RUIZ, I. Recommendation systems for education: Systematic review. *Electronics*, MDPI, v. 10, n. 14, p. 1611, 2021.
- VILLALBA-CONDORI, K. O. et al. Multi-label search model for open educational resources based on learning purpose. In: *Human-Computer Interaction (HCI-COLLAB 2022)*. [S.l.]: Springer, Cham, 2022. (Communications in Computer and Information Science, v. 1707), p. 126–137.
- VILLALBA, K. et al. A recommender system of open educational resources based on the purpose of learning. In: *2017 Twelfth Latin American Conference on Learning Technologies (LACLO)*. [S.l.]: IEEE, 2017. p. 1–4.

A Tabela Completa de Classificações

Tabela A.1: Comparação entre a Classificação Manual e a gerada pelo LLM

REA	Manual (Humano)	LLM (IA Local)	Status
Primeiras noções sobre App Inventor	Performance-Evitação	Performance-Evitação	✓ Concordou
Gameificação - Geometria Espacial...	Performance-Aproximação	Performance-Aproximação	✓ Concordou
Gameificação - Relação de Euler p...	Performance-Aproximação	Performance-Aproximação	✓ Concordou
Astrofísica – Explorando as Exop...	Aprender	Aprender	✓ Concordou
Trilha de Aprender: Programa...	Aprender	Aprender	✓ Concordou
Plano de Aula: Introdução ao Scr...	Performance-Evitação	Performance-Evitação	✓ Concordou
Computação na Ed. Infantil - Pro...	Aprender	Aprender	✓ Concordou
Programação e Pensamento Computa...	Performance-Aproximação	Performance-Aproximação	✓ Concordou
Trilha de Aprender algoritmo...	Aprender	Aprender	✓ Concordou
Plano de aula: Algoritmo - Decom...	Aprender	Aprender	✓ Concordou
Algoritmo - Decomposição	Aprender	Aprender	✓ Concordou
Aplicação de boas práticas de En...	Aprender	Aprender	✓ Concordou
Portas Lógicas com Microbit	Aprender	Aprender	✓ Concordou
Continua na próxima página...			

Tabela A.1 – continuação da página anterior

REA	Manual (Humano)	LLM (IA Local)	Status
PLANO DE AULA: EXPLORANDO PORTAS...	Aprender	Aprender	✓ Concordou
PORTAS LÓGICAS E O MICRO:BIT	Aprender	Performance- Aproximação	× Divergiu
Aula de Requisitos e Casos de Uso	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Plano de Aula para Aplicação da ...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Prática de Programação e Decompo...	Aprender	Aprender	✓ Concordou
Plano de Aula: Prática de Progra...	Aprender	Aprender	✓ Concordou
Prática de Programação e Decompo...	Aprender	Performance- Aproximação	× Divergiu
Programação e Pensamento Computa...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Pensamento computacional na Educ...	Aprender	Aprender	✓ Concordou
e-Book: Pensamento computacional...	Performance- Evitação	Performance- Evitação	✓ Concordou
Plano de aula: Pensamento comput...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Pensamento computacional na Educ...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Trilha de Aprender - Projeto...	Aprender	Aprender	✓ Concordou
Pensamento Computacional - Pilares	Aprender	Aprender	✓ Concordou
Continua na próxima página...			

Tabela A.1 – continuação da página anterior

REA	Manual (Humano)	LLM (IA Local)	Status
Pensamento Computacional - Decom...	Aprender	Performance- Aproximação	× Divergiu
Pensamento Computacional com Mic...	Aprender	Aprender	✓ Concordou
Sobrevivência Humana: Ciência pa...	Aprender	Aprender	✓ Concordou
Diagramas e Esquemas Elétricos	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Re-significação da experiência e...	Aprender	Aprender	✓ Concordou
Plano de aula de lógica e lingua...	Performance- Evitação	Performance- Evitação	✓ Concordou
Lógica de programação	Aprender	Aprender	✓ Concordou
Conceitos de programação	Performance- Evitação	Performance- Evitação	✓ Concordou
Noções de lógica de programação	Performance- Evitação	Performance- Evitação	✓ Concordou
A Ciência da Organização: Entend...	Aprender	Aprender	✓ Concordou
Plano de Aula - A Ciência da Org...	Performance- Evitação	Performance- Evitação	✓ Concordou
A Ciência da Organização: Entend...	Performance- Evitação	Performance- Aproximação	× Divergiu
Funções Afins — Interpretação (R...	Performance- Aproximação	Aprender	× Divergiu
Funções Afins — Interpretação (R...	Performance- Evitação	Performance- Evitação	✓ Concordou
Continua na próxima página...			

Tabela A.1 – continuação da página anterior

REA	Manual (Humano)	LLM (IA Local)	Status
Funções Afins — Interpretação (R...	Performance- Evitação	Performance- Evitação	✓ Concordou
O Resgate do Animal: Aprendendo ...	Aprender	Aprender	✓ Concordou
Plano de Aula - Robô da Rotina	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Plano de aula: Criptografia e Ma...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Trilha de Aprender: Luz, Som...	Aprender	Aprender	✓ Concordou
Energia em Ação: Construindo uma...	Aprender	Aprender	✓ Concordou
Matemática do Dinheiro: Juros e ...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Logica computacional: Algoritmos...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Material teórico: Logica computa...	Performance- Evitação	Performance- Aproximação	× Divergiu
Plano de Aula: Magnetismo e imãs	Performance- Evitação	Performance- Aproximação	× Divergiu
Magnetismo e imãs	Performance- Evitação	Performance- Aproximação	× Divergiu
Plano de aula: Logica computacio...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Divisores, primos e aplicações	Aprender	Aprender	✓ Concordou
Exercícios envolvendo critérios ...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Continua na próxima página...			

Tabela A.1 – continuação da página anterior

REA	Manual (Humano)	LLM (IA Local)	Status
Automatizando com Planilhas: Apl...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Plano de Aula – Aplicação de Alg...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
Descobrimo o Mundo dos Algoritmos	Aprender	Aprender	✓ Concordou
Plano de Aula – O que é um Algor...	Performance- Evitação	Performance- Evitação	✓ Concordou
Aplicação de Algoritmos em Plani...	Performance- Aproximação	Performance- Aproximação	✓ Concordou
O que é um Algoritmo?	Performance- Evitação	Performance- Evitação	✓ Concordou
Funções Afins — Interpretação	Performance- Aproximação	Performance- Evitação	× Divergiu