



Sistemas de recomendação de leitura e sua implementação: Revisão Sistemática da Literatura Nacional

Henrique Kenzo Odagui, ICT/Unifesp, henrique.odagui@unifesp.br,
<https://orcid.org/0009-0009-5799-234X>

Elisângela Ferreira Araújo, ICT/Unifesp, efaraujo@unifesp.br,
<https://orcid.org/0009-0002-2920-7155>

Denise Stringhini, ICT/Unifesp, dstringhini@unifesp.br,
<https://orcid.org/0000-0002-9729-4302>

Tiago de Oliveira, ICT/Unifesp, tiago.oliveira@unifesp.br,
<https://orcid.org/0000-0002-3676-5967>

Resumo: Este artigo apresenta uma Revisão Sistemática da Literatura (RSL) Nacional que teve como objetivo abordar os estudos relacionados a sistemas de recomendação de leitura e sua implementação, identificando os contextos em que esses sistemas são empregados, suas finalidades e os desafios enfrentados. A análise foi conduzida por meio de planilhas eletrônicas para organização e da ferramenta *Parsifal* para apoio metodológico. As questões norteadoras da revisão investigaram o contexto de aplicação, as abordagens tecnológicas utilizadas, os dados dos usuários considerados e os métodos de validação empregados. Os resultados revelaram que, embora existam estudos sobre sistemas de recomendação voltados à educação, poucos abordam especificamente a recomendação de leitura, evidenciando uma lacuna na produção científica nacional. Observou-se ainda que a maioria dos sistemas foi implementada em ambientes web, o que aponta para um ecossistema já consolidado, com ferramentas e boas práticas bastante difundidas. Embora no corpus documental apresentado na RSL tenha havido recorrência na implementação de sistemas de recomendação utilizando três das quatro abordagens disponíveis na literatura científica (filtragem baseada em conteúdo, filtragem colaborativa e abordagem híbrida), os resultados apresentados e as análises realizadas nos artigos não endereçam os principais desafios inerentes à escolha dessas abordagens.

Palavras-chave: sistemas de recomendação, leitura, educação, revisão sistemática da literatura, tecnologia educacional.

Reading recommendation systems and their implementation: National Systematic Literature Review

Abstract: This article presents a National Systematic Literature Review (SLR) that aimed to address studies related to reading recommendation systems and their implementation, identifying the contexts in which these systems are used, their purposes and the challenges faced. The analysis was conducted using spreadsheets for organization and the Parsifal tool for methodological support. The guiding questions of the review investigated the application context, the technological approaches used, the user data considered, and the validation methods used. The results revealed that, although there are studies on recommendation systems aimed at education, few specifically address reading recommendation, evidencing a gap in scientific production. It was also observed that most of the systems were implemented in web environments, which points to an already consolidated ecosystem, with widely disseminated tools and good practices. While the documented corpus in this SLR showed a recurrence in the implementation of recommendation systems using three of the four approaches available in scientific literature (content-based filtering, collaborative filtering, and hybrid approach), the results presented and the analyses conducted in the articles do not address the main challenges inherent in choosing these approaches.

Keywords: recommendation systems, reading, education, systematic literature review, educational technology.



1. Introdução

A leitura, enquanto prática social, é parte fundamental no processo educativo e no desenvolvimento de competências cognitivas, críticas e comunicativas. De acordo com o *Jornal da USP* (2023), a leitura contribui para a formação de cidadãos mais conscientes e participativos, promovendo uma educação transformadora e alinhada às exigências do século XXI. No contexto brasileiro, no entanto, os dados do Censo da Educação Superior de 2023 (BRASIL, 2023) revelam desafios persistentes na promoção de práticas leitoras eficazes, inclusive no nível superior, onde se espera maior autonomia e competência leitora dos estudantes.

Diante dessa realidade, diversas estratégias inovadoras têm sido buscadas para fomentar o hábito da leitura, torná-la mais atrativa e personalizada às necessidades e interesses dos indivíduos. É nesse cenário que emergem os sistemas de recomendação de leitura, tecnologias baseadas em algoritmos que sugerem conteúdos personalizados a partir do histórico, das preferências ou do comportamento do usuário (ESTATÍSTICA FÁCIL, 2024). Tais sistemas vêm sendo comumente utilizados em ambientes comerciais, como plataformas de *streaming* e lojas virtuais, todavia seu uso na educação tem ganhado espaço nas últimas décadas (RICCI; ROKACH; SHAPIRA, 2015).

No campo educacional, os sistemas de recomendação têm sido aplicados para orientar estudantes na escolha de materiais didáticos, livros e recursos digitais, com potencial para tornar a aprendizagem mais autônoma e significativa (GUTIÉRREZ; SCHMIDT; LOPES, 2019). Essas soluções tecnológicas, quando aliadas a princípios de personalização e adaptabilidade, têm potencial de contribuir para o desenvolvimento de competências metacognitivas, como o planejamento, o monitoramento e a avaliação da própria leitura (FLAVELL, 1979; PINTRICH, 2002; ZIMMERMAN, 2002). Assim, a recomendação de leitura deixa de ser uma tarefa algorítmica e passa a integrar um ecossistema de apoio ao processo formativo do estudante.

Apesar dos avanços, a literatura científica sobre sistemas de recomendação de leitura no contexto educacional ainda é fragmentada. Observa-se a necessidade de sistematizar os estudos existentes para identificar as abordagens predominantes, as lacunas de pesquisa e as contribuições já consolidadas. Nesse sentido, a Revisão Sistemática da Literatura (RSL) apresenta-se como metodologia rigorosa e relevante para mapear e analisar criticamente as evidências disponíveis (KITCHENHAM; CHARTERS, 2007; TRANFIELD; DENYER; SMART, 2003).

A presente RSL visa, portanto, investigar o estado da arte sobre os sistemas de recomendação de leitura e sua implementação no contexto da literatura educacional nacional, analisando especialmente os aspectos técnicos, pedagógicos e os impactos reportados em ambientes de aprendizagem. A relevância desta pesquisa se justifica pelo aumento do uso de tecnologias educacionais e pela necessidade de práticas mais eficazes de incentivo à leitura em diferentes níveis de ensino. Além disso, esta revisão pretende apoiar o desenvolvimento de novas ferramentas, como aplicações web educacionais, cuja arquitetura, responsividade e integração a ambientes virtuais de aprendizagem estão em constante aprimoramento (FOWLER, 2019; KING HOST, 2023).

Ao consolidar as evidências existentes e identificar tendências, esta RSL poderá fornecer subsídios para pesquisadores, desenvolvedores e educadores interessados em potencializar a leitura por meio de tecnologias que recomendem, contribuindo para a personalização do ensino, a autonomia do estudante e a melhoria da qualidade educacional como um todo.

O artigo está estruturado da seguinte forma: na seção 1 encontra-se uma introdução acerca do tema e da necessidade do presente trabalho; na seção 2 apresenta-se a metodologia



utilizada e também o protocolo de revisão sistemática, trazendo as questões de pesquisa, o processo de busca e a seleção dos artigos; na seção 3 discorre-se sobre os resultados visando responder às questões de pesquisa elencadas e pontuar as ameaças à validade da pesquisa; por fim, na seção 4, encontra-se a conclusão do trabalho.

2. Metodologia de Pesquisa e Execução do Protocolo de Revisão Sistemática

Para conduzir a Revisão Sistemática da Literatura (RSL), foi adotado o protocolo sugerido por Kitchenham e Charters (2007), com as devidas adaptações ao contexto educacional e tecnológico do estudo. A RSL é uma metodologia amplamente utilizada para coletar, analisar e sintetizar evidências sobre uma questão de pesquisa específica. Essa abordagem segue protocolos rigorosos, diferindo das revisões narrativas tradicionais, que são mais subjetivas e menos estruturadas. A RSL é essencial para garantir transparência e reprodutibilidade, além de oferecer uma visão abrangente sobre o estado da arte de determinado tema.

2.1 Questões de Pesquisa (QP)

- **QP1:** Em qual contexto e como os sistemas de recomendação foram implementados?
- **QP2:** Quais dados dos usuários foram utilizados para realizar a recomendação?
- **QP3:** Como os sistemas de recomendação foram validados?

A primeira questão de pesquisa busca identificar a aplicabilidade do software desenvolvido ou analisado nos estudos, bem como obter informações detalhadas sobre as tecnologias e métodos utilizados. Por sua vez, a segunda questão de pesquisa visa identificar as informações coletadas dos usuários, os dados viáveis e relevantes para as implementações propostas. Por fim, a terceira questão de pesquisa busca observar a qualidade dos sistemas desenvolvidos e como eles foram avaliados para garantir a confiabilidade dos resultados.

2.2 String de Busca

Para a formulação da estratégia de busca, é essencial definir palavras-chave e seus sinônimos, que formarão a *string* de busca e guiarão a extração de documentos relevantes. Com base nessas escolhas, foi gerada, utilizando a ferramenta *Parsifal*, a seguinte *string* de busca:

("sistema de recomendação" OR "algoritmo de recomendação" OR "algoritmos de recomendação" OR "sistemas de recomendação") AND ("leitura" OR "educação" OR "alfabetização" OR "educacional" OR "ensino" OR "metacognição").

Cabe destacar que diferentes bases de dados podem exigir adaptações na sintaxe da *string* de busca. Por exemplo, para a *ACM Digital Library*, a *string* foi adaptada da seguinte forma:

[[All: sistema] OR [All: sistemas] OR [All: algoritmo] OR [All: algoritmos]] AND [All: recomendação] AND [[All: leitura] OR [All: ensino] OR [All: educação] OR [All: educacional] OR [All: alfabetização] OR [All: metacognição]] AND [E-Publication Date: (01/01/2015 TO 12/31/2024)].



2.3 Bases de Dados Utilizadas

As principais bases de dados utilizadas para a busca de artigos científicos foram as seguintes:

1. Portal de Periódicos CAPES <https://www.periodicos.capes.gov.br/>
2. SciELO Brasil <https://www.scielo.br/>
3. ACM Digital Library <https://dl.acm.org/>
4. IEEE Xplore <https://ieeexplore.ieee.org/>

2.4 Seleção de artigos

CrITÉRIOS de Inclusão:

- Estudos sobre sistemas de recomendação aplicados à educação, leitura, ensino, alfabetização ou metacognição;
- Disponibilidade do conteúdo completo;
- Publicação entre 2005 e 2024.

CrITÉRIOS de Exclusão:

- Artigos não redigidos em português;
- Estudos fora do escopo da pesquisa;
- Estudos secundários ou revisões de literatura.

2.5 Resultados das buscas

Para assegurar que os estudos incluídos sejam confiáveis e relevantes para o objetivo da pesquisa, foi realizada uma Avaliação de Qualidade. Este processo utilizou um conjunto de 10 questões aplicadas a cada estudo analisado. Essas questões permitiram avaliar aspectos metodológicos, clareza, relevância e aplicabilidade dos artigos selecionados, conforme critérios propostos por Dermeval et al. (2016), Tiwari e Gupta (2015), Kitchenham e Charters (2007) e Wieringa, Maiden e Rolland (2006), com a seguinte pontuação:

- 1 ponto: critério totalmente atendido;
- 0,5 ponto: critério parcialmente atendido;
- 0 ponto: critério não atendido.

Os critérios de qualidade consideraram:

- Clareza dos objetivos do estudo (relacionado à Questão de Qualidade 1 – **QQ1**);
- Descrição da técnica utilizada (relacionado à Questão de Qualidade 2 – **QQ2**);
- Rigor dos dados de análise (relacionado à Questão de Qualidade 3 – **QQ3**);
- Discussão sobre trabalhos relacionados (relacionado à Questão de Qualidade 4 – **QQ4**);
- Descrição dos participantes ou unidades de análise (relacionado à Questão de Qualidade 5 – **QQ5**);
- Discussão das limitações (relacionado à Questão de Qualidade 6 – **QQ6**);
- Discussão dos resultados (relacionado à Questão de Qualidade 7 – **QQ7**);
- Lições aprendidas (relacionado à Questão de Qualidade 8 – **QQ8**);



- Relevância para a prática (relacionado à Questão de Qualidade 9 – **QQ9**);
- Potencial de provocar discussão (relacionado à Questão de Qualidade 10 – **QQ10**).

Estudos que não atingiram pelo menos metade da pontuação total (isto é, 5 pontos) foram desclassificados da pesquisa, por não apresentarem qualidade suficiente para contribuir com os objetivos da revisão.

3. Resultados Obtidos

3.1 Visão geral dos estudos

Inicialmente, foram identificados 163 artigos a partir da aplicação da *string* de busca nas bases de dados utilizadas, como comentado na seção 2. Após a triagem com base nos critérios de exclusão, restaram 10 artigos. Em seguida, foi aplicada a avaliação de qualidade cujo resultado de cada artigo está apresentado na Tabela 1, indicando o total de pontos atribuídos e a decisão final sobre a sua inclusão ou exclusão (abaixo de 5 pontos ocorre a exclusão do artigo na análise da RSL).

Tabela 1 – Avaliação de Qualidade dos artigos

Artigo	Questão de Qualidade (QQ)										Total
	1	2	3	4	5	6	7	8	9	10	
(JULIANI; DONHA, 2023)	1,0	1,0	0,5	1,0	0,5	1,0	0,5	0,5	1,0	1,0	8,00
(SILVA; PEREIRA, 2024)	1,0	0,5	0,0	0,5	0,0	0,0	0,0	0,0	0,5	0,5	3,00
(LORENÇÃO; SANTOS, 2021)	1,0	1,0	1,0	1,0	0,5	0,5	1,0	0,5	1,0	1,0	8,50
(CORREA, 2019)	1,0	1,0	0,5	1,0	0,5	0,5	1,0	0,5	1,0	1,0	8,00
(GOMES, 2022)	1,0	1,0	1,0	1,0	1,0	0,5	1,0	0,5	1,0	1,0	9,00
(LUCENA, 2022)	1,0	1,0	0,5	1,0	0,5	0,5	1,0	0,5	1,0	1,0	8,00
(KELLERMANN; SCHMITT; MORAES, 2019)	1,0	1,0	0,5	0,5	0,0	0,5	0,5	0,5	1,0	1,0	6,50
(BARCELLOS et al., 2007)	1,0	0,5	0,0	0,5	0,0	0,0	0,0	0,0	0,5	0,5	3,00
(SILVA; PEREIRA, 2014)	1,0	0,5	0,0	0,5	0,0	0,0	0,0	0,0	0,5	0,5	3,00
(CARNEIRO et al., 2008)	1,0	0,5	0,0	0,5	0,0	0,0	0,0	0,0	0,5	0,5	3,00

Após essa avaliação, 6 artigos atenderam a todos os critérios com pontuação mínima necessária e foram selecionados para análise aprofundada. Nesta etapa, os artigos selecionados foram lidos integralmente para extrair informações relevantes, como ano e local de publicação, além de responder às questões de pesquisa previamente definidas. Esses artigos serão referenciados como: **E1** – (JULIANI; DONHA, 2023); **E2** – (LORENÇÃO; SANTOS, 2021); **E3** – (CORREA, 2019); **E4** – (LUCENA, 2022); **E5** – (GOMES, 2022); e **E6** – (KELLERMANN; SCHMITT; MORAES, 2019).

A análise descritiva dos artigos selecionados permitiu identificar aspectos relevantes sobre o estado atual da literatura nacional no tema de sistemas de recomendação aplicados à leitura e à educação. Como todas as publicações selecionadas ocorreram em anos (Figura 1), isso pode indicar maior relevância e avanço na pesquisa de sistemas de recomendação no Brasil.

Além disso, a análise das instituições e locais de publicação dos artigos mostrou os principais polos de pesquisa no tema, destacando as regiões brasileiras mais engajadas na área de sistemas de recomendação educacionais (sul e sudeste).




Figura 1 – Linha Temporal dos artigos

3.2 Análise das questões de pesquisa

A partir da leitura integral dos 6 artigos aprovados na avaliação de qualidade, podemos responder às questões de pesquisa.

QP1: Em qual contexto e como os sistemas de recomendação foram implementados?

O artigo E1 apresenta um sistema de recomendação de leitura, enquanto o artigo E2 apresenta um sistema de recomendação de música, E3 e E6 de materiais didáticos, e E4 e E5 de matrizes horárias.

No estudo E1, o sistema de recomendação foi implementado por meio de um *plugin* desenvolvido para a plataforma Moodle. Esse *plugin* integra-se a uma base de dados de periódicos de acesso aberto, permitindo a identificação do conteúdo do material didático fornecido pelo docente e a sugestão de artigos científicos relevantes como leitura complementar para os alunos.

Em E2, o sistema foi implementado utilizando uma abordagem híbrida, a qual combina técnicas de filtragem colaborativa e baseada em conteúdo. Para integrar os diferentes métodos de recomendação, foram empregadas as abordagens ponderada e mista. A implementação foi realizada como um serviço web RESTful, possibilitando fácil integração com outras aplicações.

No artigo E3, o sistema desenvolvido fundamenta-se na teoria das inteligências múltiplas de Howard Gardner e nos estilos de aprendizagem de Honey-Alonso. Para a identificação do perfil de cada estudante, são utilizados o Inventário das Inteligências Múltiplas de Armstrong e o Questionário de Estilos de Aprendizagem de Honey-Alonso. Com base nessas informações, o sistema gera recomendações personalizadas de estratégias de estudo e recursos didáticos, alinhadas às preferências e habilidades individuais dos alunos.

Nos estudos E4 e E5, o sistema desenvolvido emprega técnicas de recomendação para sugerir matrizes horárias semestrais personalizadas aos estudantes, analisando dados como histórico acadêmico, pré-requisitos de disciplinas e preferências dos alunos para gerar recomendações mais adequadas ao progresso acadêmico.

Por fim, no estudo E6, o sistema foi implementado como um *plugin* para o Moodle, utilizando técnicas de recomendação para agrupar estudantes com base em seus perfis e conhecimentos prévios. Além disso, a ferramenta sugere recursos educacionais alinhados a temas transversais em discussão, analisando dados dos usuários no ambiente virtual de aprendizagem para fornecer recomendações personalizadas.

QP2: Quais dados dos usuários foram utilizados para realizar a recomendação?

O artigo E1 não menciona a coleta de dados pessoais dos usuários para a geração de recomendações. Em vez disso, as sugestões são baseadas no conteúdo do material didático



disponibilizado pelo docente no Moodle, indicando artigos científicos correlatos como leitura complementar.

No estudo de caso apresentado em E2, foram utilizados dados de avaliações musicais feitas pelos usuários, incluindo notas atribuídas a diferentes faixas. Essas avaliações serviram de base para que o sistema identificasse padrões e preferências, possibilitando a geração de recomendações personalizadas.

Em E3, os dados coletados estavam relacionados às inteligências múltiplas e aos estilos de aprendizagem dos estudantes. Para isso, foram aplicados instrumentos específicos, como o Inventário das Inteligências Múltiplas de Armstrong, que avalia as inteligências predominantes em cada indivíduo, e o Questionário de Estilos de Aprendizagem de Honey-Alonso, que identifica as preferências de aprendizagem dos alunos. Com essas informações, o sistema pôde traçar perfis personalizados e fornecer recomendações adaptadas às necessidades de cada estudante.

No contexto de E4 e também de E5, o sistema de recomendação considera informações acadêmicas dos estudantes, tais como disciplinas já cursadas, notas obtidas e dados sobre pré-requisitos e co-requisitos das disciplinas do curso. Com base nesses fatores, o sistema sugere matrizes horárias alinhadas ao progresso acadêmico e às necessidades individuais de cada aluno, permitindo a sugestão de uma matriz horária que favoreça um percurso acadêmico coerente e eficiente.

Por fim, o sistema descrito em E6 realiza recomendações a partir da coleta de dados sobre os perfis dos estudantes, incluindo informações sobre conhecimentos prévios, interações no ambiente virtual de aprendizagem e preferências de estudo. Esses dados possibilitam a formação de grupos homogêneos ou heterogêneos, conforme a necessidade pedagógica, além da indicação de materiais de aprendizagem alinhados aos interesses e demandas dos alunos.

QP3: Como os sistemas de recomendação foram validados?

A validação inicial do sistema no estudo E1 foi realizada por meio da experimentação do *plugin* pelos próprios desenvolvedores, que identificaram seu potencial para oferecer recomendações relevantes de artigos científicos. No entanto, o artigo ressalta que o *plugin* ainda não foi submetido à validação por docentes e discentes, evidenciando a necessidade de avaliações futuras para confirmar sua eficácia no ambiente educacional.

No estudo E2, a validação ocorreu por meio de um estudo de caso baseado em avaliações de músicas. O algoritmo de filtragem híbrida ponderada obteve um índice de acerto de 81,4% nas recomendações. Além disso, análises estatísticas, como o teste t, indicaram que as médias das recomendações foram estatisticamente equivalentes às médias das avaliações reais dos usuários, demonstrando a eficácia do sistema.

No artigo E3, a validação do sistema foi conduzida por meio de aplicação prática junto a estudantes da disciplina de Lógica de Programação. A análise dos dados coletados possibilitou a reflexão sobre os processos de ensino e de aprendizagem e subsidiou ações para o desenvolvimento de competências e habilidades. Os resultados apontaram que o sistema pode contribuir para a redução da evasão e o aumento da taxa de aprovação na disciplina.

A validação do sistema em E4 e em E5 foi realizada por meio de testes com um grupo de 14 estudantes de uma universidade pública. Para avaliar a usabilidade do sistema, foi aplicado o *System Usability Scale* (SUS), além da coleta de sugestões e pontos de melhoria. Os resultados indicaram boa aceitação do projeto, evidenciando a eficácia do sistema no auxílio ao planejamento das trajetórias acadêmicas dos estudantes.

No estudo E6, a validação ocorreu por meio de testes simulados, cujos resultados indicaram a relevância e a utilidade da ferramenta na abordagem de temas transversais no ensino superior. Os achados sugerem que o sistema pode contribuir para a prática da



transdisciplinaridade, facilitando a formação de grupos de estudantes e a recomendação de materiais de aprendizagem adequados.

3.3 Discussão

A análise dos seis artigos selecionados (E1 a E6) revelou tendências importantes sobre a aplicação de sistemas de recomendação no contexto educacional. Embora a literatura sobre sistemas de recomendação no ensino seja crescente, a maioria dos estudos se concentra em aspectos gerais do processo educativo, enquanto poucos se dedicam especificamente à recomendação de leitura. Essa lacuna evidencia a necessidade de maior produção científica voltada à promoção da leitura personalizada, sobretudo considerando a importância dessa habilidade para o desenvolvimento cognitivo e acadêmico dos estudantes.

Dos seis estudos analisados, todos foram implementados em ambientes web, o que reforça a consolidação dessa abordagem tecnológica no meio educacional. As linguagens, bibliotecas e *frameworks* utilizados variaram entre os estudos, mas tecnologias como *Python*, *JavaScript*, *frameworks* como *Django*, *Flask* e *React*, além de bancos de dados relacionais e *NoSQL*, foram os mais frequentes. Esse padrão demonstra que há um ecossistema de desenvolvimento relativamente bem estabelecido e apoiado por boas práticas amplamente difundidas.

Essa constatação é relevante para projetos futuros, pois a familiaridade com tais tecnologias pode facilitar a implementação de novas ferramentas. A experiência acumulada na área permite que desafios técnicos comuns sejam resolvidos com mais eficiência, otimizando os processos de desenvolvimento, validação e manutenção.

É interessante também mencionar que, observando os seis artigos selecionados (E1 a E6), houve a utilização de três das quatro principais técnicas de filtragem encontradas na literatura científica para sistemas de recomendação: filtragem colaborativa, filtragem por conteúdo, filtragem baseada em regras e abordagem híbrida. Esses resultados revelam uma distribuição equilibrada entre os tipos de algoritmos utilizados, o que sugere que os pesquisadores ainda estão explorando diferentes abordagens para alcançar maior precisão e personalização na recomendação de leituras.

No entanto, por meio da RSL realizada, constatasse a carência de uma análise mais minuciosa em relação às técnicas de filtragem utilizadas nos sistemas de recomendação implementados nos artigos, visando uma melhor avaliação das vantagens e desvantagens das técnicas escolhidas, como melhor detalhado nos próximos parágrafos.

A filtragem baseada em conteúdo (*Content-Based Filtering* – CBF) foca nas características intrínsecas dos itens e nas preferências individuais dos usuários. Esse método constrói perfis de usuário com base em interações anteriores e recomenda itens que compartilhem atributos semelhantes. Por exemplo, em uma plataforma de *streaming*, um usuário que aprecia filmes de ficção científica receberá recomendações de outros filmes desse gênero. Uma vantagem desse método é sua independência em relação à comunidade de usuários, já que a recomendação depende unicamente do histórico do indivíduo. No entanto, ele pode sofrer da limitação conhecida como "filtro de bolha", na qual o usuário é exposto apenas a conteúdos similares, restringindo sua diversidade de opções (LÜ et al., 2012).

Por sua vez, a filtragem colaborativa (*Collaborative Filtering* – CF) baseia-se na premissa de que usuários com padrões de comportamento semelhantes no passado tendem a compartilhar interesses no futuro. Essa abordagem é amplamente utilizada e se divide em dois subtipos: filtragem baseada em usuários, que encontra similaridades entre perfis de usuários, e filtragem baseada em itens, que avalia a similaridade entre itens baseando-se na interação dos usuários (KARYPIS, 2001). Embora a filtragem colaborativa seja poderosa em capturar preferências emergentes, enfrenta desafios como o "*cold start problem*" (dificuldade em



recomendar itens para novos usuários ou itens sem histórico) e a escassez de dados (quando há poucas interações para basear recomendações).

Os sistemas de recomendação baseados em regras utilizam heurísticas ou conhecimento especializado do domínio para criar recomendações. Essa abordagem pode ser manualmente projetada por especialistas ou automatizada por meio de regras definidas em sistemas. Por exemplo, em plataformas de e-commerce, recomendações de produtos complementares, como "os clientes que compraram este item também compraram", são baseadas em heurísticas simples, mas eficazes (ADOMAVICIUS; TUZHILIN, 2005). Embora sejam eficazes em cenários específicos, sistemas baseados em regras podem ser rígidos, apresentando dificuldades em capturar preferências dinâmicas ou padrões complexos.

Por fim, os sistemas híbridos combinam várias abordagens, como filtragem colaborativa, baseada em conteúdo e por regras, para melhorar a precisão e a robustez das recomendações. A integração entre os métodos permite explorar as vantagens de cada abordagem enquanto atenua suas limitações. Por exemplo, sistemas híbridos podem resolver o problema de "*cold start*" combinando informações demográficas (baseadas em regras) com filtragem colaborativa (RICCI; ROKACH; SHAPIRA, 2015). Estudos mostram que sistemas híbridos apresentam melhor desempenho em diversos contextos, como plataformas de *streaming* e e-commerce, fornecendo recomendações mais diversificadas e personalizadas (BURKE, 2002). Exemplos de aplicações incluem a Netflix, que utiliza uma combinação de algoritmos baseados em conteúdo e colaborativos para oferecer recomendações precisas e diversificadas.

Nesse sentido, como análise dos artigos apresentados na RSL em relação às técnicas de filtragem, ainda há bastante espaço para pesquisa e avanço observando a literatura científica nacional, tendo em vista que, embora no corpus documental apresentado na RSL tenha ocorrido a implementação de sistemas de recomendação utilizando três das quatro abordagens disponíveis (filtragem baseada em conteúdo, filtragem colaborativa e abordagem híbrida), os resultados apresentados e as análises realizadas nos artigos não endereçam os desafios anteriormente apresentados.

3.4 Ameaças à validade

Embora os critérios de inclusão e exclusão sejam fundamentais para selecionar um número viável de artigos para leitura integral, eles podem, inadvertidamente, excluir estudos que poderiam ser úteis. Por exemplo, a limitação à literatura em português exclui uma vasta quantidade de artigos disponíveis em inglês, que representam a maioria dos estudos na área. Isso reforça a necessidade de maior produção científica nacional sobre o tema. Além disso, as estratégias de busca precisaram ser adaptadas para atender às características específicas de cada base de dados. Algumas bases não permitem o uso de *strings* de busca complexas ou pesquisa por palavras-chave específicas. Outras não possibilitam filtrações por idioma, data de publicação ou outros critérios relevantes, o que pode ter limitado a abrangência da revisão.

4. Conclusão

A RSL revelou que, apesar de existirem estudos relevantes sobre sistemas de recomendação no contexto educacional, poucos tratam especificamente da recomendação de leitura. Essa constatação evidencia uma lacuna significativa e a necessidade de maior produção científica sobre o tema.

A maioria dos sistemas identificados foi desenvolvida em ambiente web, com uso de tecnologias bastante disseminadas, o que torna viável o desenvolvimento de novos sistemas



nessa área. Além disso, os dados utilizados e as metodologias de validação aplicadas fornecem um bom ponto de partida para projetos futuros.

Em relação aos desafios reportados nos artigos, destacaram-se questões relacionadas à coleta e uso dos dados dos usuários, dificuldades de adesão por parte dos estudantes e limitações técnicas nas fases iniciais de prototipagem. Tais desafios, no entanto, são amplamente conhecidos na área e podem ser mitigados com o uso de ferramentas consolidadas, práticas de usabilidade e validações iterativas com os usuários finais.

A análise crítica dos artigos evidencia que, apesar da escassez de estudos focados exclusivamente na recomendação de leitura, existe uma base promissora de pesquisas e soluções que podem ser adaptadas e expandidas. Isso reforça a pertinência e a oportunidade de desenvolvimento de novos sistemas com foco específico na leitura, considerando seu impacto comprovado na aprendizagem e na formação de leitores proficientes.

Referências

ADOMAVICIUS, G.; TUZHILIN, A. Toward the next generation of recommender systems: a survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, v. 17, n. 6, p. 734-749, 2005.

BARCELLOS, C. D.; MUSA, D. L.; BRANDÃO, A. L.; WARPECHOWSKI, M. Sistema de Recomendação Acadêmico para Apoio à Aprendizagem. *Revista Novas Tecnologias na Educação (RENOTE)*, Porto Alegre, v. 5, n. 2, 2007.

BRASIL. *MEC e Inep divulgam resultado do Censo da Educação Superior 2023*. Instituto Nacional de Estudos e Pesquisas Educacionais Anísio Teixeira, 29 nov. 2023. Disponível em: < <https://www.gov.br/inep/pt-br/assuntos/noticias/centso-da-educacao-superior/mec-e-inep-divulgam-resultado-do-censo-superior-2023> >. Acesso em: 30 nov. 2024.

BURKE, R. Hybrid recommender systems: Survey and experiments. *User Modeling and User-Adapted Interaction*, v. 12, n. 4, p. 331-370, 2002.

CARNEIRO, P. J. S.; SANTOS, A. T.; SANTOS, A. L.; SANTOS, G. A. B.; LUCENA, V. T. Uma Ferramenta para Realização de Gestão de Conhecimento e Recomendação Automática de Leituras em Fábricas de Software. In: CONGRESSO BRASILEIRO DE SOFTWARE: TEORIA E PRÁTICA (CBSOft), 2., 2008, Porto Alegre. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2008. p. 25–32.

CORREA, D. G. M. Desenvolvimento de um sistema de recomendação baseado na teoria das inteligências múltiplas para o ensino de lógica de programação. São José dos Campos: ICT/Unifesp, 2019. 116p. Dissertação de Mestrado.

DERMEVAL, D.; VILELA, J.; BITTENCOURT, I. I.; CASTRO, J.; ISOTANI, S.; BRITO, P.; SILVA, A. Applications of ontologies in requirements engineering: a systematic review of the literature. *Requirements Engineering*, 21(4), 405-437, 2016

ESTATÍSTICA FÁCIL. *O que é sistemas de recomendação?* Estatística Fácil, 2024. Disponível em: < <https://estatisticafacil.org/glossario/o-que-e-sistemas-de-recomendacao/> >. Acesso em: 10 jan. 2025.

FLAVELL, J. H. Metacognition and cognitive monitoring: A new area of cognitive–



developmental inquiry. *American Psychologist*, v. 34, n. 10, p. 906-911, 1979.

FOWLER, M. *Patterns of Enterprise Application Architecture*. Boston: Addison-Wesley, 2019.

GOMES, P. S. Sistema de recomendação de trajetórias curriculares para discentes do curso de Bacharelado em Engenharia de Computação do ICT-UNIFESP. São José dos Campos: ICT/Unifesp, 2022. Trabalho de Conclusão de Curso.

GUTIÉRREZ, J. M.; SCHMIDT, A. M.; LOPES, J. C. Adaptive learning: Technologies and methodologies in education. *Educational Technology & Society*, v. 22, n. 2, p. 37-45, 2019.

JORNAL DA USP. *A educação ao redor do mundo e um mundo novo a ser construído*. Jornal da USP, 23 nov. 2023. Disponível em: < <https://jornal.usp.br/artigos/a-educacao-ao-redor-do-mundo-e-um-mundo-novo-a-ser-construido/> >. Acesso em: 30 nov. 2024.

JULIANI, J. P.; DONHA, R. D. G. Sistemas de Recomendação de Artigos Científicos: Integrando o Moodle com uma Base de Dados de Acesso Aberto. *EaD em Foco*, v. 13, n. 1, p. 2027, 2023. Disponível em: < <https://eademfocoeademfoco.cecierj.edu.br/index.php/Revista/article/view/2027> >. Acesso em: 28 jan. 2025.

KARYPIS, G. Evaluation of item-based top-n recommendation algorithms. In: Proceedings of the tenth international conference on Information and knowledge management. New York: ACM, 2001. p. 247-254.

KELLERMANN, D.; SCHMITT, M. A. R.; MORAES, M. A. C. Desenvolvimento de um sistema de recomendação de grupos e recursos para apoio à abordagem de temas transversais. *RENTE*, Porto Alegre, v. 17, n. 1, p. 415-424, 2019. Disponível em: < <https://seer.ufrgs.br/index.php/rente/article/view/95849> >. Acesso em: 28 jan. 2025.

KING HOST. *Aplicação web: o que é e como funciona?* King Host, 2023. Disponível em: < <https://king.host/blog/tecnologia/aplicacao-web/> >. Acesso em: 30 nov. 2024.

KITCHENHAM, B.; CHARTERS, S. Guidelines for performing Systematic Literature Reviews in Software Engineering. *EBSE Technical Report*, v. 2, n. 1, p. 1-57, 2007.

LORENÇÃO, H. S.; SANTOS, R. V. M. Elaboração de um serviço de Recomendação Híbrido Ponderado e Misto implantado em Webservice RESTful. In: ENCONTRO NACIONAL DE COMPUTAÇÃO DOS INSTITUTOS FEDERAIS (ENCompIF), 8., 2021, Evento Online. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação, 2021. p. 49-56.

LUCENA, T. B. S. Recomendação de trajetórias curriculares para o curso de Bacharelado em Ciência da Computação do ICT - Unifesp: Um sistema computacional de auxílio aos discentes. São José dos Campos: ICT/Unifesp, 2022. 101p. Trabalho de Conclusão de Curso.

LÜ, L.; MEDO, M.; YEUNG, C. H.; ZHANG, Y. C.; ZHANG, Z. K.; ZHOU, T. Recommender systems. *Physics Reports*, v. 519, n. 1, p. 1-49, 2012.



PINTRICH, P. R. The role of metacognitive knowledge in learning, teaching, and assessing. *Theory Into Practice*, v. 41, n. 4, p. 219-225, 2002.

RICCI, F.; ROKACH, L.; SHAPIRA, B. *Recommender Systems Handbook*. 2. ed. Boston: Springer, 2015.

SILVA, J.; PEREIRA, M. Uma proposta para classificação baseada em contexto para sistemas de recomendação. In: SIMPÓSIO BRASILEIRO DE SISTEMAS MULTIMÍDIA E WEB (WEBMEDIA), 20., 2014, João Pessoa. Anais [...]. Porto Alegre: Sociedade Brasileira de Computação. p. 123-134.

SILVA, J.; PEREIRA, M. MAÎTRE: Motor de Recomendação para Dispositivos Móveis. *Revista Eletrônica de Graduação*, v. 10, n. 2, p. 123-145, 2024. Disponível em: < <https://revistaseletronicas.pucrs.br/graduacao/article/view/8809> >. Acesso em: 28 jan. 2025.

TIWARI, S.; GUPTA, A. A systematic literature review of use case specifications research. *Information and Software Technology*, v. 67, p. 128-158, 2015.

TRANFIELD, D.; DENYER, D.; SMART, P. Towards a methodology for developing evidence-informed management knowledge by means of systematic review. *British Journal of Management*, v. 14, n. 3, p. 207-222, 2003.

WIERINGA, R.; MAIDEN, N.; ROLLAND, N. M. C. Requirements engineering paper classification and evaluation criteria: a proposal and a discussion. *Requirements engineering*, v. 11, p. 102-107, 2006.

ZIMMERMAN, B. J. Becoming a self-regulated learner: An overview. *Theory Into Practice*, v. 41, n. 2, p. 64-70, 2002.