

ARTIGO ORIGINAL

Avanços nos sistemas de recomendação de artigos científicos: Uma revisão sistemática da literatura

Advances in scientific article recommendation systems: A systematic literature review

Bruno de Santana Braga Contreras ¹ and Luciano Antonio Digiampietri ¹

¹Universidade de São Paulo

*bsbcontreras@usp.br; digiampietri@usp.br

Recebido: 08/10/2024. Revisado: 13/07/2025. Aceito: 31/07/2025.

Resumo

A abundância de artigos disponíveis destaca a crescente relevância dos sistemas de recomendação. Este estudo realizou uma revisão sistemática da literatura com o objetivo de identificar o estado da arte dos sistemas de recomendação de artigos científicos. Foram identificadas abordagens que utilizam embeddings para capturar similaridade semântica, fatoração de matrizes probabilísticas para integrar relações entre artigos e autores. Os resultados indicam uma predominância de modelos híbridos, com utilização de LLMs e modelagem time-aware. Conclui-se que, embora haja avanços significativos, persistem lacunas relacionadas em padronização de métricas e reprodutibilidade dos experimentos, além de oportunidades para o desenvolvimento de modelos contextualmente personalizados.

Palavras-Chave: Palavras-chaves: Sistemas de recomendação. Artigos científicos. Contexto temporal.

Abstract

The abundance of available articles highlights the growing relevance of recommendation systems. This study conducted a systematic review of the literature with the aim of identifying the state of the art in scientific article recommendation systems. Approaches were identified that use embeddings to capture semantic similarity and probabilistic matrix factorization to integrate relationships between articles and authors. The results indicate a predominance of hybrid models, using LLMs and time-aware modeling. It is concluded that, although there have been significant advances, gaps remain in the standardization of metrics and reproducibility of experiments, as well as opportunities for the development of contextually customized models.

Keywords: Recommendation Systems. Scientific Articles. Temporal Context.

1 Introdução

Atualmente, existe uma enorme variedade de informações e produtos disponíveis na Internet, o que torna a busca e a escolha por um item adequado uma tarefa desafiadora. Por exemplo, nas grandes lojas virtuais existem dezenas ou mesmo centenas de itens de um mesmo tipo (computadores, periféricos etc.), nos *streamings* há uma grande

variedade de músicas, filmes e séries e nas bibliotecas digitais há milhares ou mesmo milhões de publicações. Os sistemas de recomendação são ferramentas utilizadas para orientar os usuários na escolha de produtos, serviços ou informações de seu interesse. A grande quantidade de informações disponíveis ao usuário na era digital combinada com o objetivo de fornecer uma melhor experiência do usu-

ário em diferentes sistemas tornou os sistemas de recomendação extremamente relevantes na atualidade (Chen et al., 2013).

Um dos pontos de aplicação dos sistemas de recomendação é na recomendação de artigos científicos. O cenário de produção científica no mundo está em crescimento, gerando uma grande quantidade de publicações nas diversas áreas do conhecimento. Onde há muitas informações, é preciso organizá-las e selecioná-las, para obter uma melhor compreensão das mesmas, transformando-as em conhecimento (Mugnaini et al., 2014). Os sistemas de recomendação de artigos científicos podem auxiliar os pesquisadores a encontrar as publicações mais relevantes e atualizadas para suas áreas de interesse, bem como a identificar tendências e lacunas de pesquisa.

Esses sistemas podem ser baseados em diferentes abordagens, como filtragem baseada em conteúdo, filtragem colaborativa ou uma combinação híbrida dessas técnicas. De maneira resumida, na filtragem baseada em conteúdo, são recomendados itens parecidos com aqueles já consumidos pelo usuário. Por exemplo, se um usuário costuma ler artigos sobre Aprendizado Profundo, o sistema recomendará artigos sobre esse assunto. Já na filtragem colaborativa, o sistema fará suas recomendações com base nos padrões de consumo de pessoas “parecidas” com você. Por exemplo, se as pessoas que estão lendo artigos sobre Aprendizado Profundo também estão lendo artigos sobre Grandes Modelos de Linguagem e você está lendo artigos sobre Aprendizado Profundo, então o sistema te recomendará artigos sobre Grandes Modelos de Linguagem. Os sistemas que adotam uma abordagem híbrida geralmente apresentam resultados mais eficazes, devido à integração de informações tanto dos usuários quanto das características do conteúdo dos artigos (Çano and Morisio, 2017).

Dois fatores são considerados fundamentais para a evolução recente dos sistemas de recomendação. O primeiro é a grande disponibilização de dados sobre conteúdos (ou produtos) e informações de redes sociais, que permitem o desenvolvimento de abordagens mais sofisticadas de filtragem colaborativa. O segundo é o desenvolvimento de novas abordagens que permitem a exploração dos dados disponíveis de forma mais complexa, utilizando, por exemplo, os grandes modelos de linguagem ou redes neurais de grafos.

As particularidades de cada tipo de sistema de recomendação, tais como objetivo, tipo de item recomendado e tipo de informação disponível, possibilitam a criação de sistemas totalmente diferentes, com características próprias de um dado domínio. Neste contexto, uma revisão sistemática atualizada sobre os sistemas de recomendação de artigos científicos se torna útil e necessária e este é o objetivo do presente trabalho: identificar o estado da arte sobre sistemas de recomendação de artigos científicos.

2 Conceitos Básicos

Esta seção apresenta alguns conceitos fundamentais relacionados a sistemas de recomendação de artigos científicos, discutindo seus diversos tipos e destacando os principais desafios envolvidos nesse campo de pesquisa. Nesta seção também são apresentados conceitos ligados a tecno-

logias ou abordagens utilizadas para ajudar a resolver os desafios da área.

Sistemas para recomendação de artigos científicos podem ser baseados em diferentes abordagens, como filtragem colaborativa, filtragem baseada em conteúdo ou uma combinação híbrida dessas técnicas. Os sistemas que adotam uma abordagem híbrida geralmente apresentam resultados mais eficazes, devido à integração de informações tanto dos usuários quanto das características do conteúdo dos artigos (Çano and Morisio, 2017).

A filtragem colaborativa é uma técnica que utiliza as interações e preferências de um grupo de pesquisadores para fazer recomendações. Ela identifica padrões e relações entre pesquisadores e artigos com base em dados históricos de leitura, citações ou colaborações em projetos científicos. Essa abordagem é especialmente útil quando há um grande volume de dados disponíveis e uma comunidade científica ativa, permitindo identificar afinidades e recomendar artigos com base nas preferências de pesquisadores semelhantes.

A filtragem baseada em conteúdo analisa as características dos artigos em si, como o conteúdo textual, as áreas temáticas, as palavras-chave e os tópicos abordados. Essa abordagem busca encontrar artigos similares com base nessas características e recomendar aqueles que sejam relevantes para o pesquisador, levando em conta seu histórico de leitura e suas áreas de interesse. Essa abordagem é particularmente útil quando há informações ricas e estruturadas sobre os artigos disponíveis, permitindo recomendações com base na similaridade de conteúdo.

Ao combinar as abordagens de filtragem colaborativa e baseada em conteúdo, os sistemas híbridos podem superar as limitações individuais de cada uma dessas técnicas. Eles podem aproveitar tanto a sabedoria coletiva dos pesquisadores quanto as informações detalhadas sobre os artigos para fornecer recomendações mais precisas, abrangentes e relevantes.

Portanto, ao optar por uma abordagem híbrida na construção de sistemas de recomendação para artigos científicos, é possível obter resultados aprimorados, proporcionando aos pesquisadores uma experiência mais personalizada e aumentando a efetividade das recomendações feitas pelos sistemas (Çano and Morisio, 2017).

2.1 Inicialização a frio

O problema de inicialização a frio (*cold start*) nos algoritmos de recomendação de artigos científicos refere-se à dificuldade de recomendar artigos recém-publicados ou recomendar artigos a pesquisadores com pouca ou nenhuma informação recente devido à falta de informações históricas, como informações de publicações ou citações desse pesquisador. Normalmente esse problema ocorre quando um novo pesquisador entra na plataforma sem histórico de publicação suficiente (Bai et al., 2019).

Quando se trata de novos artigos científicos, se estes possuem dados e metadados associados, a recomendação baseada em conteúdo consegue lidar bem com este problema: com base nas características do artigo ele é sugerido aos pesquisadores que costumam ler artigos com as mesmas características, por exemplo, sobre o mesmo assunto ou publicado pelos mesmos autores.

Já a inicialização a frio de um novo pesquisador apresenta desafios significativos e geralmente é abordada de duas maneiras. Quando não há histórico de utilização do sistema e nenhuma informação de perfil do pesquisador está disponível (como área de atuação, função, formação, entre outras), os sistemas normalmente sugerem artigos que estão em alta nos últimos dias, semanas ou meses. Esses artigos são selecionados com base em sua popularidade, número de citações ou relevância em contextos específicos, oferecendo sugestões globais ou personalizadas com base na localização do usuário.

Por outro lado, se houver informações de perfil associadas ao usuário, os sistemas tendem a empregar uma abordagem de filtragem colaborativa. Nesse caso, são sugeridos artigos que estão sendo lidos por pesquisadores com perfis semelhantes, utilizando a similaridade de perfis como critério de seleção. Essa similaridade é medida a partir de dados diversos do perfil, permitindo uma recomendação mais precisa e alinhada aos interesses do novo usuário.

2.2 Time-Aware

O *time-aware* refere-se à capacidade de um sistema ou algoritmo de recomendação de levar em consideração a dimensão temporal ao fornecer recomendações personalizadas. Em um contexto de Sistemas de Recomendação Sensíveis ao Tempo, a noção de *time-aware* envolve a utilização do tempo como um elemento crucial na geração de recomendações. Isso significa considerar não apenas as preferências atuais do usuário e as características dos itens, mas também levar em conta o momento em que a recomendação está sendo feita, como o horário do dia, o dia da semana, a estação do ano, entre outros aspectos temporais. Ao ser *time-aware*, um sistema de recomendação pode adaptar suas sugestões com base em padrões temporais, comportamentos passados do usuário e contextos específicos relacionados ao tempo, resultando em recomendações mais personalizadas e relevantes (de Borba et al., 2017).

3 Planejamento

O objetivo desta revisão sistemática é realizar a identificação e análise dos métodos e técnicas utilizados em sistemas de recomendação, visando a identificar abordagens para recomendar artigos científicos aos pesquisadores, bem como as limitações encontradas na literatura existente sobre o assunto. A lista abaixo enumera as questões de pesquisa a serem respondidas com a realização desta revisão.

- i. Que tipos de sistemas de recomendação de artigos científicos são desenvolvidos (Baseados em conteúdo, Filtros colaborativos, Híbridos ou há outros)?
- ii. Quais são os métodos utilizados para o desenvolvimento dos sistemas?
- iii. Quais são as bases de dados utilizadas nesses sistemas?
- iv. Quais as técnicas utilizadas para avaliar estes tipos de sistemas?
- v. Quais são as métricas utilizadas para avaliar esses

tipos de sistemas de recomendação?

Serão consideradas fontes disponíveis via web, de bases de dados científicas reconhecidas na área de estudo. Os critérios de inclusão e exclusão exibidos nas listas a seguir serão aplicados de forma independente e sistemática, garantindo a seleção rigorosa e objetiva dos artigos.

Critérios de Inclusão:

- i. Os estudos devem incluir uma avaliação do desempenho dos sistemas de recomendação, utilizando métricas de qualidade relevantes, como precisão, revocação, F1-score, entre outras.
- ii. Os estudos devem ter sido publicados a partir de 2018, a fim de garantir a relevância atualizada do conteúdo.
- iii. Os estudos devem ter um enfoque específico em pelo menos uma das seguintes áreas temáticas relacionadas a sistemas de recomendação de artigos científicos: filtragem colaborativa, recomendação baseada em conteúdo e modelagem híbrida.

Critérios de Exclusão:

- i. Estudos em que o artigo completo não está disponível na íntegra, o que impossibilita a leitura completa e a avaliação adequada do estudo.
- ii. Estudos que não descrevem os processos e metodologias utilizados para o desenvolvimento e avaliação dos sistemas de recomendação.
- iii. Estudos que não indicam os conjuntos de dados utilizados.

4 Conclusão

Para realizar a revisão sistemática foi utilizada a biblioteca digital Web of Science¹. Utilizando a *string* de busca abaixo foram obtidos, inicialmente, 42 resultados. Após a aplicação dos critérios de inclusão e exclusão, o número de trabalhos foi reduzido para 22.

((AB=("article recommendation")) OR
AB=("paper recommendation")) AND
(AB=(network))²

Após a seleção dos estudos, foi realizada a extração das informações relevantes para a revisão sistemática. Os estudos selecionados foram lidos integralmente e foram extraídas de cada artigo as informações da seguinte lista, sumarizados na Tabela 1.

- i. Principal método utilizado no estudo realizado.
- ii. Modelo complementar (Modelo ou Método auxiliar)
- iii. Quais foram as métricas de avaliação.
- iv. Qual foi a base de dados utilizada.


¹<https://www.webofscience.com/wos/>, acessado em 09/05/2024

²AB = Abstract (Resumo do Trabalho)

5 Apresentação e Discussão dos Resultados

Retomando o objetivo principal desta revisão, que é identificar e analisar os métodos e técnicas existentes para sistemas de recomendação com foco em recomendações de artigos científicos, foram identificadas diferentes formas de tratar esse problema. O detalhamento e a discussão de cada uma das estratégias são apresentados nas subseções a seguir.

Figura 1: Número de artigos científicos selecionados de acordo com abordagem utilizada



A Fig. 1 ilustra os métodos analisados durante a condução da pesquisa. Nota-se que, ao longo dos anos analisados, a estrutura de meta-grafos se destacou como o método predominante. A Tabela 1 oferece um panorama abrangente dos trabalhos analisados, destacando principalmente suas características mais relevantes, como o método principal adotado e a eventual utilização de modelos ou estratégias auxiliares para atingir seus objetivos. Nesta tabela, também é possível verificar as métricas de avaliação empregadas, assim como os conjuntos de dados utilizados.

5.1 Baseados em Grafos e Meta-grafos

Observou-se, nesta revisão sistemática, a forma como os grafos podem ser usados na base da construção de sistemas de recomendação de artigos científicos. Grafos são estruturas que representam relações entre diferentes entidades e podem ser úteis para auxiliar os pesquisadores a encontrar os trabalhos mais relevantes e adequados para as suas necessidades de informação.

Redes acadêmicas podem ser representadas por grafos utilizando artigos científicos como nós e as citações en-

tre eles como arestas. Esses grafos formam uma rede de citações, que indica a influência e a relevância de um trabalho sobre outros. A partir dessa rede, é possível aplicar técnicas de análise de redes sociais, que são métodos que permitem estudar as propriedades estruturais e dinâmicas das redes. Essas técnicas podem ser usadas para identificar os artigos mais centrais, influentes e similares em uma determinada área ou tema e, assim, recomendar os artigos mais adequados para os pesquisadores.

O trabalho de Ma et al. (2018) implementa o método HIPRec (*Heterogeneous Information Network-based Paper recommendation*) para resolver o problema de recomendação de artigos científicos utilizando um sistema baseado em meta-grafos. Um meta-grafo é um grafo que consiste em múltiplos tipos de objetos (por exemplo, pesquisadores, artigos, conferências e tópicos) e múltiplos tipos de conexões entre esses objetos. Um meta-caminho é um caminho que conecta dois objetos em um meta-grafo, percorrendo uma sequência de tipos de objetos e suas respectivas conexões. Por exemplo, no meta-grafo de uma rede bibliográfica, um meta-caminho pode ser definido como uma sequência de tipos de objetos e suas conexões correspondentes, como pesquisador-artigo-conferência-artigo-pesquisador. Os meta-caminhos podem ser usados para capturar as relações semânticas entre diferentes tipos de objetos no meta-grafo, sendo assim possível gerar meta-grafos significativos para recomendação de artigos, o que, segundo o trabalho, ajuda a melhorar a precisão das recomendações para artigos recém-publicados.

O trabalho de Ma and Wang (2019) introduz o método HGRRec (*Heterogeneous Graph Recommendation*), que se diferencia dos sistemas de recomendação de artigos científicos tradicionais pelo fato de aprender diretamente as incorporações de todos os tipos de nós a partir do grafo heterogêneo original, em vez de transferir os grafos para sub-grafos simples ou grafos homogêneos. O HGRRec também propõe duas medidas de proximidade com base em meta-caminhos para avaliar a relevância das representações dos nós, baseados no método LINE. *Meta-Path Based First-Order Proximity* baseado na proximidade de primeira ordem e *Meta-Path Based Second-Order Proximity* de segunda ordem. Por fim, experimentos comparativos com base em um conjunto de dados do mundo real demonstram a eficácia do HGRRec na tarefa de recomendação personalizada de artigos.

O modelo proposto em Ali et al. (2020) utiliza a incorporação de grafos bipartidos para aprender representações de baixa dimensão dos objetos. Mais especificamente, o modelo emprega a proximidade de segunda ordem, conforme adotado no método LINE, para explorar toda a rede. O modelo também integra nós mais próximos com base em texto e vetores baseados em estrutura, aprendidos utilizando técnicas de incorporação como *Paper2vec* e *Struct2vec*. Além de possuir um enfoque em problemas de recomendação de artigos com inicialização a frio, propondo incorporar várias redes de informações, como a rede autor-conferência, autor-tópico e redes de citações. Ao aproveitar essas fontes auxiliares de informações, o modelo pode gerar recomendações mesmo quando há informações limitadas sobre os artigos. Os autores também relatam que o seu modelo alcança bons resultados em termos de revocação.

Tabela 1: Extração de características dos trabalhos analisados

Ano	Trabalho	Método	Modelo Comple- mentar	Avaliação	Base de Dados
2018	Ma et al. (2018)	Meta-Graph	Time-Aware	A* (HIPrec)	DBLP
2018	Alshareef et al. (2018)	Meta-Graph	Latent Semantic Analysis	P, R	IEEE, ACM
2019	Ma and Wang (2019)	Meta-Graph	Embedding		DBLP
2019	Waheed et al. (2019)	Demografic			
2020	Ali et al. (2020)	Meta-Graph		MAP, MRR	
2020	Zhao et al. (2020)	Large Language Model		P, R, F1	
2020	Jeong et al. (2020)	Large Language Model	Context-Aware	P, R	FullTextPeerRead
2021	Hao et al. (2021)	Meta-Graph	Graph Neural Network	NDCG	DBLP, AAN, CiteU- Like, PRSDataset
2021	Li et al. (2021)	Meta-Graph		Random Walks	
2021	Lu et al. (2021)	Meta-Graph	Time-Aware	HR, MRR, NDCG	CiteULike
2021	Tang et al. (2021)	Meta-Graph			CiteULike, AHData
2021	Kong et al. (2021)	Embeddings	Rede de Citação	P, R, F1	PRA
2021	Du et al. (2021)	Neural Network	Bayesian Neural Networks	NDCG	DBLP, ACM, MAG
2021	Zhu et al. (2021)	Neural Network	Recurrent Neural Network	MRR, NDCG	
2021	Wang et al. (2021)	Probabilistic Matrix Factorization	Group Recommen- dation	P, R, MAP	CiteULike
2022	Ali et al. (2022)	Large Language Model		P, A, R, F1, NDCG, MAP	DBLP, AAN
2022	Mei et al. (2022)	Embedding	Rede de Co-autoria	P, R, MRR, MAP, NDCG	HepTh, AAN
2022	Xie et al. (2022)	Neural Network	Graph Convolutio- nal Neural Network	NDCG, MRR, MAP	ACM, Scopus
2022	Wang et al. (2022)	Probabilistic Matrix Factorization		P, R, MRR, MAP	CiteULike
2023	Chen et al. (2023)	Meta-Graph		NDCG, HR	DBLP, AMiner, Me- tallurgical
2023	Mataoui et al. (2023)	Demografic		P, R, F1, MAP	ResearchGate
2023	Jiang et al. (2023)	Neural Network	Time-Aware	P, R, MRR	DBLP

Os meta-caminhos também estão presentes em [Li et al. \(2021\)](#). Neste trabalho, os meta-caminhos podem ser definidos da seguinte forma: Usuário-Curte Artigo-Escrito por Autor-escreve Artigo. Trabalhando agora com a possibilidade de um usuário curtir um determinado artigo. Os meta-caminhos possuem pesos, que por sua vez são aprendidos com base nos registros de preferências dos usuários. Um usuário tende a ter preferências diferentes para diferentes meta-caminhos e essas preferências estão incorporadas no histórico dos usuários. Os pesos dos meta-caminhos refletem a importância de cada meta-caminho para um usuário específico e são utilizados para calcular as pontuações de recomendação para artigos candidatos. Para lidar com a inicialização a frio, o trabalho trata o problema de forma híbrida. O método extrai inicialmente as características textuais do novo artigo e representa elas como um vetor espacial. Em seguida, calcula a similaridade entre o novo artigo e todos os outros artigos no conjunto de dados com base em suas características textuais. Por fim, recomenda com base nos principais k artigos que são mais semelhantes ao novo artigo.

O trabalho de [Alshareef et al. \(2018\)](#) propõe uma abordagem combinando o conteúdo do artigo com suas métricas bibliométricas para avaliar o impacto das suas citações na rede de citações próximas, calculando a similaridade semântica entre dois artigos na rede, utilizando metadados

do artigo. A similaridade entre os artigos e suas pontuações biblio-métricas são, então, utilizadas para avaliar o impacto do artigo dentro da sua rede de citações.

Em [Lu et al. \(2021\)](#), Redes Neurais em Grafo (GNNs – Graph Neural Networks) foram utilizadas para aprender os interesses dos autores e consolidar informações de contexto sobre os artigos, com o objetivo de modelar os interesses de cada autor. Para avaliar a similaridade entre dois nós na rede acadêmica, o método proposto une a similaridade de conteúdo e a interação estrutural entre os artigos. Ou seja, a similaridade de conteúdo entre dois nós é calculada com base em suas características, seja o título, resumo e palavras chave, enquanto a interação estrutural é avaliada com base em suas características estruturais, fornecidas com o aprendizado da GNN empregada durante o treinamento da rede. A similaridade de conteúdo e a interação estrutural são, então, combinadas por meio de uma soma ponderada para obter a similaridade global entre os dois nós. Os pesos empregados nessa combinação são ajustados durante o processo de treinamento.

O método CGPRec proposto em [Tang et al. \(2021\)](#) funciona combinando abordagens baseadas em conteúdo e baseadas em grafos de conhecimento para recomendação de artigos científicos. O método baseado em conteúdo deste trabalho utiliza auto-atenção em duas etapas, primeiramente de forma individual em cada artigo, junto

com o Doc2Vec, depois é aplicada a auto-atenção entre os artigos, obtendo assim características globais de todos os artigos. Isso é feito capturando a importância de diferentes palavras no texto e obtendo uma representação ponderada do texto. O método baseado em grafos de conhecimento utiliza uma rede convolucional de grafos (GCN) para modelar associações de alto nível no grafo de conhecimento e extrair preferências implícitas do usuário. O grafo de conhecimento é construído com nós de conceitos, nós de usuários, nós de artigos e outros meta-nós. Para obter preferências implícitas do usuário, o método CGPRec utiliza uma agregação de vizinhança, coletando informações dos vizinhos de um nó ao levar em conta os dados vetoriais desse nó e a estrutura dos nós ao seu redor, para melhorar o GCN, que não consegue considerar vários tipos de relações no grafo de conhecimento.

5.2 Baseados em Grandes Modelos de Linguagem

Em Zhao et al. (2020) é apresentada uma abordagem visando a aprimorar a precisão na previsão de classificações implícitas de usuários. Esta abordagem é baseada em um modelo híbrido que aproveita a semântica latente contida no conteúdo de texto não estruturado, resultando em uma matriz de classificação mais precisa. Especificamente, o modelo utiliza o histórico de comportamento do usuário, incluindo registros de favoritos, para construir uma matriz de classificação. Esta matriz é então decomposta para extrair os vetores de fatores latentes associados aos usuários e ao conteúdo literário. Em seguida, o modelo emprega a arquitetura BiGRU (*Bidirectional Gated Recurrent Unit*) para aprimorar a capacidade de extração de características das redes neurais recorrentes. A BiGRU processa a sequência de entrada em ambas as direções (para frente e para trás) e utiliza um mecanismo de atenção do usuário para explorar o conteúdo textual dos artigos. Isso resulta na geração de novos vetores de características latentes, que substituem os vetores de fatores latentes originais obtidos durante a decomposição da matriz de classificação. Por fim, com base nos novos vetores de fatores latentes do usuário, uma nova matriz de classificação é gerada. Com base nessa matriz, uma lista de recomendações é produzida, personalizada de acordo com o perfil latente do usuário.

O trabalho de Jeong et al. (2020) apresenta um modelo baseado em aprendizado profundo e um conjunto de dados bem organizado para recomendação de artigos sensível ao contexto. O modelo proposto combina BERT e redes convolucionais de grafos (GCNs) para capturar tanto as informações semânticas quanto as informações estruturais de artigos científicos. A principal contribuição deste artigo é fornecer conjuntos de dados e modelos de ponta adequados para a pesquisa de tarefas de recomendação de artigos com consciência de contexto e, por sua vez, proporcionar aos pesquisadores um ambiente aprimorado para a escrita de artigos. A motivação por trás do desenvolvimento de um modelo de recomendação de citações sensível ao contexto é resolver o processo demorado de busca por referências ao escrever um artigo científico. Com o grande crescimento no número de artigos científicos sendo publicados, os autores alegam que uma técnica que possa inserir uma citação de referência no local apropriado em uma frase seria benéfica. Por fim os autores apresentam

um novo conjunto de dados chamado *FullTextPeerRead*, que contém artigos completos e seus contextos de citação, para avaliar o desempenho do modelo proposto. Os resultados experimentais demonstram que o modelo proposto alcança um desempenho relevante na tarefa de recomendação de citação.

O método utilizado em Ali et al. (2022), *Scientific paper recommendation employing SPECTER with memory network SPR-SMN* utiliza o modelo de incorporação de documentos SPECTER. Primeiramente o método SPR-SMN utiliza o SPECTER para criar representações da parte textual dos artigos concatenando o resumo e o título. Em seguida, o método entra no módulo de incorporação personalizada. Esse módulo utiliza um MLP para capturar as preferências dos pesquisadores e gerar incorporações personalizadas para cada artigo. Por fim, a rede de memória é utilizada para capturar informações contextuais de longo prazo, ou seja, a rede de memória recebe como entrada as incorporações personalizadas dos artigos e o artigo de consulta, e gera uma representação final do artigo de consulta. Esta representação é então utilizada para calcular a similaridade entre os artigos disponíveis, retornando assim as principais recomendações.

5.3 Baseado em Embeddings

Uma técnica bastante empregada nos últimos anos por sistemas de recomendação é a dos *embeddings*, que consiste em converter informações textuais em vetores numéricos de baixa dimensão. Esses vetores capturam a similaridade semântica entre os textos, permitindo que o sistema identifique artigos com afinidades temáticas. Assim, o sistema pode fornecer recomendações mais acuradas e pertinentes para os usuários, de acordo com seus interesses de pesquisa.

O trabalho de Kong et al. (2021) introduz o método VO-PRec (*Vector Representation Learning of Papers*), esse método transforma artigos em vetores seguindo um processo que começa obtendo os vetores textuais dos artigos com base em seu conteúdo, utilizando a incorporação de palavras. Em seguida, ele aprende os vetores estruturais dos artigos a partir da identidade estrutural para encontrar possíveis artigos com estruturas similares. Por fim, o VO-PRec conecta esses dois conjuntos de vetores por meio de uma rede de citações ponderadas, ligando os *m*-vizinhos mais próximos com base no texto e os *n*-vizinhos mais próximos com base na estrutura. Com base na rede de citações ponderadas reconstruída, a similaridade entre os artigos pode ser calculada com a utilização de incorporações de rede para recomendação de artigos científicos.

O trabalho de Mei et al. (2022) apresenta o método *Mutual Reinforcement Network Embedding* (MRNE), que utiliza redes de coautoria, informações textuais e estruturas de rede bibliográficas para realizar recomendações. Esse método se baseia no princípio de reforço mútuo, o que significa que a coautoria e as informações textuais de um artigo se reforçam mutuamente com base na estrutura de rede. Primeiramente, o trabalho incorpora o texto dos artigos em uma estrutura de grafo utilizando uma rede neural convolucional (CNN), utilizando a sequência de palavras de cada artigo como entrada. Em seguida é incorporada a informação da rede de citações, combinando com o texto

já incorporado utilizando uma estrutura de aprendizado mutuamente reforçada que atualiza as incorporações de cada artigo com base nas incorporações de seus vizinhos. Por fim, é utilizada uma rede de atenção de grafos para calcular os coeficientes de atenção para cada vizinho de um artigo, permitindo que a rede se concentre nos vizinhos mais relevantes para realizar a recomendação. Os autores reforçam que a inclusão de informações de coautoria na recomendação de artigos científicos pode melhorar significativamente a precisão do processo.

5.4 Time-Aware (Preocupação com o Tempo)

O trabalho de [Lu et al. \(2021\)](#) utiliza o conceito de *Time-Aware* na implementação de seu método de sistema de recomendação, significando que o modelo leva em consideração o fator temporal na recomendação de artigos acadêmicos. O impacto de um artigo acadêmico gradualmente diminuiria ao longo do tempo e os interesses de pesquisa dos usuários também podem mudar. Portanto, o tempo deve ser levado em consideração ao trabalhar com os sistemas de recomendação.

A proposta apresentada nesse artigo, TGMF-FMLP, combina uma filtragem colaborativa neural sensível ao tempo com características multidimensionais extraídas com uma MLP (Perceptron de Múltiplas Camadas). A MLP é empregada para treinar as características dos artigos, que incluem informações como a revista e o tipo de artigo como características, além do título e resumo. Os autores utilizam o método FMLP (Perceptron de Múltiplas Camadas Sensível a Características) para incorporar essas características dos artigos no modelo. Para a parte de filtragem colaborativa é utilizado o método TGMF (*Time-aware Generalized Matrix Factorization*), que se trata de uma adaptação do método GMF (*Generalized Matrix Factorization*), utilizado para analisar a relação linear entre o usuário e o artigo. Porém, nesse artigo é levado em consideração o aspecto temporal utilizando quatro tipos de funções de decaimento temporal como coeficientes de peso para adicioná-las ao modelo GMF característico. Assim, quanto mais antigo o artigo, mais a função de decaimento terá influência nele.

O trabalho de [Jiang et al. \(2023\)](#) apresenta o método *Time-aware Paper Recommendation* (TAPRec), que tem como uma de suas abordagens a inicia-lização a frio, combinando as preferências dinâmicas dos coautores de um pesquisador com as preferências do próprio pesquisador. Isso é particularmente importante para pesquisadores juniores que possuem poucas publicações e, portanto, possuem poucas publicações onde os sistemas de recomendação podem se basear. Ao modelar as preferências de pesquisa de pesquisadores juniores a partir das informações textuais de suas publicações, das referências das publicações e dos interesses dinâmicos de seus colaboradores, o TAPRec é capaz de fornecer recomendações, mesmo para pesquisadores com poucas produções acadêmicas.

5.5 Redes Neurais

O propósito central do artigo de [Du et al. \(2021\)](#) é apresentar e avaliar o POLAR++ (*PersOnaLized Article Recommen-*

dation framework++). Este arcabouço adota abordagens baseadas em Redes Neurais Bayesianas para capturar a incerteza que permeia as preferências do usuário. Além disso, ele se distingue por seu processo de seleção ativa de artigos para interação com o usuário a fim de obter *feedback*, e sua capacidade de aprender de forma adaptativa às preferências do usuário através do aprendizado *one-shot*. Um desafio abordado pelo POLAR++ é o problema de inicialização a frio aprendendo ativamente as preferências de novos usuários por meio de interações, mesmo quando os dados de preferência do usuário estão ausentes ou limitados. O sistema utiliza Redes Neurais Bayesianas para modelar a incerteza nas preferências do usuário. Estas redes incorporam uma distribuição prévia nos parâmetros da rede neural, a qual é refinada durante o treinamento para gerar uma distribuição posterior. Essa distribuição posterior, informada pelos dados de treinamento e pela distribuição prévia, representa a incerteza nas previsões do modelo. Esse nível de incerteza é valioso para tomar decisões mais ponderadas sobre quais artigos apresentar ao usuário e, posteriormente, receber *feedback*.

O método proposto por [Zhu et al. \(2021\)](#) é uma Rede Neural Recorrente (RNN) baseada em incorporação de conhecimento heterogêneo. Nesse trabalho é construída uma rede bibliográfica, com autores e trabalhos, em seguida é feita uma incorporação TransD para vetorizar as entidades e relações da rede, essa vetorização consiste em utilizar dois vetores para cada entidade e relação. A RNN é utilizada com mecanismo de atenção, atribuindo pesos adaptativos em diferentes partes da sequência de entrada, gerando assim recomendações com base nas preferências aprendidas do usuário e nas entidades e relações vetorizadas.

O trabalho de [Xie et al. \(2022\)](#) traz o método *Subspace-based Paper Recommendation*, nele o conceito de subespaço é utilizado para descrever os aspectos centrais do artigo, ou seja, um subespaço é definido como um espaço que captura um aspecto específico das características do artigo, como o conteúdo, informações de citação ou coautoria. Os autores propõem um modelo de incorporação de subespaços com base em redes gêmeas para mapear o conteúdo de um artigo para alguns subespaços de acordo com os dados extraídos. Neste método é construída uma rede de citações e uma co-autoria, que em seguida são utilizadas para analisar as diferenças entre os artigos, por meio de um método chamado Análise de Diferenças em Artigos. Esse processo envolve a definição de regras especializadas, assim criando subespaços de avaliação para poder medir as diferenças entre os artigos e identificar os artigos altamente citados que possuem relevância em todos os subespaços. Por fim, as representações aprendidas e a rede de citações são utilizadas para treinar uma rede neural convolucional para grafos (GCN) para recomendação de artigos. Em resumo, o conceito de subespaço é utilizado para capturar a natureza multidimensional dos artigos acadêmicos e melhorar a precisão da recomendação de artigos, levando em consideração diferentes aspectos do artigo.

5.6 Fatoração de Matrizes Probabilísticas

O método de Fatoração de Matrizes Probabilísticas (FMP) é uma técnica que tem o objetivo de prever classificações ausentes dentro de uma matriz de interações entre usuários

e itens que representam as preferências e características dos mesmos. Reportado pela primeira vez em Funk (2006) para o campo de Sistemas de Recomendação, apesar de ser um método relativamente antigo, ele ainda é utilizado por sua relevância em fornecer recomendações precisas.

Os trabalhos Wang et al. (2021) e Wang et al. (2022) adotam o método FMP para incorporar informações entre artigo e autor, pois ambos se baseiam em conteúdo e podem aprimorar as recomendações realizadas. O trabalho de Alshareef et al. (2018) emprega o método Análise Semântica Latente (ASL), que tem uma forte correlação com o método FMP, já que os dois métodos são usados para decomposição de dados não negativos. Nesse trabalho, o método ASL é usado para identificar citações (referências) que terão um maior impacto para o pesquisador.

Em Wang et al. (2022), o método denominado *Group-Oriented Paper Recommendation With Probabilistic Matrix Factorization and Evidential Reasoning* (GPMF_ER) é apresentado. O processo inicia com a criação de uma Rede Social Científica (RSC), que posteriormente é empregada na aplicação do método de Factorização Matricial Probabilística (FMP). Este procedimento tem como objetivo prever classificações para artigos não previamente classificados. Para enriquecer ainda mais o método FMP, ele é otimizado pela integração de informações tanto do grupo quanto do conteúdo dos artigos. Após a conclusão do processo de recomendação individual de artigos, é possível obter classificações previstas para todos os artigos, considerando a análise da similaridade nos interesses de pesquisa entre os membros do grupo. O próximo passo consiste em consolidar essas classificações individuais dos membros em uma única classificação para o grupo como um todo. Para realizar essa tarefa, é introduzida a chamada Regra de Raciocínio Evidencial (ER), que é responsável por combinar as classificações dos membros, levando em consideração tanto os pesos atribuídos a cada membro quanto a confiabilidade de suas contribuições. A Regra ER é uma técnica de fusão de informações que atribui peso e confiabilidade a cada elemento de evidência, suportando a análise de decisões em contextos com múltiplos atributos.

Em Wang et al. (2021), o Método ER é empregado para analisar decisões que envolvem múltiplos critérios. No contexto do método de recomendação de artigos em grupo proposto, a regra ER é introduzida na agregação de grupo. Utilizada para identificação dos impactos dos membros do grupo, levando em consideração o peso e a confiabilidade de cada membro. Esse método de agregação para recomendação de artigos em grupo permite a identificação de diferentes níveis de importância atribuídos a cada membro do grupo, por meio da alocação de pesos e confiabilidades distintas.

6 Considerações Finais

Esta revisão sistemática analisou avanços recentes em sistemas de recomendação de artigos científicos. O levantamento identificou não apenas a diversidade técnica das soluções propostas, mas também o direcionamento atual da área para modelos que combinam múltiplas fontes de informação semântica, temporal e estrutural.

De forma geral, observou-se uma tendência de substituição

de abordagens puramente colaborativas por modelos híbridos e baseados em aprendizado profundo, com foco crescente na personalização contextualizada e no aproveitamento de redes acadêmicas. Técnicas como GNNs, BERT e embeddings específicos para publicações científicas, como o Specter, têm ampliado a capacidade dos sistemas de capturar relações relevantes entre documentos, autores e interesses de pesquisa.

Apesar dos avanços, a literatura ainda carece de maior padronização experimental, sobretudo no uso de bases públicas e protocolos de avaliação reproduzíveis. A ausência de benchmarks consolidados dificulta comparações diretas e compromete a validação cruzada entre estudos, levando a maioria dos sistemas utilizarem técnicas de ablação.

Como direcionamento futuro, destaca-se a importância de se avançar na integração entre modelos semânticos e temporais, no desenvolvimento de soluções escaláveis para grandes repositórios científicos como o Openalex³.

Referências

- Ali, Z., Qi, G., Kefalas, P., Khusro, S., Khan, I. and Muhammad, K. (2022). SPR-SMN: scientific paper recommendation employing SPECTER with memory network, *Scientometrics* **127**(11): 6763–6785. <https://doi.org/10.1007/s11192-022-04425-3>.
- Ali, Z., Qi, G., Muhammad, K., Ali, B. and Abro, W. A. (2020). Paper recommendation based on heterogeneous network embedding, *Knowledge-Based Systems* **210**: 106438. <https://doi.org/10.1016/j.knosys.2020.106438>.
- Alshareef, A. M., Alhamid, M. F. and Saddik, A. E. (2018). Toward citation recommender systems considering the article impact in the extended nearby citation network, *Peer-to-Peer Networking and Applications* **12**(5): 1336–1345. <https://doi.org/10.1007/s12083-018-0687-4>.
- Bai, X., Wang, M., Lee, I., Yang, Z., Kong, X. and Xia, F. (2019). Scientific paper recommendation: A survey, *IEEE Access* **7**: 9324–9339. <https://doi.org/10.1109/access.2018.2890388>.
- Chen, S., Owusu, S. and Zhou, L. (2013). Social network based recommendation systems: A short survey, 2013 *International Conference on Social Computing*, IEEE, Alexandria, VA, USA, pp. 882–885. <https://doi.org/10.1109/socialcom.2013.134>.
- Chen, W., Zhang, Y., Xian, Y. and Wen, Y. (2023). Hotspot information network and domain knowledge graph aggregation in heterogeneous network for literature recommendation, *Appl. Sci. (Basel)* **13**(2): 1093. <https://doi.org/10.3390/app13021093>.
- de Borja, E. J., Gasparini, I. and Lichtnow, D. (2017). *Time-Aware Recommender Systems: A Systematic Mapping*, Springer International Publishing, p. 464–479. http://dx.doi.org/10.1007/978-3-319-58077-7_38.

³Openalex: <https://openalex.org/>

- Du, Z., Tang, J. and Ding, Y. (2021). POLAR++: Active one-shot personalized article recommendation, *IEEE Trans. Knowl. Data Eng.* 33(6): 2709–2722. <https://doi.org/10.1109/TKDE.2019.2953721>.
- Funk, S. (2006). Netflix update: Try this at home. URL: <https://sifter.org/simon/journal/20061211.html>
- Hao, Liu, S. and Pan, L. (2021). Paper recommendation based on author-paper interest and graph structure, *2021 IEEE 24th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, IEEE, Dalian, China, pp. 256–261. <https://doi.org/10.1109/CSCWD49262.2021.9437743>.
- Jeong, C., Jang, S., Park, E. and Choi, S. (2020). A context-aware citation recommendation model with BERT and graph convolutional networks, *Scientometrics* 124(3): 1907–1922. <https://doi.org/10.1007/s11192-020-03561-y>.
- Jiang, C., Ma, X., Zeng, J., Zhang, Y., Yang, T. and Deng, Q. (2023). TAPRec: time-aware paper recommendation via the modeling of researchers' dynamic preferences, *Scientometrics* 128(6): 3453–3471. <https://doi.org/10.1007/s11192-023-04731-4>.
- Kong, X., Mao, M., Wang, W., Liu, J. and Xu, B. (2021). VOPRec: Vector representation learning of papers with text information and structural identity for recommendation, *IEEE Trans. Emerg. Top. Comput.* 9(1): 226–237. <https://doi.org/10.1109/TETC.2018.2830698>.
- Li, Y., Wang, R., Nan, G., Li, D. and Li, M. (2021). A personalized paper recommendation method considering diverse user preferences, *Decision Support Systems* 146: 113546. <https://doi.org/10.1016/j.dss.2021.113546>.
- Lu, Y., He, Y., Cai, Y., Peng, Z. and Tang, Y. (2021). Time-aware neural collaborative filtering with multi-dimensional features on academic paper recommendation, *2021 IEEE 24th International Conference on Computer Supported Cooperative Work in Design (CSCWD)*, IEEE, Dalian, China, pp. 1052–1057. <https://doi.org/10.1109/cscwd49262.2021.9437673>.
- Ma, X. and Wang, R. (2019). Personalized scientific paper recommendation based on heterogeneous graph representation, *IEEE Access* 7: 79887–79894. <https://doi.org/10.1109/access.2019.2923293>.
- Ma, X., Zhang, Y. and Zeng, J. (2018). Newly published scientific papers recommendation in heterogeneous information networks, *Mobile Networks and Applications* 24(1): 69–79. <https://doi.org/10.1007/s11036-018-1133-9>.
- Mataoui, M., Sebbak, F., Sidhoum, A. H., Harbi, T. E., Senouci, M. R. and Belmessous, K. (2023). A hybrid recommendation system for researchgate academic social network, *Social Network Analysis and Mining* 13(1): 12. <https://doi.org/10.1007/s13278-023-01056-1>.
- Mei, X., Cai, X., Xu, S., Li, W., Pan, S. and Yang, L. (2022). Mutually reinforced network embedding: An integrated approach to research paper recommendation, *Expert Syst. Appl.* 204(117616): 117616. <https://doi.org/10.1016/j.eswa.2022.117616>.
- Mugnaini, R., Digiampetri, L. A. and Mena-Chalco, J. P. (2014). Comunicação científica no Brasil (1998–2012): indexação, crescimento, fluxo e dispersão, *Transinformação* 26(3): 239–252. <https://doi.org/10.1590/0103-3786201400030002>.
- Tang, H., Liu, B. and Qian, J. (2021). Content-based and knowledge graph-based paper recommendation: Exploring user preferences with the knowledge graphs for scientific paper recommendation, *Concurrency and Computation: Practice and Experience* 33(13): 11. <https://doi.org/10.1002/cpe.6227>.
- Waheed, W., Imran, M., Raza, B., Malik, A. K. and Khattak, H. A. (2019). A hybrid approach toward research paper recommendation using centrality measures and author ranking, *IEEE Access* 7: 33145–33158. <https://doi.org/10.1109/access.2019.2900520>.
- Wang, G., Wang, H.-R., Yang, Y., Xu, D.-L., Yang, J.-B. and Yue, F. (2021). Group article recommendation based on ER rule in scientific social networks, *Appl. Soft Comput.* 110(107631): 107631. <https://doi.org/10.1016/j.asoc.2021.107631>.
- Wang, G., Zhang, X., Wang, H., Chu, Y. and Shao, Z. (2022). Group-oriented paper recommendation with probabilistic matrix factorization and evidential reasoning in scientific social network, *IEEE Trans. Syst. Man Cybern. Syst.* 52(6): 3757–3771. <https://doi.org/10.1109/TSMC.2021.3072426>.
- Xie, Y., Li, W., Sun, Y., Bertino, E. and Gong, B. (2022). Subspace embedding based new paper recommendation, *2022 IEEE 38th International Conference on Data Engineering (ICDE)*, IEEE, Kuala Lumpur, Malaysia, pp. 1767–1780. <https://doi.org/10.1109/ICDE53745.2022.00178>.
- Zhao, X., Kang, H., Feng, T., Meng, C. and Nie, Z. (2020). A hybrid model based on LFM and BiGRU toward research paper recommendation, *IEEE Access* 8: 188628–188640. <https://doi.org/10.1109/access.2020.3031281>.
- Zhu, Y., Lin, Q., Lu, H., Shi, K., Qiu, P. and Niu, Z. (2021). Recommending scientific paper via heterogeneous knowledge embedding based attentive recurrent neural networks, *Knowledge-Based Systems* 215: 106744. <https://doi.org/10.1016/j.knosys.2021.106744>.
- Çano, E. and Morisio, M. (2017). Hybrid recommender systems: A systematic literature review, *Intelligent Data Analysis* 21(6): 1487–1524. <https://doi.org/10.3233/ida-163209>.