

Além da Busca por Palavras-Chave: Um Sistema de Perguntas e Respostas para Exploração Semântica do Acervo do SBIE

Alexya Silva¹, Marcelo Machado¹

¹Laboratory of Innovative Applications in Computing (LApIC)
Federal University of Juiz de Fora (UFJF)
Juiz de Fora – MG – Brazil

alexya.jesus@estudante.ufjf.br, marcelo.machado@ufjf.br

Abstract. *The proceedings of the Brazilian Symposium on Computers in Education (SBIE) constitute an important source of scientific knowledge, yet access to this content still relies predominantly on keyword-based search, limiting semantic exploration. This paper presents sbie-qa, a Retrieval-Augmented Generation (RAG) question-answering system that enables semantic exploration of SBIE proceedings through natural language queries. An exploratory evaluation recovered the gold document in 64.3% of the evaluated questions and produced satisfactory or partially satisfactory answers for most queries. The results indicate that conversational access can complement keyword-based search while revealing challenges related to document retrieval and answer generation.*

Resumo. *Os anais do Simpósio Brasileiro de Informática na Educação (SBIE) constituem uma importante fonte de conhecimento científico, mas seu acesso ainda depende de buscas por palavras-chave, limitando a exploração semântica do acervo. Neste trabalho, apresentamos o sbie-qa, um sistema de perguntas e respostas baseado em Retrieval-Augmented Generation (RAG) para exploração dos anais do SBIE por meio de consultas em linguagem natural. Em uma avaliação exploratória, o sistema recuperou o artigo-ouro em 64,3% das perguntas e produziu respostas satisfatórias ou parcialmente satisfatórias para a maioria das consultas. Os resultados indicam que a abordagem complementa a busca por palavras-chave, embora ainda apresente desafios relacionados à recuperação documental e à geração de respostas.*

1. Introdução

O Simpósio Brasileiro de Informática na Educação (SBIE), promovido pela Comissão Especial de Informática na Educação (CEIE) da Sociedade Brasileira de Computação (SBC), é um dos principais eventos científicos da América Latina na interface entre Informática e Educação. Seus anais, disponíveis no portal SBC Openlib (SOL)¹, reúnem centenas de artigos sobre temas como aprendizagem colaborativa, objetos de aprendizagem, jogos educacionais, *learning analytics*, inteligência artificial, acessibilidade, entre outros [Procaci et al., 2015, Semaan et al., 2019].

Apesar da riqueza desse acervo, o sistema de busca da SOL depende predominantemente de estratégias lexicais aplicadas a títulos e resumos, dificultando consultas exploratórias em linguagem natural. Assim, perguntas como “*como jogos educacionais têm sido aplicados no ensino de matemática?*” frequentemente exigem múltiplas

¹SBC Openlib: <https://sol.sbc.org.br>

reformulações e análise manual de resultados até que informações relevantes sejam encontradas. Esse problema torna-se ainda mais evidente em situações de ASK (*Anomalous State of Knowledge*) [Belkin, 1980], nas quais o usuário possui uma necessidade informacional, mas ainda não consegue expressá-la por meio de termos de busca.

Ferramentas tradicionais de recuperação da informação apresentam limitações para interpretar consultas em linguagem natural, especialmente quando há incompatibilidade entre os termos utilizados pelo usuário e aqueles presentes nos documentos indexados [Hambarde et al., 2023, Kiepora et al., 2025]. Avanços recentes em Inteligência Artificial Generativa (GenAI), especialmente com os Grandes Modelos de Linguagem (LLMs), abriram novas possibilidades para superar essas limitações por meio de interfaces conversacionais e mecanismos de busca semântica [Fan et al., 2024]. Entretanto, LLMs puros ainda sofrem com problemas como alucinações e dificuldade em justificar suas respostas com evidências verificáveis [Huang et al., 2025, Rahman et al., 2026].

Para lidar com essas limitações, a abordagem de *Retrieval-Augmented Generation* (RAG) [Lewis et al., 2020] combina recuperação documental com geração textual contextualizada. Diferentemente de um LLM puro, sistemas RAG fundamentam suas respostas em documentos previamente indexados, reduzindo alucinações e permitindo a apresentação de evidências textuais.

Neste trabalho, apresentamos o *sbie-qa*², um sistema de perguntas e respostas baseado em RAG construído para os anais do SBIE. O *sbie-qa* permite consultas em linguagem natural, recuperando trechos relevantes dos artigos e gerando respostas contextualizadas a partir desses trechos. Para avaliar a viabilidade da solução, foi selecionado um subconjunto de artigos e elaborado um conjunto de perguntas exploratórias que posteriormente foram respondidas por dois especialistas para servir como referência na avaliação. O *sbie-qa* é agnóstico ao modelo de linguagem utilizado, porém a avaliação experimental foi conduzida utilizando o Llama-3.3-70B, escolhido por ser um modelo *open-source*, amplamente adotado pela comunidade e disponível para implantação em diferentes ambientes, favorecendo a reprodutibilidade da arquitetura proposta.

Os resultados indicam que a abordagem é promissora para ampliar as formas de acesso e exploração semântica do acervo do SBIE, ao mesmo tempo que evidenciam desafios relacionados à recuperação documental e à geração de respostas. Além de ampliar as possibilidades de recuperação de informação em um contexto acadêmico, a proposta demonstra potencial para apoiar experiências de busca alinhadas ao paradigma de Busca como Processo de Aprendizagem (*Search as Learning* – SAL) [Machado et al., 2019], no qual a busca é compreendida como parte integrante da construção do conhecimento.

O restante do artigo está organizado da seguinte forma: a Seção 2 apresenta fundamentos sobre recuperação da informação, busca semântica, RAG e SAL; a Seção 3 discute trabalhos relacionados; a Seção 4 descreve a arquitetura do *sbie-qa*; a Seção 5 apresenta o método de avaliação e os resultados encontrados; a Seção 6 discute os principais achados; e, finalmente, a Seção 7 conclui o trabalho e apresenta perspectivas futuras.

2. Fundamentação Teórica

Esta seção apresenta os principais conceitos que fundamentam a proposta deste trabalho. Inicialmente, são discutidos aspectos relacionados à recuperação de informação e busca

²Todos os artefatos estão disponíveis em: <https://github.com/lapic-ufjf/sol-qa>

semântica, seguidos pela abordagem de RAG.

2.1. Recuperação de Informação e Busca Semântica

A Recuperação de Informação (IR) reúne técnicas para indexar e recuperar documentos relevantes a partir de consultas de usuários. Em sistemas tradicionais de IR, consultas e documentos são representados como conjuntos de termos, e a relevância é estimada pela correspondência lexical entre consulta e documento [Schütze et al., 2008]. Métodos clássicos como TF-IDF e BM25 [Robertson and Zaragoza, 2009], amplamente utilizados em mecanismos de busca baseados em Lucene e Elasticsearch [Gormley and Tong, 2015, McCandless et al., 2010], dependem fortemente da sobreposição textual entre termos. Como consequência, consultas em linguagem natural ou com terminologias diferentes daquelas presentes nos documentos podem apresentar limitações na recuperação de informação [Guo et al., 2020].

Com os avanços recentes em modelos neurais de linguagem, sistemas modernos de busca semântica passaram a utilizar *embeddings* vetoriais para representar consultas e documentos em espaços vetoriais contínuos. Nessa abordagem, textos semanticamente semelhantes ocupam regiões próximas no espaço vetorial, permitindo recuperar documentos relevantes mesmo sem correspondência exata entre palavras-chave [Reimers and Gurevych, 2019]. A recuperação baseada em *embeddings*, frequentemente chamada de *dense retrieval*, utiliza medidas de similaridade vetorial para identificar documentos semanticamente relacionados à consulta [Karpukhin et al., 2020]. Trabalhos recentes mostram que abordagens desse tipo apresentam melhor desempenho em consultas em linguagem natural e recuperação exploratória de informação [Zhao et al., 2024], motivo pelo qual técnicas de busca semântica têm sido amplamente incorporadas em pipelines modernos de RAG.

2.2. Geração Aumentada por Recuperação (RAG)

Retrieval-Augmented Generation (RAG) é um paradigma introduzido por [Lewis et al., 2020] que combina módulo de recuperação de documentos com um módulo de geração de texto. Dada uma consulta q , o módulo de recuperação seleciona os k documentos mais relevantes D_k de uma base de conhecimento $\mathcal{C}$. Em seguida, o LLM gera uma resposta r condicionada em (q, D_k) . Formalmente

$$r = \text{LLM}(q, D_k), \quad D_k = \text{Top-}k(\text{Ret}(q, \mathcal{C})) \quad (1)$$

Podemos dividir os sistemas de RAG em duas grandes categorias: (i) *RAG Simples* que segue fluxo de indexação $\rightarrow$ recuperação $\rightarrow$ geração; (ii) *RAG Avançado* que incorpora etapas de pré-recuperação (expansão de consulta, geração de múltiplas consultas) e pós-recuperação (re-ranqueamento, compreensão de contexto).

Embora o sbie-qa utilize geração em etapa única (*single-shot generation*), sua arquitetura de recuperação caracteriza um pipeline de RAG Avançado, uma vez que incorpora expansão de consultas por LLM, recuperação híbrida (BM25 + busca vetorial), fusão de resultados e re-ranqueamento com *cross-encoders*.

Na fase de indexação, os documentos da base de conhecimento são processados e armazenados em estruturas que permitem recuperação eficiente. O processo inicia com a extração e limpeza do conteúdo textual dos documentos originais. Em seguida, os textos são segmentados em unidades menores denominadas *chunks*, pois LLMs possuem janelas

de contexto limitadas e a recuperação de trechos menores tende a ser mais precisa do que a de documentos inteiros. Estratégias comuns de segmentação incluem janelas deslizantes com sobreposição que preservam continuidade semântica entre segmentos adjacentes, e segmentação por estrutura lógica do documento, como parágrafos e seções [Gao et al., 2023b]. Cada segmento é então convertido em uma representação vetorial densa, os chamados *embedding*, por um modelo de linguagem especializado, e armazenado em uma base vetorial (ChromaDB³) junto aos metadados originais (título, fonte). Essa base vetorial permite consultas por similaridade semântica.

O módulo de recuperação pode utilizar de diferentes estratégias. A recuperação densa representa documentos e consultas como vetores em um espaço semântico contínuo, calculando similaridade por produto interno ou distância cosseno [Karpukhin et al., 2020]; A recuperação esparsa, como o modelo BM25 [Robertson and Zaragoza, 2009], pondera termos por frequência e raridade na base, sendo eficaz para correspondências lexicais precisas. A recuperação híbrida combina os dois, beneficiando-se da complementaridade entre correspondência lexical (BM25) e semântica (*embeddings*) resultando em maior cobertura e precisão [Gao et al., 2023a]. Após a recuperação inicial, as técnicas de re-ranqueamento com *cross-encoders* [Nogueira and Cho, 2019] reordenam os candidatos de forma mais precisa, pois calculam a pontuação de relevância de forma conjunta para o par consulta-documento, ao custo de maior latência.

A expansão de consulta por LLM *query rewriting* gera múltiplas variações da pergunta original, aumentando a cobertura semântica da recuperação [Ma et al., 2023]. A principal motivação para a expansão de consulta é mitigar a divergência de termos utilizados por usuários e aqueles presentes nos documentos.

Por fim, na etapa de geração de resposta os segmentos recuperados são fornecidos ao LLM como contexto, juntamente a pergunta original. O LLM é instruído a responder utilizando exclusivamente a base fornecida, reduzindo a chance de alucinações. Desse modo, a qualidade da geração depende diretamente da qualidade da recuperação, portanto, quando as informações relevantes estão ausentes no contexto, o modelo produz respostas imprecisas ou inventadas [Huang et al., 2025]. Outro acontecimento que pode prejudicar a qualidade da geração de respostas é o *lost in the middle* [Liu et al., 2024], no qual informações críticas presentes nos segmentos não são adequadamente aproveitadas pelo modelo devido à sua posição intermediária no contexto.

2.3. A Busca como um Processo de Aprendizagem

Embora sistemas de Recuperação da Informação (RI) tenham sido tradicionalmente desenvolvidos para localizar documentos relevantes a partir de consultas, pesquisas na interseção entre RI e Educação reconhecem que a busca também constitui um processo de aprendizagem [Machado et al., 2019, Rieh et al., 2016, Urgo and Arguello, 2025, Vakari, 2016]. Essa perspectiva, denominada *Search as Learning*, compreende que atividades como formular consultas, analisar resultados, reformular perguntas e navegar entre documentos contribuem para a construção de conhecimento pelo usuário.

No contexto de SAL, o aprendizado ocorre ao longo do próprio processo de busca, especialmente em tarefas exploratórias e abertas [Collins-Thompson et al., 2017]. Tal perspectiva é particularmente relevante em situações de ASK [Belkin, 1980], nas quais

³<https://www.trychroma.com/>

o usuário possui uma necessidade informacional, mas ainda não consegue expressá-la adequadamente por meio de palavras-chave.

Nesse cenário, abordagens baseadas em LLMs e RAG apresentam potencial para apoiar experiências de busca mais alinhadas aos princípios de SAL. Ao permitir consultas em linguagem natural e gerar respostas contextualizadas fundamentadas em documentos científicos, sistemas dessa natureza podem favorecer processos exploratórios de aprendizagem e reduzir limitações associadas à busca tradicional baseada em palavras-chave [Collins-Thompson et al., 2017, White, 2016]. Assim, o *sbie-qa* é concebido não apenas como um mecanismo de RI, mas também como uma ferramenta de apoio à exploração semântica e à construção de conhecimento sobre os anais do SBIE.

3. Trabalhos Relacionados

A crescente disponibilidade de acervos científicos digitais tem impulsionado o desenvolvimento de ferramentas voltadas ao apoio da recuperação e exploração de literatura acadêmica. Nesse cenário, diferentes abordagens vêm sendo propostas tanto para automatizar tarefas relacionadas à busca documental quanto para permitir formas mais flexíveis de interação com coleções científicas.

No contexto da plataforma SOL, o trabalho mais relevante para a presente proposta é o de Souza et al. [2024], que introduz a ferramenta *pySol* para automatização de buscas e exportação de resultados da plataforma. O trabalho parte da constatação de que o mecanismo de busca da SOL apresenta limitações operacionais importantes, especialmente em cenários de revisões sistemáticas da literatura, nos quais pesquisadores precisam executar buscas repetitivas e exportar manualmente referências bibliográficas. Para lidar com esse problema, os autores desenvolveram uma ferramenta baseada em *web scraping* capaz de automatizar consultas na SOL e exportar resultados em formato BibTeX, contribuindo para aumentar a reprodutibilidade e reduzir o esforço necessário em revisões sistemáticas [Souza et al., 2024].

Embora o *pySol* represente um avanço importante no acesso automatizado ao conteúdo da SOL, sua proposta permanece centrada em buscas lexicais baseadas em palavras-chave previamente definidas pelo usuário, não contemplando consultas em linguagem natural nem mecanismos de exploração semântica do acervo.

Em paralelo, o crescimento recente de ferramentas baseadas em GenAI tem transformado a forma como pesquisadores acessam e analisam literatura científica. Técnicas de recuperação semântica e modelos de linguagem passaram a permitir interações mais próximas da linguagem natural, reduzindo parte das limitações presentes em mecanismos tradicionais de busca acadêmica. Plataformas como Semantic Scholar [Ammar et al., 2018], Scite [Nicholson et al., 2021], Elicit [Whitfield and Hofmann, 2023], OpenScholar [Asai et al., 2024] e, mais recentemente, NotebookLM do Google⁴ passaram a incorporar mecanismos de perguntas e respostas, recuperação documental, geração textual para apoiar tarefas de descoberta, sumarização e exploração de artigos científicos.

Grande parte dessas plataformas opera sobre bases científicas internacionais e de propósito geral, como ACM Digital Library, IEEE Xplore e arXiv. Embora esses ecossistemas disponibilizem mecanismos avançados de indexação e recuperação, ainda existem poucas iniciativas direcionadas à exploração semântica de repositórios científicos naci-

⁴Google NotebookLM: <https://notebooklm.google.com/>

onais especializados, como a SOL. Além disso, um ponto crítico, é que muitas dessas soluções dependem de infraestruturas proprietárias, o que pode introduzir restrições relacionadas a custo, privacidade de dados e dependência tecnológica.

Diferentemente dessas abordagens, o presente trabalho investiga o uso de RAG sobre os anais do SBIE com o objetivo de permitir consultas em linguagem natural fundamentadas diretamente nos documentos recuperados. Em vez de apenas automatizar buscas ou exportação de resultados, o `sbie-qa` busca atuar como uma ferramenta de perguntas e respostas especializada, capaz de recuperar evidências relevantes nos artigos e gerar respostas contextualizadas a partir do conteúdo científico indexado. Além disso, a solução proposta é baseada exclusivamente em tecnologias *open-source*, favorecendo reprodutibilidade, redução de dependência de serviços proprietários e implantação institucional de baixo custo.

4. SBIE-QA

O `sbie-qa` é implementado como uma biblioteca *Python* com uma interface de linha de comando (CLI) que expõe três subcomandos principais: `download`, `ingest` e `query`.

4.1. Download e Ingestão

O comando `download` dispara um pipeline de *web scraping* sobre o portal SOL, utilizando a biblioteca BeautifulSoup⁵ para navegação e extração das URLs dos artigos do SBIE. Os arquivos PDF recuperados passam por uma etapa de validação estrutural baseada no cabeçalho binário do documento, permitindo descartar arquivos corrompidos.

No processo de ingestão o texto dos artigos é extraído utilizando a biblioteca `pypdf`⁶, e então os documentos são segmentados utilizando uma estratégia de janela deslizante de 1.200 caracteres com sobreposição de 200 caracteres. Essa configuração busca equilibrar granularidade e preservação de contexto semântico entre segmentos adjacentes, reduzindo problemas de fragmentação de informação em pipelines RAG. Cada segmento é associado a metadados como título do artigo, edição do SBIE e posição do trecho no documento original, permitindo rastreabilidade das evidências recuperadas.

Os segmentos são convertidos em representações vetoriais utilizando o modelo BGE-M3 [Chen et al., 2024], disponibilizado pela BAAI via `sentence-transformers`⁷. A escolha do BGE-M3 foi motivada principalmente por seu suporte multilíngue, características importantes para um acervo heterogêneo como o do SBIE, que contém artigos em português, inglês e espanhol. Diferentemente de abordagens puramente lexicais, o modelo projeta textos semanticamente semelhantes em um mesmo espaço vetorial independentemente do idioma, reduzindo problemas de incompatibilidade terminológica entre consultas e documentos. Além disso, o BGE-M3 foi projetado para diferentes granularidades textuais e estratégias de recuperação, favorecendo a extensibilidade futura da arquitetura. Os *embeddings* gerados são armazenados no banco vetorial ChromaDB, escolhido por sua simplicidade de integração local e adequação a experimentos acadêmicos com recuperação semântica.

⁵<https://www.crummy.com/software/BeautifulSoup/>

⁶<https://pypdf.readthedocs.io/>

⁷<https://www.sbert.net/>

4.2. Pipeline de Perguntas e Respostas

A Figura 1 apresenta o pipeline de perguntas e respostas do *sbie-qa*. O fluxo inicia com a submissão de uma pergunta em linguagem natural pelo usuário (1) e termina com a geração de uma resposta contextualizada fundamentada nos artigos recuperados do acervo do SBIE (10). A arquitetura segue o paradigma de RAG, combinando mecanismos de recuperação semântica e geração textual baseada em LLMs.




Figura 1. Pipeline de perguntas e respostas do *sbie-qa*.

O primeiro componente do pipeline corresponde à etapa de reescrita da pergunta (*query rewriting*) (2). Nessa etapa, o sistema utiliza um LLM para gerar múltiplas variações semanticamente equivalentes da consulta original, ampliando a cobertura da recuperação documental [Ma et al., 2023]. Em nossa implementação, são geradas $n = 3$ variações da consulta utilizando um *prompt* em estilo acadêmico, que são posteriormente combinadas à pergunta original. O objetivo dessa estratégia é reduzir problemas de incompatibilidade terminológica entre a formulação utilizada pelo usuário e os termos presentes nos artigos indexados. As consultas expandidas são então utilizadas pela etapa de busca documental (3), que combina recuperação densa baseada em *embeddings* vetoriais com recuperação esparsa baseada em BM25 (4), caracterizando uma abordagem híbrida. Enquanto a busca vetorial permite identificar similaridade semântica entre consulta e documentos por meio de distância cosseno no ChromaDB, o BM25 contribui para recuperar correspondências lexicais exatas importantes em domínios acadêmicos. O índice BM25 é construído *on-the-fly* com a biblioteca `rank_bm25` [Brown, 2020], aplicando normalização Unicode para melhorar a correspondência em textos em português.

Os documentos recuperados pelas estratégias densa e esparsa são posteriormente fundidos e deduplicados (5), formando um *pool* de candidatos para a etapa de re-ranqueamento (6), na qual um modelo *cross-encoder* (BAAI/bge-reranker-base) avalia conjuntamente cada par consulta-documento para estimar sua relevância contextual [Nogueira and Cho, 2019]. Após o re-ranqueamento, apenas os segmentos mais relevantes são selecionados (7) e enviados ao módulo de geração de respostas (8). Nessa etapa, o LLM recebe a pergunta original e os trechos recuperados como contexto, sendo instruído, por meio de um *prompt*, a produzir respostas fundamentadas exclusivamente

nas evidências fornecidas pelos documentos recuperados. Além disso, o *prompt* instrui o modelo a responder sempre no mesmo idioma utilizado pelo usuário na consulta original, permitindo interações multilíngues de forma transparente. Por fim, a resposta gerada (9) é retornada ao usuário juntamente com os documentos utilizados como base para a geração (10), permitindo maior transparência e rastreabilidade do processo de resposta.

5. Avaliação e Resultados

Para avaliar o *sbie-qa*, foi construído um dataset composto por um subconjunto de artigos dos anais do SBIE obtido a partir de uma consulta pelo termo “Search as Learning” na SOL. A escolha desse tema foi motivada principalmente por sua aderência à proposta deste trabalho. SAL investiga o uso de mecanismos de busca como suporte à aprendizagem e à construção de conhecimento, perspectiva alinhada ao objetivo do *sbie-qa* de transformar a exploração do acervo do SBIE em uma experiência conversacional orientada à descoberta de informação.

Além da aderência temática, essa consulta representa um cenário ilustrativo das limitações do mecanismo de busca atualmente disponível na SOL. Embora a busca retorne artigos relacionados a SAL, diversos resultados recuperados tratam de tópicos apenas tangencialmente relacionados ao tema principal. O acervo utilizado é composto por 30 artigos, dos quais apenas seis abordam diretamente SAL. Entre eles estão trabalhos sobre mapeamentos sistemáticos da área [Gimenez et al., 2020, Machado et al., 2020], ontologias para busca colaborativa [Silva et al., 2021], vieses cognitivos em SAL [Machado et al., 2024], um framework experimental para SAL [Silva et al., 2025] e critérios de reordenação de resultados de busca [Teixeira et al., 2019]. Os demais artigos abordam outros tópicos da Informática na Educação, como jogos sérios [Almeida et al., 2024, Pereira et al., 2019], gamificação [Klock et al., 2015], mineração de dados educacionais [Silva and Nunes, 2015], realidade aumentada [Primo et al., 2024] e sistemas de recomendação [Júnior et al., 2020, 2023].

Os 30 artigos foram analisados por dois especialistas com experiência em Search as Learning e, a partir dessa leitura, foram elaboradas 14 perguntas representativas de consultas exploratórias em linguagem natural que um usuário poderia realizar sobre o acervo. Para cada pergunta foi definido um artigo-ouro, correspondente ao documento considerado pelos especialistas como a principal referência para responder à consulta.

A avaliação do *sbie-qa* considerou duas dimensões complementares: (i) verificar se o artigo-ouro era recuperado pelo módulo de recuperação; e (ii) avaliar a qualidade da resposta gerada. Para essa segunda dimensão, as respostas foram avaliadas independentemente pelos especialistas, considerando critérios de correção, completude e aderência às evidências recuperadas, utilizando uma escala ordinal de três níveis: 0 (insatisfatória), 1 (parcialmente satisfatória) e 2 (satisfatória). Nos casos de divergência, os avaliadores discutiram a classificação até alcançar um consenso.

Todos os experimentos foram conduzidos utilizando a configuração completa do *sbie-qa*, composta por recuperação híbrida, re-ranqueamento por *cross-encoder* e geração das respostas pelo modelo Llama-3.3-70B.

5.1. Resultados

A Tabela 1 apresenta os resultados obtidos para as 14 perguntas avaliadas. A coluna *Doc.* indica se o artigo-ouro foi recuperado pelo módulo de recuperação (S = sim; N = não),

enquanto a coluna *Sat.* apresenta a avaliação atribuída à resposta gerada pelos especialistas. Além disso, foram calculadas as métricas de *Precision*, *Recall* e *F1-score*, amplamente empregadas na avaliação de sistemas de recuperação da informação [Schütze et al., 2008]. Essas métricas foram calculadas para cada pergunta a partir da comparação entre o conjunto de documentos recuperados e o respectivo artigo-ouro, sendo posteriormente agregadas pela média aritmética.

Tabela 1. Resultados do sbie-qa em perguntas sobre *Search as Learning*.

ID	Pergunta	Doc.	Sat.
1	O que é <i>Search as Learning</i> ?	S	2
2	O que é viés cognitivo?	S	2
3	O que é aprendizagem informal?	S	0
4	O que é busca colaborativa?	S	2
5	O que é literacia digital?	N	0
6	O que é ontologia em sistemas educacionais?	N	2
7	Qual a definição de viés de confirmação?	S	2
8	Quais são as principais dimensões da área de SAL?	N	0
9	Quais as principais teorias de aprendizagem em SAL?	N	0
10	Quais as principais variáveis envolvidas na interação de busca como aprendizagem?	S	2
11	Quais seriam os principais critérios de relevância para reordenar resultados de busca?	S	2
12	Quais sistemas existem para execução de experimentos em SAL?	S	1
13	O que são Recursos Educacionais Abertos (REAs)?	N	0
14	O que são Sistemas Tutores Inteligentes (STIs)?	S	2

Artigo-ouro recuperado	Sat. média	Precision	Recall	F1-score
9/14 (64,3%)	1,21	0,536	0,643	0,571

Doc.: artigo-ouro recuperado (S/N). Sat.: 0 = insatisfatória; 1 = parcialmente satisfatória; 2 = satisfatória.

Em média, o módulo de recuperação obteve *Precision* de 0,536, *Recall* de 0,643 e *F1-score* de 0,571. O artigo-ouro foi recuperado em nove das quatorze perguntas avaliadas (64,3%), enquanto a satisfação média das respostas foi de 1,21.

Entre as perguntas avaliadas, sete apresentaram simultaneamente recuperação do artigo-ouro e satisfação máxima (IDs 1, 2, 4, 7, 10, 11 e 14). Em um único caso (ID 6), a resposta recebeu satisfação máxima mesmo sem a recuperação do artigo-ouro. Por outro lado, cinco perguntas receberam satisfação zero, sendo uma delas com recuperação do artigo-ouro (ID 3) e quatro sem sua recuperação (IDs 5, 8, 9 e 13).

6. Discussão

Os resultados permitem analisar o desempenho do sbie-qa sob três perspectivas complementares: a eficácia da recuperação documental, a capacidade de geração de respostas contextualizadas e as limitações inerentes ao pipeline RAG adotado.

De forma geral, a combinação entre recuperação híbrida (BM25 e *embeddings* vetoriais), expansão de consultas e re-ranqueamento apresentou desempenho satisfatório em parte significativa das perguntas avaliadas. O artigo-ouro foi recuperado em 64,3%

das consultas, e sete perguntas apresentaram simultaneamente recuperação do artigo-ouro e satisfação máxima. Nesses casos, os trechos recuperados continham definições ou explicações diretamente relacionadas às perguntas formuladas, permitindo que o LLM produzisse respostas corretas e contextualizadas. Esse comportamento é consistente com estudos que apontam ganhos na recuperação em domínios especializados a partir da combinação entre recuperação lexical e semântica [Gao et al., 2023a, Nogueira and Cho, 2019].

Entretanto, os resultados também evidenciam que a qualidade da resposta permanece fortemente condicionada à qualidade da recuperação. As Perguntas 5, 6, 8, 9 e 13, nas quais o artigo-ouro não foi recuperado, compartilham uma característica em comum: os documentos relevantes utilizavam terminologias diferentes daquelas presentes nas consultas formuladas. Na Pergunta 5, por exemplo, o conceito aparecia predominantemente como *search literacy* (literacia de busca), enquanto a pergunta utilizava o termo “literacia digital”. Situação semelhante ocorreu na Pergunta 13, em que o artigo empregava principalmente a sigla REA. Esse fenômeno, conhecido como *vocabulary mismatch* [Guo et al., 2020], permanece um desafio importante mesmo em sistemas baseados em representações vetoriais, especialmente em domínios especializados e multilíngues.

Embora a expansão automática de consultas tenha contribuído para ampliar a cobertura da recuperação, observou-se que as reformulações produzidas permaneceram semanticamente próximas da pergunta original, sem incorporar terminologias técnicas presentes nos documentos. Esse comportamento ficou particularmente evidente nas Perguntas 5 e 13, sugerindo que mecanismos adicionais de expansão semântica, como ontologias de domínio, dicionários terminológicos ou bases estruturadas de conhecimento, podem representar caminhos promissores para aprimorar a recuperação documental.

Apesar dessa forte dependência da recuperação, os resultados mostram que a recuperação exata do artigo-ouro nem sempre é condição necessária para produzir respostas corretas. A Pergunta 6 constitui o exemplo mais representativo desse comportamento. Embora o artigo-ouro não tenha sido recuperado, o sistema identificou trechos semanticamente relacionados em outros artigos do acervo que descreviam adequadamente o papel das ontologias em contextos educacionais, permitindo que o LLM produzisse uma resposta considerada satisfatória. Esse resultado evidencia uma capacidade parcial de generalização semântica do pipeline, na medida em que o modelo foi capaz de sintetizar conhecimento distribuído em diferentes documentos [Lewis et al., 2020]. Em cenários exploratórios de busca acadêmica, essa característica é particularmente relevante, pois o objetivo do usuário frequentemente consiste em compreender determinado conceito, e não necessariamente localizar um documento específico.

Entretanto, esse comportamento não se repetiu nas Perguntas 8 e 9. Diferentemente de perguntas conceituais mais objetivas, essas consultas exigiam consolidar informações distribuídas em múltiplos artigos e estruturas conceituais distintas. Embora o sbie-qa utilize estratégias avançadas de recuperação e re-ranqueamento, a geração ocorre em um único ciclo de recuperação e síntese, sem mecanismos iterativos de planejamento ou refinamento. Como consequência, o sistema não conseguiu integrar adequadamente as diferentes evidências necessárias para responder a consultas de maior complexidade conceitual. Esse resultado reforça que perguntas analíticas permanecem particularmente desafiadoras para arquiteturas RAG *single-shot*.

Outro comportamento observado refere-se aos casos em que o artigo-ouro foi re-

cuperado, mas a resposta não atingiu qualidade satisfatória. As Perguntas 3 e 12 ilustram essa situação. Na Pergunta 3, a definição principal encontrava-se em um segmento adjacente separado pelo processo de *chunking*, levando o modelo a produzir uma resposta baseada apenas em contexto periférico. Fenômeno semelhante ocorreu parcialmente na Pergunta 12, cuja resposta recebeu satisfação intermediária. Esses casos ilustram limitações já discutidas na literatura relacionadas à fragmentação textual e ao fenômeno conhecido como *lost in the middle* [Liu et al., 2024], no qual informações relevantes presentes no contexto recuperado não são efetivamente aproveitadas pelo LLM.

Os resultados também mostram que métricas tradicionais de recuperação devem ser interpretadas com cautela em pipelines RAG. Embora a *Precision* média tenha sido de 0,536, sua relação com a qualidade da resposta não é direta. Nas Perguntas 1 e 14, por exemplo, a *Precision* foi de apenas 0,500, indicando que documentos adicionais foram recuperados além do artigo-ouro, mas ambas receberam satisfação máxima. Em contraste, a Pergunta 3 apresentou exatamente o mesmo valor de *Precision*, porém recebeu satisfação zero. Esses exemplos demonstram que a recuperação de documentos adicionais nem sempre prejudica a geração da resposta e que a presença do artigo-ouro, isoladamente, também não garante sucesso. Assim, embora métricas clássicas de recuperação permaneçam importantes para avaliar o módulo de busca, elas devem ser complementadas por métricas que considerem a qualidade da resposta produzida pelo sistema.

Por fim, as Perguntas 5, 8, 9 e 13 representam o cenário mais crítico observado na avaliação, pois o módulo de recuperação não conseguiu fornecer evidências suficientemente relevantes para fundamentar a geração. Nesses casos, o modelo produziu respostas incompletas ou incorretas, reforçando um dos principais desafios de sistemas RAG: a forte dependência da qualidade da recuperação documental. Quando o contexto recuperado é insuficiente, o LLM tende a produzir respostas inadequadas, mesmo quando explicitamente instruído a utilizar apenas as evidências fornecidas [Huang et al., 2025].

De forma mais ampla, os resultados reforçam que sistemas RAG voltados à exploração de literatura científica não devem ser avaliados exclusivamente pela recuperação exata de documentos, mas também por sua capacidade de apoiar processos exploratórios de construção de conhecimento. Sob a perspectiva de Search as Learning, o *sbie-qa* demonstra potencial para transformar os anais do SBIE em um ambiente de exploração semântica mais acessível e alinhado a cenários de ASK, complementando mecanismos tradicionais de busca ao favorecer descoberta, compreensão e navegação conceitual sobre o acervo científico da área.

7. Conclusão e Trabalhos Futuros

Este trabalho apresentou o *sbie-qa*, um sistema de perguntas e respostas baseado em RAG construído sobre os anais do SBIE disponíveis na plataforma SOL. A arquitetura proposta combina recuperação híbrida de documentos (BM25 e embeddings BGE-M3), expansão de consultas com LLMs, re-ranqueamento por *cross-encoder* e geração contextualizada de respostas, permitindo consultas em linguagem natural fundamentadas diretamente nos artigos do acervo.

A avaliação exploratória demonstrou que a abordagem é capaz de complementar mecanismos tradicionais de busca por palavras-chave, recuperando corretamente o artigo-ouro em 64,3% das perguntas avaliadas e produzindo respostas satisfatórias ou parcialmente satisfatórias para a maior parte das consultas. Mais do que demonstrar a viabilidade

técnica da arquitetura proposta, os resultados evidenciaram que a qualidade das respostas não depende exclusivamente da recuperação documental: em alguns casos, o sistema produziu respostas satisfatórias mesmo sem recuperar o artigo-ouro, enquanto, em outros, a recuperação do documento esperado não foi suficiente para garantir uma resposta adequada. Esses achados reforçam a importância de avaliar sistemas RAG considerando conjuntamente os módulos de recuperação e geração, em vez de analisar apenas métricas tradicionais de recuperação de informação.

Sob a perspectiva de *Search as Learning*, a principal contribuição deste trabalho consiste em transformar um acervo tradicionalmente acessado por buscas lexicais em um ambiente de exploração semântica apoiado por interação conversacional. Ao permitir consultas em linguagem natural fundamentadas nos documentos recuperados, o *sbie-qa* amplia as possibilidades de descoberta, compreensão e navegação conceitual sobre a literatura científica da área, especialmente em cenários nos quais os usuários ainda não conseguem expressar adequadamente sua necessidade informacional por meio de palavras-chave. O suporte multilíngue da proposta amplia ainda mais seu potencial de aplicação em acervos compostos por artigos em português, inglês e espanhol.

Além da arquitetura proposta, este trabalho contribui ao disponibilizar um protocolo de avaliação que considera simultaneamente a recuperação documental e a qualidade das respostas geradas. Essa estratégia permitiu identificar limitações distintas dos componentes de recuperação e geração e compreender situações em que ambos apresentam comportamentos divergentes. A utilização exclusiva de tecnologias *open-source* também amplia o potencial de adoção da proposta, favorecendo sua reprodutibilidade, adaptação e evolução por outras instituições sem dependência de serviços proprietários.

Os resultados devem ser interpretados considerando algumas limitações. A avaliação foi conduzida sobre um subconjunto do acervo do SBIE e um conjunto reduzido de perguntas, o que restringe a generalização dos resultados para todo o repositório. Além disso, a qualidade das respostas foi avaliada manualmente por dois especialistas, procedimento que pode introduzir subjetividade, embora tenha permitido uma análise qualitativa detalhada dos diferentes comportamentos observados.

Como trabalhos futuros, pretende-se ampliar a avaliação utilizando todo o acervo do SBIE e estudos envolvendo estudantes e pesquisadores em cenários reais de busca e aprendizagem. Também serão investigadas estratégias para reduzir incompatibilidades terminológicas por meio de expansão semântica baseada em ontologias e conhecimento estruturado, bem como arquiteturas RAG iterativas capazes de integrar evidências provenientes de múltiplos documentos. Nesse contexto, pretende-se incorporar ao processo de indexação uma base de conhecimento derivada dos próprios artigos. Espera-se, assim, combinar recuperação textual e recuperação baseada em conhecimento explícito para apoiar consultas mais precisas e melhorar a qualidade das respostas.

Em síntese, este trabalho demonstra que interfaces conversacionais fundamentadas em RAG podem ampliar as formas de acesso à produção científica da comunidade brasileira de Informática na Educação. Mais do que substituir mecanismos tradicionais de busca, o *sbie-qa* representa um passo em direção a ambientes de exploração semântica capazes de apoiar descoberta de informação, construção de conhecimento e aprendizagem a partir da literatura científica.

Uso de Inteligência Artificial

Os autores utilizaram ferramentas baseadas em IA para auxiliar no aprimoramento da linguagem e na correção gramatical. Todo o conteúdo científico, as decisões metodológicas, as interpretações e as conclusões foram desenvolvidos, revisados e aprovados de forma independente pelos autores, que assumem total responsabilidade pelo conteúdo final. Além disso, por se tratar de uma pesquisa relacionada a sistemas baseados em IA generativa, parte da avaliação experimental envolveu respostas produzidas por modelos de linguagem utilizados no pipeline do sistema proposto.

Referências

- Almeida, E., Feitosa, J., and Brega, J. (2024). Desenvolvimento de um jogo sério para ensino sobre os desafios de acessibilidade no contexto urbano. In *Anais do XXXV Simpósio Brasileiro de Informática na Educação*, pages 2673–2682, Porto Alegre, RS, Brasil. SBC.
- Ammar, W., Groeneveld, D., Bhagavatula, C., Beltagy, I., Crawford, M., Downey, D., Dunkelberger, J., Elgohary, A., Feldman, S., Ha, V., et al. (2018). Construction of the literature graph in semantic scholar. In *Proceedings of the 2018 Conference of the North American Chapter of the Association for Computational Linguistics: Human Language Technologies, Volume 3 (Industry Papers)*, pages 84–91.
- Asai, A., He, J., Shao, R., Shi, W., Singh, A., Chang, J. C., Lo, K., Soldaini, L., Feldman, S., D’arcy, M., Wadden, D., Latzke, M., Tian, M., Ji, P., Hu, S., Hu, Y., Hu, Z., Dasigi, P., Goyal, N., Zettlemoyer, L., Smith, N. A., Beltagy, I., and Hajishirzi, H. (2024). OpenScholar: Synthesizing scientific literature with retrieval-augmented LMs. *arXiv preprint arXiv:2411.10922*.
- Belkin, N. J. (1980). Anomalous states of knowledge as a basis for information retrieval. *Canadian journal of information science*, 5(1):133–143.
- Brown, D. (2020). rank_bm25: A collection of BM25 algorithms in python. https://github.com/dorianbrown/rank_bm25. Acesso em: 2026.
- Chen, J., Xiao, S., Zhang, P., Luo, K., Lian, D., and Liu, Z. (2024). Bge m3-embedding: Multi-lingual, multi-functionality, multi-granularity text embeddings through self-knowledge distillation. *arXiv preprint arXiv:2402.03216*, 4(5).
- Collins-Thompson, K., Hansen, P., and Hauff, C. (2017). Search as Learning (Dagstuhl Seminar 17092). *Dagstuhl Reports*, 7(2):135–162.
- Fan, W., Ding, Y., Ning, L., Wang, S., Li, H., Yin, D., Chua, T.-S., and Li, Q. (2024). A survey on rag meeting llms: Towards retrieval-augmented large language models. In *Proceedings of the 30th ACM SIGKDD conference on knowledge discovery and data mining*, pages 6491–6501.
- Gao, L., Ma, X., Lin, J., and Callan, J. (2023a). Precise zero-shot dense retrieval without relevance labels. In *Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics (Volume 1: Long Papers)*, pages 1762–1777.
- Gao, Y., Xiong, Y., Gao, X., Jia, K., Pan, J., Bi, Y., Dai, Y., Sun, J., Guo, Q., Wang, M., and Wang, H. (2023b). Retrieval-augmented generation for large language models: A survey. *arXiv preprint arXiv:2312.10997*.
- Gimenez, P., Machado, M., Pinelli, C., and Siqueira, S. (2020). Investigating the learning perspective of Searching as Learning, a review of the state of the art. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 302–311, Porto Alegre, RS, Brasil. SBC.

- Gormley, C. and Tong, Z. (2015). *Elasticsearch: the definitive guide: a distributed real-time search and analytics engine*. "O'Reilly Media, Inc."
- Guo, J., Fan, Y., Pang, L., Yang, L., Ai, Q., Zamani, H., Wu, C., Croft, W. B., and Cheng, X. (2020). A deep look into neural ranking models for information retrieval. *Information Processing & Management*, 57(6):102067.
- Hambarde, K. A. et al. (2023). Information retrieval: Recent advances and beyond. *IEEE Access*, 11:14800–14839.
- Huang, L., Yu, W., Ma, W., Zhong, W., Feng, Z., Wang, H., Chen, Q., Peng, W., Feng, X., Qin, B., et al. (2025). A survey on hallucination in large language models: Principles, taxonomy, challenges, and open questions. *ACM Transactions on Information Systems*, 43(2):1–55.
- Júnior, C. B., Dorça, F., Andrade, A., and Assis, L. (2020). Avanços na recomendação personalizada de objetos de aprendizagem através da utilização de meta-heurísticas clássicas associadas aos problemas de cobertura de conjuntos e de máxima cobertura: Uma análise experimental. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 1383–1392, Porto Alegre, RS, Brasil. SBC.
- Júnior, C. B., Dorça, F., Assis, L., and Vivas, A. (2023). Solving the individualized instructional content delivery problem using ontology and metaheuristics on the set covering problem: An experimental analysis. In *Anais do XXXIV Simpósio Brasileiro de Informática na Educação*, pages 1202–1214, Porto Alegre, RS, Brasil. SBC.
- Karpukhin, V., Oguz, B., Min, S., Lewis, P., Wu, L., Edunov, S., Chen, D., and Yih, W.-t. (2020). Dense passage retrieval for open-domain question answering. In *Proceedings of the 2020 conference on empirical methods in natural language processing (EMNLP)*, pages 6769–6781.
- Kiepora, A., Lam, J., Gu, N., and Hahnloser, R. (2025). Literature discovery with natural language queries. In *Proceedings of the Fifth Workshop on Scholarly Document Processing (SDP 2025)*, pages 83–95.
- Klock, A. C., Gasparini, I., Kemczinski, A., Hounsell, M., and Isotani, S. (2015). One man's trash is another man's treasure: um mapeamento sistemático sobre as características individuais na gamificação de ambientes virtuais de aprendizagem. In *Anais do XXVI Simpósio Brasileiro de Informática na Educação*, pages 539–548, Porto Alegre, RS, Brasil. SBC.
- Lewis, P., Perez, E., Piktus, A., Petroni, F., Karpukhin, V., Goyal, N., Küttler, H., Lewis, M., tau Yih, W., Rocktäschel, T., Riedel, S., and Kiela, D. (2020). Retrieval-augmented generation for knowledge-intensive NLP tasks. In *Advances in Neural Information Processing Systems (NeurIPS)*, volume 33, pages 9459–9474.
- Liu, N. F., Lin, K., Hewitt, J., Paranjape, A., Bevilacqua, M., Petroni, F., and Liang, P. (2024). Lost in the middle: How language models use long contexts. *Transactions of the Association for Computational Linguistics*, 12:157–173.
- Ma, X., Gong, Y., He, P., Zhao, H., and Duan, N. (2023). Query rewriting in retrieval-augmented large language models. In *Proceedings of the 2023 Conference on Empirical Methods in Natural Language Processing (EMNLP)*, pages 5303–5315.
- Machado, M., Gimenez, P., and Siqueira, S. (2020). Raising the Dimensions and Variables for Searching as a Learning Process: A Systematic Mapping of the Literature. In *Anais do XXXI Simpósio Brasileiro de Informática na Educação*, pages 1393–1402, Porto Alegre, RS, Brasil. SBC.
- Machado, M., Pinelli, C., and Siqueira, S. (2019). A evolução da área de busca como um processo de aprendizagem com base em um mapeamento sistemático. In *Anais dos Workshops do Congresso Brasileiro de Informática na Educação*, volume 8, page 833.

- Machado, M., Souza, J., and Siqueira, S. (2024). Identifying Confirmation Bias in a Search as Learning Task: A Study on The Use of Artificial Intelligence in Education. In *Anais do XXXV Simpósio Brasileiro de Informática na Educação*, pages 1208–1221, Porto Alegre, RS, Brasil. SBC.
- McCandless, M., Hatcher, E., Gospodnetić, O., and Gospodnetić, O. (2010). *Lucene in action*, volume 2. Manning Greenwich.
- Nicholson, J. M., Mordaunt, M., Lopez, P., Uppala, A., Rosati, D., Rodrigues, N. P., Grabitz, P., and Rife, S. C. (2021). scite: A smart citation index that displays the context of citations and classifies their intent using deep learning. *Quantitative science studies*, 2(3):882–898.
- Nogueira, R. and Cho, K. (2019). Passage re-ranking with BERT. *arXiv preprint arXiv:1901.04085*.
- Pereira, W., Filho, G. C., and Aguiar, Y. (2019). Diretrizes para o desenvolvimento de serious games: Um mapeamento sistemático da literatura. In *Anais do XXX Simpósio Brasileiro de Informática na Educação*, pages 714–722, Porto Alegre, RS, Brasil. SBC.
- Primo, J., Amaral, J., Carvalho, K., Horbylon, C., and Nascimento, T. (2024). Safari escolar: Uma aventura em busca dos animais com realidade aumentada. In *Anais do XXXV Simpósio Brasileiro de Informática na Educação*, pages 2836–2845, Porto Alegre, RS, Brasil. SBC.
- Procaci, T. B., Siqueira, S. W., Pinhati, F., and Nunes, B. P. (2015). Estudo exploratório das produções e colaborações entre pesquisadores em informática na educação: uma análise de publicações do simpósio brasileiro de informática na educação de 2001 a 2013. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, pages 1323–1332. SBC.
- Rahman, S. S., Islam, M. A., Alam, M. M., Zeba, M., Rahman, M. A., Chowa, S. S., Raiaan, M. A. K., and Azam, S. (2026). Hallucination to truth: a review of fact-checking and factuality evaluation in large language models. *Artificial Intelligence Review*.
- Reimers, N. and Gurevych, I. (2019). Sentence-BERT: Sentence Embeddings using Siamese BERT-Networks. In *Proceedings of the 2019 Conference on Empirical Methods in Natural Language Processing and the 9th International Joint Conference on Natural Language Processing (EMNLP-IJCNLP)*, pages 3982–3992, Hong Kong, China. Association for Computational Linguistics.
- Rieh, S. Y., Collins-Thompson, K., Hansen, P., and Lee, H.-J. (2016). Towards searching as a learning process: A review of current perspectives and future directions. *Journal of Information Science*, 42(1):19–34.
- Robertson, S. and Zaragoza, H. (2009). The probabilistic relevance framework: BM25 and beyond. *Foundations and Trends in Information Retrieval*, 3(4):333–389.
- Schütze, H., Manning, C. D., and Raghavan, P. (2008). *Introduction to information retrieval*, volume 39. Cambridge University Press Cambridge.
- Semaan, G. S., Corrêa, D. A., Ribas, S. G., Dembogurski, B. J., Silva, E. F., de Moura Brito, J. A., and Ochi, L. S. (2019). Um panorama geral das contribuições e das redes de colaboração do sbie. In *Simpósio Brasileiro de Informática na Educação (SBIE)*, pages 1361–1370. SBC.
- Silva, J., David, J. M., Barrére, E., and de Souza, J. (2021). Uma ontologia para auxílio em ambientes colaborativos para busca de informações. In *Anais do XXXII Simpósio Brasileiro de Informática na Educação*, pages 737–748, Porto Alegre, RS, Brasil. SBC.
- Silva, J., Neto, A., Rosado, B., Machado, M., Souza, J., and Siqueira, S. (2025). A framework for search as learning experiments: Design, implementation, and usability

- insights. In *Anais do XXXVI Simpósio Brasileiro de Informática na Educação*, pages 305–316, Porto Alegre, RS, Brasil. SBC.
- Silva, J. L. and Nunes, I. (2015). Mineração de dados educacionais como apoio para a classificação de alunos do ensino médio. In *Anais do XXVI Simpósio Brasileiro de Informática na Educação*, pages 1112–1121, Porto Alegre, RS, Brasil. SBC.
- Souza, N. C., de Sales, A. B., and Palmeira, E. G. (2024). pysol: Uma proposta python para automação de busca na sbc openlib. *Anais do Computer on the Beach*, 15:283–289.
- Teixeira, C., Tibau, M., and Siqueira, S. W. (2019). Google, se reordene e me ajude a aprender: Critérios de relevância para reordenar resultados de busca como um processo de aprendizagem. In *Anais do XXX Simpósio Brasileiro de Informática na Educação*, pages 576–585, Porto Alegre, RS, Brasil. SBC.
- Urgo, K. and Arguello, J. (2025). Search as learning. *Foundations and Trends® in Information Retrieval*, 19(4):365–556.
- Vakkari, P. (2016). Searching as learning: A systematization based on literature. *Journal of Information Science*, 42(1):7–18.
- White, R. W. (2016). *Interactions with search systems*. Cambridge University Press.
- Whitfield, S. and Hofmann, M. A. (2023). Elicit: Ai literature review research assistant. *Public Services Quarterly*, 19(3):201–207.
- Zhao, W. X., Liu, J., Ren, R., and Wen, J.-R. (2024). Dense text retrieval based on pretrained language models: A survey. *ACM Transactions on Information Systems*, 42(4):1–60.