

CINELEARN: SISTEMA DE RECOMENDAÇÃO AUDIOVISUAL PARA CRIANÇAS E ADOLESCENTES COM ENFOQUE EDUCACIONAL

Rafaela Margutte Cândido¹, Leandro de Bona Dias², André Faria Ruaro³

Resumo: O uso de recursos audiovisuais no contexto educacional tem se destacado por promover aprendizagem significativa, engajamento e desenvolvimento crítico entre crianças e adolescentes. No entanto, a escolha adequada de filmes e séries ainda representa um desafio para professores e responsáveis, especialmente diante do grande volume de conteúdos disponíveis. Diante disso, este trabalho teve como objetivo desenvolver o CineLearn, um sistema web de recomendação voltado ao apoio pedagógico na seleção de produções audiovisuais apropriadas por faixa etária e temática educacional. A solução foi implementada com React.js no front-end, Node.js com Express.js no back-end e MongoDB como banco de dados, utilizando Mongoose para integração das camadas. O sistema adota filtragem baseada em conteúdo estruturada com teoria dos grafos, relacionando palavras-chave educativas a respostas de um quiz aplicado aos usuários. Além das recomendações personalizadas, foram incorporados mecanismos de cadastro, login, favoritos, histórico de quizzes e filtragem por classificação indicativa. Os testes demonstraram um bom resultado na correspondência temática das recomendações, adequação etária e boa aceitação dos usuários quanto à usabilidade e clareza da interface. Conclui-se que o CineLearn contribui como ferramenta de apoio ao uso pedagógico do audiovisual, favorecendo escolhas conscientes e integrando tecnologia ao processo educacional.

Palavras-chave: sistema de recomendação; educação; cinema; grafos.

¹Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), rafa.margutte@gmail.com

²Coorientador. Curso de Letras, Universidade do Extremo Sul Catarinense (Unesc), debonaletas@unesc.net

³Orientador. Curso de Ciência da Computação, Universidade do Extremo Sul Catarinense (Unesc), andre.ruaro@unesc.net

ABSTRACT: The use of audiovisual resources in the educational context has stood out for promoting meaningful learning, engagement, and critical development among children and adolescents. However, choosing appropriate films and series still poses a challenge for teachers and guardians, especially given the large volume of content available. Given this, this work aimed to develop CineLearn, a web-based recommendation system designed to provide pedagogical support in selecting audiovisual productions appropriate for different age groups and educational themes. The solution was implemented with React.js on the front end, Node.js with Express.js on the back end, and MongoDB as the database, using Mongoose for layer integration. The system adopts content-based filtering structured with graph theory, relating educational keywords to the answers of a quiz applied to users. In addition to personalized recommendations, mechanisms for registration, login, favorites, quiz history, and filtering by rating were incorporated. The tests showed good results in terms of the thematic relevance of the recommendations, age appropriateness, and user acceptance of the usability and clarity of the interface. It is concluded that CineLearn contributes as a tool to support the pedagogical use of audiovisual media, promoting conscious choices and integrating technology into the educational process.

Keywords: recommendation system; education; cinema; graphs.

1 INTRODUÇÃO

O cinema, ao longo das últimas décadas, consolidou-se como uma ferramenta pedagógica de grande potencial no processo de ensino e aprendizagem. Filmes e séries, além de seu caráter artístico e de entretenimento, permitem explorar temáticas sociais, históricas, culturais e científicas, favorecendo a reflexão crítica e a formação integral dos estudantes (Holleben; Portela; Fogaça, 2007).

A cinematografia, por sua linguagem envolvente, atinge com maior facilidade o imaginário coletivo e se estabelece como um recurso valioso no processo de ensino-aprendizagem. Ainda que não represente integralmente a realidade, sua narrativa que combina elementos de ficção e aspectos da vida real, permite ao espectador construir sentidos a partir de experiências audiovisuais. Dessa forma, o cinema amplia as estratégias educativas possíveis tanto no espaço escolar quanto em contextos formativos mais amplos (Pires; Silva, 2014). Entretanto, diante da grande quantidade de produções disponíveis em plataformas digitais, selecionar conteú-

dos apropriados e alinhados a objetivos pedagógicos torna-se um desafio tanto para docentes quanto para responsáveis.

Nesse cenário, a necessidade de sistemas capazes de filtrar informações e indicar conteúdos adequados torna-se evidente. Sistemas de Recomendação são conjuntos de métodos computacionais que fazem uso de técnicas de aprendizagem de máquinas e recuperação de dados para sugerir conteúdos com base em análises e filtrações específicas dos itens disponíveis (Jannach et al., 2010). Assim, ao atuar como filtros inteligentes, tais sistemas contribuem para reduzir a complexidade de escolha, aproximando os usuários de conteúdos potencialmente mais significativos.

As técnicas de recomendação podem ser classificadas em diferentes abordagens. A filtração colaborativa se baseia na análise coletiva de preferências. A técnica envolve a criação de um repositório com as avaliações feitas pelos usuários e, a partir dessas informações, identifica perfis com gostos semelhantes. Esses perfis compõem um grupo chamado de vizinhança. Com isso, o sistema sugere ao usuário itens que ele ainda não avaliou, mas que foram bem recebidos por outros usuários com interesses compatíveis (Isinkaye; Folajimi; Ojokoh, 2015).

Além disso, a filtração baseada no conhecimento é particularmente útil em situações em que o usuário ainda não possui um histórico de interações. Embora compartilhe algumas características com a filtração baseada em conteúdo, essa abordagem foca na interação direta com o usuário para compreender suas necessidades e preferências (Ricci; Rokach; Shapira, 2010).

Ademais, a filtração híbrida consiste na integração de diferentes técnicas de recomendação com o objetivo de aumentar a qualidade dos resultados e reduzir as limitações das abordagens isoladas. O princípio por trás dessa estratégia é que, ao combinar métodos distintos, é possível obter melhores sugestões, compensando as falhas de um algoritmo com os pontos fortes de outro (Isinkaye; Folajimi; Ojokoh, 2015).

Dentre as principais técnicas de recomendação, existe a filtração baseada em conteúdo, que constitui a base deste trabalho. Essa técnica utiliza as características de itens previamente avaliados para recomendar outros semelhantes, analisando atributos como gêneros, palavras-chave e descrições. Embora apresente o risco de superespecialização, restringindo as opções a itens muito próximos dos já consumidos, sua aplicação mostra-se especialmente relevante em contextos nos quais a personalização precisa respeitar critérios claros, como adequação etária e temática

educacional (Isinkaye; Folajimi; Ojokoh, 2015).

Na presente pesquisa, a partir do seu objetivo geral, desenvolveu-se o CineLearn, um sistema de recomendação educacional de filmes e séries para crianças e adolescentes. Tendo-se também como objetivos: estudar e aplicar algoritmos de grafos para criar um mecanismo de recomendação de conteúdo educativo; desenvolver um sistema web que permita a recomendação de filmes e séries educacionais com base em temas e faixas etárias; integrar uma API externa de filmes para obter informações detalhadas sobre conteúdos audiovisuais; projetar e implementar um banco de dados para armazenar e gerenciar informações sobre usuários, filmes e séries; analisar o sistema de recomendação com base em testes de usabilidade e relevância dos conteúdos sugeridos.

Para o desenvolvimento do sistema, será utilizada a abordagem baseada em grafos. Formalmente, a estrutura de um grafo é expressa pelo par ordenado $G = (V, E)$, onde $V = V(G)$ representa o conjunto dos vértices (vertices) e $E = E(G)$ corresponde ao conjunto das arestas (edges). Cada aresta estabelece uma conexão entre dois vértices, sendo caracterizada por um par v, w , podendo também ser simbolizada simplesmente como vw , indicando o vínculo entre esses dois pontos (Catarino, 2025). Essa representação mostra-se especialmente eficaz para modelar relações complexas, pois possibilita mapear conexões entre filmes, palavras-chave e perfis de usuários de forma mais estruturada. A escolha dessa abordagem justifica-se pela capacidade dos grafos em lidar com a esparsidade dos dados, garantindo maior precisão nas recomendações e permitindo explorar associações que ultrapassam comparações diretas entre itens (Sacenti et al., 2021).

Entre os estudos revisados, destaca-se o trabalho de Bernardo e Andrade (2019), que apresenta o desenvolvimento do aplicativo Cine Collection, um sistema de recomendação de filmes baseado na técnica de filtragem colaborativa. O aplicativo, voltado para dispositivos Android, utilizou a API do The Movie Database (TMDb) como fonte de dados e o Firebase para armazenamento e autenticação, incluindo login via Facebook. A proposta foi implementada com o modelo de desenvolvimento em cascata, permitindo o acompanhamento sistemático desde a concepção até a entrega do produto final. Os resultados evidenciam como a utilização de dados coletivos pode fornecer recomendações personalizadas e alinhadas aos interesses de usuários com perfis semelhantes, reforçando a importância da personalização no consumo de conteúdos audiovisuais.

Outro estudo relevante é o de Leon (2022), que propõe a aplicação de agrupamentos de grafos em um sistema de recomendação de produtos da plataforma Amazon. A pesquisa construiu uma rede bipartida entre usuários e produtos avaliados, aplicando o algoritmo BRIM para formar clusters com base na modularidade da rede. Os testes, realizados sobre dados do segmento de produtos de beleza, alcançaram modularidade de 0.843 em seu cenário mais eficaz, demonstrando boa separação entre grupos de usuários e itens. Essa abordagem mostrou-se eficiente na personalização de recomendações em ambientes de grande volume de dados, embora tenha apresentado limitações para novos usuários e itens recém-inseridos na base.

No campo da análise estrutural de sistemas de recomendação, o estudo de Mirza, Keller e Ramakrishnan (2003) investigou algoritmos de recomendação por meio da teoria dos grafos, propondo o modelo de jumping connections. Em vez de avaliar apenas a precisão preditiva, o artigo explorou propriedades estruturais como caminhos médios, componentes conectados e fenômenos de pequeno mundo em bases de dados como MovieLens e EachMovie. Os autores ressaltam que essa perspectiva favorece a transparência e a explicabilidade das recomendações, permitindo compreender como conexões entre usuários e itens emergem e se organizam dentro da rede.

Por fim, o trabalho de Pontes (2017) explorou o uso de bancos de dados orientados a grafos, com destaque para o Neo4j, como alternativa eficiente aos métodos tradicionais de recomendação. A proposta demonstrou como a modelagem em grafos facilita a integração de novas informações, representando usuários, itens e categorias como nós, e suas interações como arestas. A utilização de consultas na linguagem Cypher possibilitou gerar recomendações a partir de percursos no grafo, evidenciando a riqueza semântica das conexões e a flexibilidade desse modelo diante de cenários dinâmicos. O estudo reforça o potencial dos bancos de dados orientados a grafos em capturar a complexidade das relações entre usuários e itens, oferecendo recomendações mais precisas e contextualizadas.

A estrutura deste trabalho está organizada da seguinte forma: inicialmente, apresenta-se a introdução, com a contextualização do tema, os objetivos e a justificativa. Em seguida, são descritos os procedimentos metodológicos adotados, abrangendo desde a coleta e organização dos dados até a implementação do sistema. Logo após, apresentam-se os re-

sultados obtidos com o desenvolvimento do protótipo e sua análise. Por fim, a conclusão destaca as contribuições alcançadas e sugere possibilidades de continuidade para pesquisas futuras.

2 MATERIAIS E MÉTODOS

O desenvolvimento do sistema de recomendação baseado em conteúdo e estruturado por meio da Teoria de Grafos, proposto nesta pesquisa, caracteriza-se como uma pesquisa aplicada de base tecnológica, com abordagem descritiva e experimental, fundamentada em pesquisa bibliográfica para o embasamento teórico das técnicas utilizadas. O estudo visou a construção de uma aplicação prática que integra conceitos de sistemas de recomendação, grafos e recursos audiovisuais voltados à educação infantil e juvenil.

A metodologia adotada envolve o uso de filtragem baseada em conteúdo, aplicada sobre dados coletados da API do The Movie Database (TMDb), e a utilização de grafos como estrutura central para modelar as relações entre filmes, palavras-chave e perfis de usuários. O sistema foi implementado em ambiente web, empregando o Node.js no back-end e o React.js no front-end, com armazenamento de dados no MongoDB, banco de dados orientado a documentos.


2.1 BASE DE DADOS

A base de dados do CineLearn foi construída a partir da API do The Movie Database (TMDb), uma plataforma amplamente utilizada para acesso a metadados de produções audiovisuais. A coleta dos dados foi realizada por meio de requisições à API, extraíndo informações como título, sinopse, palavras-chave, gênero, classificação indicativa, popularidade e idioma. Esses dados foram armazenados em um banco MongoDB, devido à sua estrutura flexível e suporte nativo a documentos JSON, que facilita o relacionamento entre filmes, séries e suas respectivas palavras-chave.

A estrutura geral do banco de dados pode ser observada na Figura 1, que apresenta as coleções existentes e suas relações internas. A aplicação conta com duas coleções principais: movies e users. A primeira armazena os dados das produções audiovisuais obtidas pela API do TMDb (The Movie Database), incluindo título, gêneros, palavras-chave, faixa etária e ano de lançamento. Já a coleção users guarda as informações dos perfis cadastrados, como nome, idade, papel (professor ou estudante), preferências e resultados do quiz. Essa estrutura simplificada garante eficiência nas

consultas e flexibilidade na geração das recomendações.

Figura 1 - Estrutura do banco de dados



Fonte: Elaborado pelo autor (2025).

Durante o processo de extração, foi aplicado um filtro automático para selecionar apenas obras adequadas às faixas etárias do público-alvo (crianças e adolescentes). Em seguida, as palavras-chave foram normalizadas para garantir consistência semântica entre os registros e facilitar sua utilização em consultas e na construção do grafo de recomendações. Esse tratamento foi fundamental para que as palavras-chave atuassem como nós de ligação entre as produções e os perfis de usuários, permitindo o funcionamento eficiente do sistema de recomendação.

2.2 SERVIDOR

O servidor do sistema foi implementado utilizando o Node.js com o framework Express.js, estruturado em uma arquitetura modular que separa as camadas de rotas, controladores, serviços e modelos. Essa estruturação favorece a manutenção e a escalabilidade do projeto, permitindo a adição de novos módulos sem comprometer a estabilidade do sistema.

A comunicação entre o servidor e o banco de dados foi realizada por meio do Mongoose, uma biblioteca que oferece abstrações de modelos e esquemas para o MongoDB. Os endpoints principais incluem rotas para cadastro e autenticação de usuários, registro de respostas do quiz, listagem de filmes recomendados e gerenciamento da lista de favoritos.

A Figura 2 apresenta exemplos de endpoints implementados no servidor do CineLearn, desenvolvidos com o framework Express.js. O primeiro exemplo ilustra a rota responsável por adicionar filmes à lista de favoritos do usuário, enquanto o segundo exibe o endpoint utilizado para registrar as respostas do quiz e gerar recomendações personalizadas.

Figura 2 - Exemplos de endpoints do servidor CineLearn

```
// Adiciona um filme aos favoritos do usuário
app.post("/users/:id/favorites", async (req, res) => {
  const { id } = req.params;
  const { movieId } = req.body;

  if (!mongoose.Types.ObjectId.isValid(id)) {
    return res.status(400).json({ error: "ID de usuário inválido" });
  }

  try {
    const user = await Users.findById(id);
    if (!user) return res.status(404).json({ error: "Usuário não encontrado" });

    if (user.favorites.includes(movieId)) {
      user.favorites.push(movieId);
      await user.save();
    }

    res.json({ message: "Filme adicionado aos favoritos", favorites: user.favorites });
  } catch (err) {
    console.error(err);
    res.status(500).json({ error: "Erro ao adicionar favorito", details: err.message });
  }
});
```

(a) Endpoint de favoritos

```
// Salvar quiz e retornar filmes recomendados
app.post("/users/:id/quiz", async (req, res) => {
  try {
    const { quizId, answers } = req.body;
    const { id } = req.params;
    const user = await Users.findById(id);
    if (!user) return res.status(404).json({ error: "Usuário não encontrado" });

    const recResponse = await fetch("http://localhost:5000/api/recommendations/graph", {
      method: "POST",
      headers: { "Content-Type": "application/json" },
      body: JSON.stringify({ answers }),
    });
    const recData = await recResponse.json();

    const recommendedIds = (recData.recommendations || [])
      .filter(r => r !== r._id)
      .map(r => r._id);

    console.log("IDs de filmes recomendados:", recommendedIds);

    const newQuiz = {
      quizId: quizId || "educacional",
      answers: answers || [],
      recommendations: recommendedIds,
      createdAt: new Date(),
    };

    user.quizResults.push(newQuiz);
    await user.save();

    const fullMovies = await Movie.find({ _id: { $in: recommendedIds } })
      .select("title tmdbData")
      .lean();

    console.log("Filmes encontrados:", fullMovies.length);

    const populatedQuiz = {
      ...newQuiz,
      recommendations: fullMovies,
    };

    res.json({
      message: "Quiz salvo com sucesso!",
      quiz: populatedQuiz,
    });
  } catch (err) {
    console.error("X Erro ao salvar quiz:", err);
    res.status(500).json({ error: "Erro ao salvar quiz", details: err.message });
  }
});
```

(b) Endpoint do quiz

Fonte: Elaborado pelo autor (2025).

O servidor também inclui tratamento de erros, middleware de autenticação e controle de acesso, garantindo segurança e integridade dos dados durante as transações.

2.3 APLICAÇÃO WEB


A aplicação web do CineLearn foi desenvolvida com o objetivo de oferecer uma interface interativa e acessível para professores, alunos e responsáveis, permitindo a exploração de filmes e séries com potencial educativo de forma intuitiva. O sistema foi implementado utilizando React no front-end e à API do TMDb (The Movie Database) para obtenção e atualização das informações das produções audiovisuais.

A aplicação oferece uma interface intuitiva voltada a professores e estudantes, permitindo o cadastro e login de usuários, que podem registrar-se conforme o perfil desejado (professor ou estudante) e participar de um quiz temático, cujas respostas são utilizadas para personalizar as recomendações. Além disso, o sistema armazena o histórico de atividades e possibilita que o usuário favorite produções para consulta posterior, ampliando a interação e o acompanhamento pedagógico. Após o

envio das respostas, o sistema exibe os filmes sugeridos com base na afinidade das palavras-chave selecionadas, aplicando filtros de classificação indicativa para garantir a adequação etária. As produções recomendadas são apresentadas com sinopses, capas, categorias e classificações etárias, permitindo ao usuário explorar de forma completa os conteúdos disponibilizados e facilitando a seleção de materiais alinhados a seus interesses e necessidades educacionais.


A navegação foi projetada para ser simples e intuitiva, priorizando a experiência em ambientes de desktop. O layout utiliza cores e componentes que favorecem a leitura e a compreensão dos conteúdos, mantendo o foco na clareza e no caráter educativo da proposta. As Figuras apresentam as principais telas da aplicação: a tela de login (Figura 3), responsável pelo acesso ao sistema; a tela inicial (Figura 4), que reúne os filtros de pesquisa e as opções de navegação; a tela de quiz educacional (Figura 5), onde são exibidos os filmes recomendados conforme as palavras-chave selecionadas; e a tela de perfil do usuário (Figura 6), que exibe a lista de filmes favoritados e o histórico das atividades realizadas nos quizzes.

Figura 3 - Tela de Login do CineLearn




Fonte: Elaborado pelo autor (2025).

Figura 4 - Tela do Catálogo Educacional do CineLearn




Fonte: Elaborado pelo autor (2025).

Figura 5 - Tela do Quiz Educacional



Fonte: Elaborado pelo autor (2025).

Figura 6 - Tela do Perfil do Usuário



Fonte: Elaborado pelo autor (2025).

2.4 ALGORITMO DE RECOMENDAÇÃO

O algoritmo de recomendação do CineLearn foi implementado com base na Teoria dos Grafos, adotando uma abordagem baseada em conteúdo. Nesse modelo, os filmes, palavras-chave e perfis de usuários são representados como nós (vértices), enquanto as arestas expressam as relações entre esses elementos. Cada aresta possui um peso associado, que indica o grau de relevância ou similaridade entre os nós conectados, de acordo com a ocorrência e a correspondência das keywords nos filmes.

Durante o uso do sistema, quando o usuário seleciona determinados temas ou palavras-chave no quiz, o algoritmo percorre o grafo ponderado para identificar os filmes mais relacionados, priorizando aqueles com maiores pesos de conexão. Esse processo considera a proximidade semântica e a quantidade de palavras-chave compartilhadas, resultando em recomendações mais coerentes com as preferências e o perfil do usuário.

Para tornar essas relações mais expressivas, atribuem-se pesos às arestas do grafo, de modo que cada conexão represente o grau de relevância entre o filme e as respostas fornecidas pelo usuário. No CineLearn, esse peso é definido a partir de critérios principais, como a quantidade de palavras-chave em comum entre o quiz e o filme, indicando afinidade temá-

tica, a adequação da classificação indicativa à idade informada pelo usuário, que reforça o peso quando há compatibilidade, a nota média do TMDb, utilizada como métrica externa de qualidade e aceitação geral da obra e bônus adicionais para filmes que cobrem mais de um grupo temático selecionado no quiz, valorizando produções com maior amplitude pedagógica. A combinação desses elementos gera pesos mais robustos e sensíveis às nuances do perfil do usuário, influenciando diretamente a ordenação final dos resultados e contribuindo para recomendações mais precisas, contextualizadas e alinhadas aos objetivos educacionais do sistema.

O uso de grafos ponderados permite lidar com a esparsidade dos dados e explorar relações complexas entre produções audiovisuais e preferências, superando as limitações de modelos tradicionais de filtragem. Assim, o sistema oferece recomendações mais precisas, contextualizadas e adaptáveis a diferentes perfis de usuários, mantendo alinhamento com o enfoque educacional e etário proposto pelo CineLearn (Sacenti et al., 2021).

2.5 EXPERIMENTOS

Com o objetivo de validar o funcionamento do sistema de recomendação CineLearn e avaliar sua usabilidade, foram realizados dois experimentos complementares: um teste funcional do algoritmo de recomendação e um teste de usabilidade com participantes reais. Ambos tiveram como finalidade verificar se o sistema atende aos objetivos propostos de oferecer recomendações coerentes com os temas selecionados e proporcionar uma experiência de uso simples e intuitiva.

Antes da etapa de testes, foi realizada a importação e limpeza dos dados provenientes da API do TMDb, a fim de garantir a qualidade e a adequação das produções armazenadas na base. Inicialmente, foram coletados 17.853 filmes, que passaram por um processo automatizado de filtragem. Foram removidos 6.894 filmes sem descrição, 203 títulos duplicados e 2.085 produções inadequadas ao público infantojuvenil (classificadas como voltadas para maiores de idade). Após a limpeza, restaram 8.671 filmes válidos, que compuseram a base final utilizada pelo sistema para geração das recomendações.

Esse pré-tratamento dos dados foi essencial para garantir que o algoritmo de recomendação operasse sobre um conjunto consistente e adequado ao público-alvo, evitando que conteúdos inapropriados interferissem na construção do grafo e na precisão das recomendações.

O teste funcional teve como objetivo avaliar o desempenho do algoritmo baseado em grafos, verificando se as produções sugeridas mantinham relação direta com as palavras-chave escolhidas no quiz. Foram realizadas 385 simulações de uso, com diferentes combinações de temas e palavras-chave, cada simulação resultou em cinco filmes recomendados, totalizando 1.925 produções analisadas. A amostragem seguiu uma distribuição etária proporcional ao público-alvo do CineLearn, definida com base no Censo Demográfico do Instituto Brasileiro de Geografia e Estatística (IBGE) (2022), assegurando representatividade entre as faixas etárias consideradas. Os resultados de cada simulação foram registrados em planilha contendo as respostas do quiz, os filmes recomendados e observações sobre a coerência dos resultados com os objetivos pedagógicos.

Para a análise automatizada, foi desenvolvido um script em Python (Figura 7), utilizando a biblioteca Pandas para leitura e manipulação dos dados. O código comparou as palavras-chave do quiz com as dos filmes recomendados, calculando automaticamente o percentual de cobertura de categorias atingido pelo algoritmo. Ao final, os resultados foram consolidados em uma nova planilha, permitindo quantificar a precisão das recomendações e confirmar a validade do modelo baseado em grafos.

Figura 7 - Estrutura do banco de dados

```
import pandas as pd

# === 1. Configuração de arquivos ===
arquivo = "Cinelearn_listaPredefinida_385_IdadesDistribuidas (1).xlsx"
aba_resultados = "Resultados"
aba_dicionario = "Dicionario_Keywords"

# === 2. Ler a aba Dicionario_Keywords e montar o dicionário ===
dic = pd.read_excel(arquivo, sheet_name=aba_dicionario)
categorias = {}

for _, row in dic.iterrows():
    opcao = str(row["Opção"]).strip()
    palavras = [p.strip().lower() for p in str(row["Keywords_en"]).split(",")]
    categorias[opcao] = palavras

# === 3. Ler a aba Resultados ===
df = pd.read_excel(arquivo, sheet_name=aba_resultados)

COL_QUIZ = "Palavras_Quiz"
COL_FILME = "Palavras_Filme"

# === 4. Função para comparar por categoria ===
def cobertura_categoria(respostas_quiz, palavras_filme):
    try:
        if pd.isna(respostas_quiz) or pd.isna(palavras_filme):
            return 0, "", 0

        respostas = [r.strip() for r in str(respostas_quiz).split(",")]
        filme_kw = [k.strip().lower() for k in str(palavras_filme).split(",")]

        acertos = 0
        encontradas = []

        for r in respostas:
            if r in categorias:
                for palavra in categorias[r]:
                    if any(palavra in fk for fk in filme_kw):
                        acertos += 1
                        encontradas.append(r)
                        break

        total_categorias = len(respostas)
        percentual = (acertos / total_categorias) * 100 if total_categorias > 0 else 0

        return acertos, "; ".join(encontradas), percentual
    except Exception as e:
        print(f"⚠ Erro ao processar linha: {e}")
        return 0, "", 0

# === 5. Aplicar a função ===
resultados = df.apply(lambda x: cobertura_categoria(x[COL_QUIZ], x[COL_FILME]), axis=1)
df["Categorias_Cobertas"] = [r[0] for r in resultados]
df["Categorias_Encontradas"] = [r[1] for r in resultados]
df["Percentual_Categorias"] = [r[2] for r in resultados]

# === 6. Salvar resultados ===
saida = "Cinelearn_Resultados_Por_Categorias.xlsx"
df.to_excel(saida, sheet_name=aba_resultados, index=False)
print("🎉 Avaliação por categoria concluída com sucesso!")
```

Fonte: Elaborado pelo autor (2025).

Outrossim, o teste de usabilidade teve como finalidade avaliar a experiência dos usuários em relação à interface e à interação com o sistema. Participaram do teste 15 voluntários, incluindo 7 professores, 4 alunos e 3 responsáveis. Após a navegação, cada participante respondeu a um questionário composto por afirmações avaliadas em uma escala de Li-

kert de 1 a 5, variando de “discordo totalmente” a “concordo totalmente”. O questionário abordou aspectos como clareza da interface, facilidade de navegação, compreensão dos ícones e menus, adequação das recomendações e satisfação geral com o sistema. As respostas foram compiladas para posterior análise quantitativa e qualitativa.

Dessa forma, os experimentos permitiram observar tanto a precisão do algoritmo de recomendação quanto a usabilidade da aplicação web, fornecendo dados que fundamentam a análise apresentada na próxima seção.

3 RESULTADOS E DISCUSSÃO

A análise dos resultados obtidos nos experimentos permitiu avaliar a eficiência do algoritmo de recomendação do CineLearn e a percepção dos usuários quanto à facilidade de uso e à relevância das sugestões apresentadas. De modo geral, os participantes demonstraram boa aceitação do sistema, destacando a clareza das telas e a pertinência das recomendações.

No teste funcional, em termos de adequação etária, observou-se que 1.514, correspondendo a 78,65% do total de 1.925 recomendações analisadas, estavam compatíveis com as faixas etárias definidas para o CineLearn. Esse resultado indica que o conjunto de regras de filtragem por classificação indicativa e metadados de faixa etária cumpriu seu papel de restringir conteúdos inadequados para crianças e adolescentes.

A Tabela 1 apresenta a distribuição das recomendações adequadas por faixa etária, evidenciando o desempenho do sistema em diferentes grupos de usuários. Nota-se que as faixas de 10 a 14 anos e 15 a 19 anos apresentaram os maiores índices de conformidade, com 90,31% e 99,41% de adequação, respectivamente. Por outro lado, as faixas 1 a 4 anos e 5 a 9 anos apresentaram índices menores, ainda que expressivos, de 62,22% e 60,62%. Essa diferença pode estar relacionada à maior dificuldade de identificar e filtrar conteúdos completamente apropriados para crianças mais novas, uma vez que classificações como PG, TV-G, TV-PG, TV-Y, TV-14 e entre outros, podem ser interpretadas de forma distinta entre plataformas, e parte dessas classificações ainda não foi totalmente incorporada ao mecanismo de filtragem.

Como o código de verificação de faixa etária não foi totalmente adaptado para interpretar a diversidade desses formatos, algumas produções acabaram sendo consideradas válidas para todas as faixas etárias.

Por limitações de tempo durante o desenvolvimento, não foi possível realizar o mapeamento completo entre os sistemas de classificação internacionais e nacionais, o que justifica as ocorrências de recomendações fora da faixa indicada, principalmente nos grupos mais jovens.


Tabela 1 - Adequação etária por faixa etária do público-alvo

Faixa etária	Recomendações	Adequadas (n)	Adequadas (%)
1–4	450	280	62,22%
5–9	485	294	60,62%
10–14	485	438	90,31%
15–19	505	502	99,41%
Total	1.925	1.514	78,65%

Fonte: Elaborado pelo autor (2025).

Quanto à cobertura das categorias, a Figura 8 apresenta a distribuição das correspondências entre os grupos de palavras-chave selecionados no quiz e aquelas associadas aos filmes recomendados. O quiz é composto por sete grupos temáticos de perguntas, cada um contendo um conjunto de palavras-chave relacionadas a um tema educativo. Dessa forma, cada filme recomendado pode apresentar de 1 a 7 correspondências possíveis, indicando em quantos desses grupos o sistema encontrou pelo menos uma palavra-chave coincidente.

Figura 8 - Distribuição das correspondências



Fonte: Elaborado pelo autor (2025).

No resultado obtido, observa-se que a maior parte das recomendações apresentou 2 grupos cobertos, correspondendo a 51,84% dos casos. Em seguida, recomendações com apenas 1 grupo foram identificadas em 27,74% das situações, enquanto 17,77% das recomendações apresentaram correspondência com 3 grupos do quiz. Coberturas mais amplas

foram menos frequentes: 4 grupos representaram 2,55% das recomendações, e casos com 5 grupos ocorreram em apenas 0,10% dos resultados. Não foram verificadas recomendações com 6 ou 7 grupos simultaneamente, o que evidencia a atual tendência do modelo em identificar relações mais centrais entre os interesses do usuário e os conteúdos disponíveis.

Essa distribuição demonstra que o algoritmo foi capaz de estabelecer relações semânticas entre múltiplos temas respondidos no quiz, refletindo um bom nível de coerência nas recomendações. Embora recomendações que contemplam um grande número de grupos sejam raras, o predomínio de correspondências entre dois ou três conjuntos evidencia que o modelo conseguiu conectar adequadamente os interesses educacionais dos usuários aos conteúdos audiovisuais recomendados, mesmo sem utilizar técnicas híbridas mais complexas ou volumes massivos de dados.

Assim, os resultados reforçam o potencial da abordagem baseada em grafos, indicando que o sistema foi capaz de gerar recomendações relevantes e alinhadas a diferentes dimensões pedagógicas. Apesar desses resultados positivos, reconhece-se que o modelo ainda não alcança sua performance ideal, especialmente no que diz respeito à abrangência de múltiplos grupos temáticos simultaneamente. A predominância de correspondências entre um e três grupos sugere que o sistema consegue captar relações essenciais entre os interesses do usuário e os conteúdos recomendados, mas ainda possui margem para aprimoramentos na identificação de conexões mais amplas e complexas. Futuramente, pretende-se ampliar o conjunto de dados, refinar os pesos entre vértices e testar técnicas complementares de processamento semântico, o que poderá elevar a diversidade contextual nas recomendações.

Em relação ao teste de usabilidade, os resultados mostraram médias elevadas nas avaliações dos participantes, conforme apresentado na Tabela 2. As notas atribuídas variaram entre 4,60 e 4,93, com média geral de 4,82 pontos, o que demonstra um excelente nível de satisfação. Os maiores índices foram observados nos critérios de clareza da interface, facilidade de navegação e organização das informações, reforçando que o CineLearn foi percebido como intuitivo, funcional e agradável de utilizar. Nenhum dos participantes relatou dificuldades significativas durante as interações, o que evidencia a eficácia da estrutura visual e da lógica de navegação implementadas. Tais resultados confirmam que o sistema atende aos princípios de usabilidade e acessibilidade, sendo adequado para diferentes perfis de usuários dentro do público-alvo proposto.

Tabela 2 - Teste de Usabilidade

Questão Avaliada	1	2	3	4	5	Média
O sistema CineLearn é fácil de usar e compreender.	0	0	0	2	13	4,87
A interface do sistema é clara e intuitiva.	0	0	0	1	14	4,93
As etapas de cadastro, login e navegação são simples e funcionam sem dificuldades.	0	0	0	4	11	4,73
O tempo de carregamento e resposta do sistema é satisfatório.	0	0	0	1	14	4,93
A organização das informações e seções facilita a navegação.	0	0	0	1	14	4,93
O processo de realizar o quiz e receber recomendações é rápido e prático.	0	0	0	2	13	4,87
As recomendações de filmes e séries apresentadas são coerentes com as respostas do quiz.	0	0	1	4	10	4,60
O CineLearn apresenta boa estabilidade.	0	0	0	3	12	4,80
As informações apresentadas sobre os filmes são úteis e bem organizadas.	0	0	0	3	12	4,80
O design visual do CineLearn é agradável e torna o uso mais fácil e envolvente.	0	0	1	1	13	4,73
Nível geral de satisfação com o CineLearn.	0	0	0	2	13	4,87

Fonte: Elaborado pelo autor (2025).

As respostas abertas reforçaram essa percepção positiva. Quando questionados sobre dificuldades ou limitações, a maioria relatou ausência de problemas técnicos, descrevendo o sistema como “intuitivo”, “de fácil compreensão” e “visualmente agradável”. Apenas dois participantes mencionaram pequenas limitações, relacionadas à ausência de confirmação visual no cadastro e à impossibilidade de visualizar a senha digitada, aspectos pontuais e de fácil correção.

Quanto às sugestões de melhoria, destacaram-se: a inclusão de novos filtros de pesquisa, como faixa etária e categorias específicas; a possibilidade de selecionar múltiplas opções no quiz; o aumento da base de dados de filmes e séries; a adição de feedback visual e confirmação de cadastro; e o aprimoramento da pesquisa por palavras-chave. Os participantes também propuseram novas funcionalidades, como a exibição de trailers, indicação de plataforma de streaming, recuperação de senha, e a exibição de obras semelhantes à selecionada, ampliando o potencial de engajamento do usuário. Tais sugestões evidenciam que, embora o sistema tenha sido bem avaliado, há espaço para evoluções que podem torná-lo ainda mais completo, atrativo e alinhado às necessidades práticas do público-alvo. A

incorporação gradual dessas melhorias pode contribuir para um ambiente ainda mais intuitivo, robusto e adequado ao uso contínuo em contextos educacionais.

Na questão final, que investigava se o participante recomendaria o uso do CineLearn a outros professores, pais ou alunos, 14 dos 15 voluntários (93,3%) responderam “Sim”, enquanto apenas um respondeu “Talvez”, não havendo respostas negativas. Esse resultado reforça a boa recepção do sistema e seu potencial de aplicação prática em contextos educacionais. Nesse contexto, é pertinente comparar o CineLearn com trabalhos relacionados, a fim de evidenciar como a presente solução se insere no cenário de sistemas de recomendação e quais inovações ela introduz em relação a pesquisas anteriores.

Assim como observado em Bernardo e Andrade (2019), que desenvolveram o aplicativo Cine Collection utilizando a filtragem colaborativa para recomendar filmes com base nas preferências coletivas dos usuários, o CineLearn também parte do princípio da personalização de conteúdos audiovisuais. No entanto, enquanto o Cine Collection se apoia no comportamento agregado de usuários para gerar recomendações, o CineLearn adota uma abordagem baseada em conteúdo aliada à teoria dos grafos, priorizando critérios pedagógicos e adequação etária. Essa distinção é fundamental, pois o foco do CineLearn não se limita a similaridades de gosto, mas sim à curadoria educativa, priorizando segurança, relevância pedagógica e desenvolvimento cognitivo de crianças e adolescentes. Enquanto o Cine Collection visa aprimorar a experiência de entretenimento, o CineLearn expande esse propósito para o contexto educacional, atuando como apoio ao processo de ensino-aprendizagem.

Da mesma forma, a pesquisa de Leon (2022) apresentou o uso de agrupamentos de grafos para estruturar recomendações na plataforma Amazon, explorando modularidade e conexões entre itens e usuários em larga escala. Embora ambos os trabalhos utilizem grafos como base estrutural, suas finalidades divergem quanto ao domínio e ao público-alvo. Nesse estudo, a modelagem visa otimizar a experiência de consumo em um ambiente comercial, enquanto no CineLearn os grafos são utilizados para mapear relações semânticas entre palavras-chave educacionais e conteúdos audiovisuais, alinhando-se às respostas do quiz temático do usuário. Essa adaptação reforça o papel do CineLearn como ferramenta pedagógica, direcionando recomendações que promovem desenvolvimento crítico e aprendizagem.

4 CONCLUSÃO

O desenvolvimento do CineLearn permitiu demonstrar o potencial dos sistemas de recomendação como ferramenta de apoio pedagógico, com foco na curadoria de conteúdos audiovisuais apropriados para crianças e adolescentes. A aplicação da filtragem baseada em conteúdo, apoiada pela teoria dos grafos, mostrou-se eficaz na geração de recomendações alinhadas às respostas do quiz temático e às características educacionais dos filmes. A implementação de filtros de classificação indicativa e metadados de faixa etária contribuiu para garantir maior segurança no processo de recomendação, reduzindo a exposição a conteúdos inadequados.

Os resultados obtidos nos testes funcionais indicaram níveis satisfatórios de adequação etária e coerência temática, reforçando a capacidade do CineLearn em conectar interesses educacionais dos usuários a obras audiovisuais relevantes. Embora o sistema tenha apresentado desempenho superior nas faixas etárias mais elevadas, a precisão alcançada para crianças mais novas evidencia a viabilidade da abordagem, ao mesmo tempo em que revela oportunidades de melhoria na interpretação de classificações etárias internacionais e na ampliação da base de dados. A avaliação de usabilidade também demonstrou uma experiência clara, intuitiva e adequada ao público-alvo.

Como perspectivas futuras, destacam-se a ampliação da base de dados, a integração de métricas pedagógicas mais refinadas, a adaptação a diferentes currículos escolares e a possibilidade de incorporar técnicas híbridas de recomendação, combinando o perfil de aprendizado do usuário com análise colaborativa. Conclui-se que o CineLearn representa um avanço na união entre tecnologia e educação, oferecendo um ambiente inovador para a mediação do uso consciente e formativo do audiovisual em contextos educacionais.

REFERÊNCIAS

BERNARDO, L. E.; ANDRADE, K. d. O. **Cine collection: um aplicativo para recomendação de filmes**. Revista Tecnológica da Fantec Americana, 2019,

CATARINO, M. H. **Teoria dos Grafos**. [S.l.]: Freitas Bastos, 2025.

HOLLEBEN, V. H. V.; PORTELA, A. F.; FOGAÇA, R. S. **CINEMA & EDUCAÇÃO: Diálogo Possível**. 2007. UEPG - Universidade Estadual de Ponta Grossa.

Instituto Brasileiro de Geografia e Estatística (IBGE). **Censo Demográfico 2022: Panorama do Brasil**. 2022. Disponível em: <<https://censo2022.ibge.gov.br/panorama/>>. Acesso em: 1 set. 2025.

ISINKAYE, F.; FOLAJIMI, Y.; OJOKOH, B. **Recommendation systems: Principles, methods and evaluation**. Egyptian Informatics Journal, 2015, v. 16, n. 3, p. 261–273. ISSN 1110-8665.

JANNACH, D. et al. **Recommender systems: an introduction**. [S.l.]: Cambridge university press, 2010.

LEON, G. V. **Agrupamento de grafos e sistema de recomendação: um estudo de caso das avaliações da Amazon**. 2022. Universidade Tecnológica Federal do Paraná.

MIRZA, B. J.; KELLER, B. J.; RAMAKRISHNAN, N. **Studying recommendation algorithms by graph analysis**. Journal of intelligent information systems, 2003, Springer, v. 20,

PIRES, M. d. C. F.; SILVA, S. L. P. d. **O cinema, a educação e a construção de um imaginário social contemporâneo**. Educação Sociedade, 2014, Centro de Estudos Educação e Sociedade - Cedes, v. 35, n. 127, p. 607–616. ISSN 0101-7330.

PONTES, A. V. **Sistema de recomendação baseado em banco de dados orientado a grafos**. 2017. Universidade Federal do Maranhão.

RICCI, F.; ROKACH, L.; SHAPIRA, B. Introduction to recommender systems handbook. In: **Recommender systems handbook**. [S.l.]: Springer, 2010. p. 1–35.

SACENTI, J. A. P. et al. **Impactos da representação e da sumarização de grafos de conhecimentos em sistemas de recomendação**. 2021. Universidade Federal de Santa Catarina.