

Sistemas de recomendação baseados em dados espaciais: um mapeamento sistemático

Aline Ferreira Pereira^{[1]*}, João Batista da Rocha Junior^[2]

^[1] aline.ferreira@ifba.edu.br. Instituto Federal da Bahia (IFBA), Euclides da Cunha, Bahia, Brasil

^[2] joao@uefs.br. Universidades Estadual de Feira de Santana (UEFS), Feira de Santana, Bahia, Brasil

*autora correspondente

Resumo

Este artigo apresenta os resultados de um mapeamento sistemático da literatura sobre o uso de dados espaciais em Sistemas de Recomendação. O estudo teve como objetivo identificar as principais técnicas empregadas, as fontes e os tipos de dados espaciais utilizados, bem como os métodos de avaliação mais comuns, abordando assim uma lacuna importante sobre como os dados espaciais são incorporados em tais sistemas. Um total de 199 artigos publicados entre 2003 e 2024 foram analisados, recuperados da Scopus, IEEE Xplore, ACM Digital Library e ScienceDirect, sendo selecionados apenas estudos primários que atendiam a critérios de qualidade específicos. Os resultados indicam a predominância de Filtragem Colaborativa e Aprendizado de Máquina, juntamente com o uso extensivo de dados de redes sociais baseados em localização. A aplicação frequente de métricas espaciais, como Distância Euclidiana, e abordagens baseadas em similaridade também foi observada. Além disso, técnicas híbridas foram identificadas como métodos empregados para melhorar a qualidade das recomendações. Este mapeamento sistemático contribui para consolidar o estado da arte em sistemas de recomendação focados em dados espaciais, fornecendo uma visão abrangente de tendências, desafios e oportunidades de pesquisa na área. Por fim, o uso da metodologia *Snowball* pode ser explorado em estudos futuros para permitir a inclusão de novos trabalhos relevantes e fornecer uma perspectiva complementar que aprimore a compreensão da área.

Palavras-chave: aprendizado de máquina; dados espaciais; filtragem colaborativa; mapeamento sistemático; sistemas de recomendação.

Spatial data-based recommender systems: a systematic mapping

Abstract

This article presents the results of a systematic mapping of the literature on the use of spatial data in Recommender Systems. The study aimed to identify the main techniques employed, the sources and types of spatial data used, as well as the most common evaluation methods, thereby addressing an important gap regarding how spatial data are incorporated into such systems. A total of 199 articles published between 2003 and 2024 were analyzed, retrieved from Scopus, IEEE Xplore, ACM Digital Library, and ScienceDirect, with only primary studies meeting specific quality criteria being selected. The results indicate the predominance of Collaborative Filtering and Machine Learning, along with the extensive use of location-based social network data. The frequent application of spatial metrics, such as Euclidean Distance, and similarity-based approaches was also observed. In addition, hybrid techniques were identified as methods employed to improve the quality of recommendations. This systematic mapping contributes to consolidating the state of the art in recommender systems focused on spatial data, providing a comprehensive overview of trends, challenges, and research opportunities in the field. Finally, the use of the Snowball methodology may be explored in future studies to enable the inclusion of new relevant works and provide a complementary perspective that enhances the understanding of the area.

Keywords: collaborative filtering; machine learning; recommender systems; spatial data; systematic mapping.

1 Introdução

A crescente demanda por soluções que otimizem o tempo e apoiem decisões rápidas tem impulsionado o desenvolvimento de tecnologias capazes de personalizar experiências em diferentes áreas. Nesse contexto, os Sistemas de Recomendação (SRs) destacam-se como ferramentas relevantes,

ao auxiliarem na filtragem de informações e na proposição de sugestões que se alinham às preferências dos usuários.

De acordo com Angelis, Kotis e Spiliotopoulos (2021), esses sistemas têm por objetivo aprimorar a experiência do usuário por meio de recomendações personalizadas, considerando suas características e comportamentos individuais. Tais sistemas desempenham um papel crucial em várias plataformas online, como nos serviços de streaming de filmes, a exemplo da Netflix, que recomenda conteúdos com base no histórico de visualização e nas avaliações anteriores.

Entre os dados utilizados por SRs, os dados espaciais vêm ganhando destaque. Esses dados descrevem fenômenos relacionados a dimensões geográficas, sendo representados por coordenadas, trajetos e áreas. Güting (1994) classifica-os em pontos, linhas e regiões, possibilitando uma representação detalhada da localização de objetos fixos ou móveis.

A integração de dados espaciais aos SRs amplia a capacidade de personalização ao incorporar a localização geográfica como fator determinante nas recomendações, aspecto particularmente valioso em cenários como turismo, mobilidade urbana e comércio eletrônico e *delivery*. Um exemplo é o iFood, aplicativo brasileiro de entrega de refeições, que utiliza informações de localização para oferecer recomendações personalizadas de pratos e restaurantes próximos ao usuário (Granado *et al.*, 2025).

A literatura indica que os dados espaciais podem ser utilizados tanto como entrada para aprimorar as recomendações quanto como saída, quando os itens recomendados possuem atributos espaciais. Estudos como o de Vahidnia (2022) demonstram que a inclusão da geolocalização do usuário pode aumentar a relevância das recomendações. Pesquisas como a de Ivanova, Andrić e Ricci (2022) exploram a recomendação de rotas personalizadas, a exemplo de trilhas de escalada, enquanto Artemenko, Pasichnyk e Kunanets (2020) aborda a recomendação de pontos, rotas e áreas durante deslocamentos, com o objetivo de minimizar engarrafamentos.

A popularização dos dispositivos móveis e das plataformas que capturam dados espaciais continuamente contribui para o aumento da disponibilidade e da relevância dessas informações. Esse cenário reforça a importância de compreender de forma sistemática como os dados espaciais têm sido incorporados aos SRs ao longo dos anos, aspecto fundamental para o desenvolvimento de soluções eficazes e adaptadas às necessidades dos usuários.

A motivação deste estudo também se justifica por experiências práticas que revelam falhas na contextualização espacial das recomendações. Por exemplo, ao buscar um veículo em plataformas de comércio eletrônico, recomendações tecnicamente adequadas são fornecidas, porém, muitas vezes, não consideram a distância geográfica, o que pode inviabilizar sua utilidade prática. Essa situação exemplifica a relevância da dimensão espacial para a efetividade das recomendações.

Apesar da crescente atenção ao tema, a literatura apresenta-se dispersa, dificultando a identificação de padrões e de lacunas na área. Dessa forma, torna-se necessário realizar um mapeamento sistemático da literatura com o objetivo de sintetizar esse conhecimento fragmentado. Um panorama abrangente possibilita identificar tendências emergentes, técnicas mais utilizadas, áreas pouco exploradas e oportunidades de avanço da pesquisa. Esse esforço mostra-se relevante tanto para a academia quanto para o setor produtivo, considerando a aplicação crescente de SRs em serviços que dependem de localização, como aplicativos de mobilidade urbana e de *delivery*.

O presente artigo tem como objetivo apresentar os resultados de um mapeamento sistemático sobre o uso de dados espaciais em SRs, abrangendo o período de 2003 a junho de 2024. O estudo busca identificar as técnicas mais utilizadas, examinar como os dados espaciais são extraídos, representados e incorporados aos SRs, além de analisar os métodos de avaliação, com ênfase em evidenciar as tendências e lacunas existentes na literatura. Entre as principais lacunas identificadas, destacam-se a dispersão e a falta de sistematização do conhecimento produzido na área, bem como a escassez de estudos que abordem os desafios relacionados à integração de dados espaciais aos SRs.

Ao final desta introdução, apresentam-se as demais seções que compõem o artigo. A Seção 2 aborda os principais conceitos teóricos relacionados a SRs e dados espaciais, contextualizando a integração entre esses domínios. A Seção 3 descreve os procedimentos metodológicos adotados para a realização do mapeamento sistemático da literatura. Em seguida, a Seção 4 apresenta e discute os

principais resultados encontrados, destacando as abordagens mais utilizadas, as lacunas identificadas e as tendências emergentes. Por fim, a Seção 5 expõe as considerações finais do estudo, discutindo suas contribuições, limitações e sugestões para pesquisas futuras.

2 Referencial teórico

A compreensão dos conceitos fundamentais relacionados aos dados espaciais e aos SRs é essencial para contextualizar as contribuições deste estudo. Esta seção apresenta, primeiramente, os principais aspectos teóricos sobre dados espaciais. Em seguida, discutem-se os SRs, suas técnicas mais utilizadas, formas de avaliação, bem como sua arquitetura genérica. Por fim, aborda-se a integração entre esses dois domínios e apresentam-se trabalhos relacionados.

2.1 Dados espaciais

Dados espaciais referem-se a informações que descrevem objetos com localização geográfica, dimensões físicas e relações espaciais bem definidas (Güting, 1994). Em geral, são expressos por coordenadas, como latitude e longitude, permitindo identificar a posição exata de entidades geográficas (Pebesma; Bivand, 2023).

Esses dados podem ser classificados em três tipos principais: pontos, representando localizações específicas, como cidades; linhas, que conectam pontos e representam elementos como estradas ou rios; e regiões, que delimitam áreas geográficas, como estados ou zonas urbanas. Cada abstração contribui para a modelagem de fenômenos espaciais de forma estruturada e eficaz (Güting, 1994; Rocha-Junior, 2012).

Sistemas de Gerenciamento de Bancos de Dados Espaciais são organizados para armazenar e gerenciar esse tipo de dado de forma eficiente. Segundo Güting (1994), diferem de representações meramente visuais ao oferecerem suporte a consultas complexas baseadas em relações espaciais, como proximidade ou sobreposição. Esses sistemas são fundamentais para aplicações que exigem análise espacial detalhada.

2.2 Sistemas de recomendação

As SRs são ferramentas computacionais desenvolvidas para auxiliar os usuários a lidar com a sobrecarga de informações, fornecendo sugestões personalizadas com base em suas preferências (Zangerle; Bauer, 2022). Estão presentes em diversos serviços digitais, como plataformas de streaming, e-commerce e redes sociais.

Segundo Aggarwal (2016) e Roy *et al.* (2022), três abordagens são amplamente utilizadas em SRs: Filtragem Colaborativa, Baseada em Conteúdo e Abordagens Híbridas.

A Filtragem Colaborativa fundamenta-se nas opiniões e preferências de um grupo de usuários, identificando padrões e informações relevantes. Essa abordagem utiliza o histórico de visualização e avaliações de usuários com gostos semelhantes (Aggarwal, 2016). Por exemplo, se um usuário A assistiu na Netflix aos filmes: *O Auto da Compadecida* e *Central do Brasil*, e um usuário B assistiu nessa mesma plataforma de streaming aos filmes: *O Auto da Compadecida*, *Central do Brasil* e *Olga*, infere-se que ambos apresentam gostos similares, pois compartilharam as mesmas escolhas iniciais. Nesse caso, o filme *Olga*, já visualizado por B mas ainda não por A, pode ser recomendado ao usuário A, considerando que históricos semelhantes tendem a indicar preferências convergentes.

A Recomendação Baseada em Conteúdo concentra-se na análise de itens previamente avaliados por um usuário, criando um perfil de interesses a partir dessas avaliações. Nesse processo, o sistema compara o perfil com os atributos dos itens da aplicação, recomendando aqueles que apresentam maior similaridade (Aggarwal, 2016). Por exemplo, em um aplicativo de streaming de música, as preferências do usuário podem orientar a recomendação de faixas com características semelhantes, como gênero, ritmo e tom, oferecendo uma recomendação compatível com o perfil construído. Uma limitação dessa abordagem consiste em identificar itens distintos para recomendação, permanecendo restrita a itens similares. Dessa forma, a descoberta de novos conteúdos torna-se mais limitada, reduzindo a diversidade das recomendações.

As Abordagens Híbridas combinam de forma sinérgica técnicas como a Filtragem Colaborativa e a Baseada em Conteúdo, reunindo os benefícios de ambas para aprimorar a qualidade das recomendações. Nessa estratégia, considera-se não apenas as preferências de usuários semelhantes e as características intrínsecas dos itens, mas também técnicas de análise de grandes volumes de dados (Roy; Dutta, 2022). O resultado são recomendações mais refinadas e adaptadas. Por exemplo, o iFood combina informações sobre o histórico de pedidos de cada usuário com padrões coletivos de consumo em determinadas regiões (Granado *et al.*, 2025).


Além das abordagens tradicionais, técnicas de Aprendizado de Máquina têm sido amplamente empregadas, possibilitando a análise automatizada de grandes volumes de dados e a identificação de padrões de comportamento dos usuários. Nesse contexto, algoritmos de aprendizado supervisionado e não supervisionado são utilizados para modelar interações passadas e prever itens de interesse (Han *et al.*, 2024). Por exemplo, em aplicações que envolvem a recomendação de locais para negócios, a utilização de Aprendizado de Máquina permite identificar padrões geográficos e demográficos relevantes para a escolha estratégica de um ponto comercial.

Outras técnicas da área de Inteligência Artificial também vêm sendo aplicadas em SRs, como algoritmos baseados em Lógica *Fuzzy* e *Clusters*. A Lógica *Fuzzy*, por exemplo, possibilita lidar com incertezas e subjetividades nas preferências dos usuários, refinando as sugestões com base em múltiplos critérios (Álvarez; Zarazaga-Soria; Baldassarri, 2020).

2.3 Arquitetura dos sistemas de recomendação

A arquitetura de um SR refere-se à estrutura fundamental que define seus componentes e o modo como se dá o seu funcionamento. De acordo com Tiwari *et al.* (2012), um SR é formalmente composto por um conjunto de usuários (U) e um conjunto de itens disponíveis para recomendação (I), em que uma função operacional ($f: U \times I \rightarrow R$) é responsável por mapear as interações dos usuários com os itens. Nesse caso, R representa um conjunto ordenado de um ou mais números positivos em determinado intervalo, podendo corresponder, por exemplo, a uma classificação em escala de cinco estrelas ou a uma avaliação binária — *Gostei* (1) ou *Não gostei* (0) — conforme descrito por Khushro, Ali e Ullah (2016). Essa arquitetura constitui a base para compreender a complexidade e o funcionamento dos SR em relação a seus usuários.

Figura 1 – Arquitetura genérica de um sistema de recomendação



Fonte: elaborado pelos autores

As interações entre usuários e itens podem incluir visualizações, avaliações, adição a listas ou favoritos, entre outras ações. A estrutura de dados pode ser modelada por grafos ou matrizes, sendo

possível incorporar informações sobre os itens, os usuários e o contexto, a fim de personalizar as recomendações.

A Figura 1 apresenta uma arquitetura genérica de um SR, ilustrando as interações entre usuários individuais ou grupos de usuários com perfis semelhantes e o Sistema de Recomendação de Filmes. De modo hipotético, considerando que todos os filmes possuem características como gênero e ano, na primeira interação o usuário João visualizou o Filme A, adicionou-o à lista de favoritos e expressou sua preferência positiva pelo Filme B.

Em seguida, usuários com perfis semelhantes ao de João visualizaram o Filme B, adicionaram o Filme C a suas listas de favoritos e também expressaram preferência positiva por ele. Por fim, João interage novamente com o sistema e recebe como recomendação o Filme C.

Essas interações são capturadas por um processo denominado Coletor de Interações, módulo responsável por registrar e organizar todos os sinais de comportamento do usuário dentro da aplicação, conforme a abordagem aplicada.

As informações coletadas são, então, armazenadas em uma Base de Dados, que alimenta o SR. Esse sistema pode recorrer a técnicas baseadas em conteúdo ou à filtragem colaborativa, entre outras possibilidades.

2.4 Sistemas de recomendação com dados espaciais

SRs que utilizam dados espaciais integram a localização do usuário em tempo real (dados dinâmicos) ou dos itens, como um restaurante (dados estáticos), para gerar sugestões mais contextualizadas. Esses sistemas podem utilizar dados espaciais como entrada (visando melhorar a qualidade das recomendações) ou como saída (quando os próprios itens recomendados apresentam atributos espaciais), como demonstrado por Acharya, Yadav e Mohbey (2023), Vahidnia (2022) e Artemenko, Pasichnyk e Kunanets (2020).

Um exemplo é a recomendação de pontos de interesse turísticos com base na localização atual, nas categorias e na proximidade, que tem se mostrado eficiente na personalização das sugestões (Luo *et al.*, 2023). Já Vahidnia (2022) propõe uma abordagem que pondera a influência da distância e da similaridade de preferências entre usuários para recomendar locais. Essas estratégias são particularmente relevantes em aplicações como mobilidade urbana, turismo, redes sociais e serviços de entrega, nos quais a localização desempenha papel central na tomada de decisão do usuário.

2.5 Trabalhos relacionados

O estudo de Weydemann, Sacharidis e Werthner (2019) constitui um trabalho de revisão sistemática focado na categorização precisa das avaliações em SR espaciais. Os autores investigam as decisões algorítmicas desses sistemas ao recomendar objetos espaciais, como pontos de interesse e áreas geográficas, além de quantificar critérios de equidade, sobretudo em relação a vieses derivados da popularidade de locais, frequentemente influenciada pelos perfis de usuários que moldam as preferências de grupos nesses sistemas.

Embora compartilhe a metodologia de revisão sistemática com o presente estudo, o trabalho de Weydemann, Sacharidis e Werthner (2019) concentra-se exclusivamente na avaliação dos SRs. Em contraste, este mapeamento sistemático é mais abrangente, ao explorar outras temáticas e apresentar sete questões de pesquisa secundárias: QS2.1: Qual a origem desses dados? QS2.2: Quais dados espaciais são extraídos? QS2.3: O que é recomendado? QS2.4: Qual tipo de dado espacial é recomendado? QS2.5: Dados espaciais são recomendados? QS2.6: Como é calculada a distância no experimento? e QS2.7: Qual técnica é utilizada para melhorar o desempenho dos Sistemas de Recomendação?

O estudo de Tiwari *et al.* (2012) também constitui uma revisão sistemática, voltada à investigação de trabalhos que empregam SR baseados em dados espaciais para fornecer recomendações automatizadas a usuários móveis, considerando sua localização atual e preferências. A pesquisa destaca o papel da localização do usuário e da integração de dados geoespaciais e pontos de interesse para sugerir locais, como restaurantes, alinhados aos gostos pessoais. O estudo também

aborda os desafios de implementação e avaliação, além das aplicações potenciais em áreas como turismo, medicina, arqueologia e estudos ambientais.

Embora compartilhe a metodologia de revisão sistemática com o presente artigo, o estudo de Tiwari *et al.* (2012) concentra-se em uma análise qualitativa dos desafios encontrados no desenvolvimento desses sistemas. Em contraste, este estudo realizou um levantamento abrangente de publicações no período de 2003 a junho de 2024, oferecendo quase vinte anos de cobertura. Assim, apresenta um mapeamento mais amplo e uma visão quantitativa acerca das técnicas e abordagens empregadas.

O artigo de Roy e Dutta (2022) analisa a crescente importância dos SR como ferramentas cruciais para filtrar informações on-line, ressaltando sua popularidade diante das mudanças nos hábitos de usuários da internet. Já o artigo de Zangerle e Bauer (2022), também uma revisão sistemática, busca sistematizar e consolidar o conhecimento disperso sobre a avaliação do desempenho dos SR, construindo uma estrutura para essa finalidade.

Embora compartilhem a abordagem de revisão sistemática, esses estudos não exploram o uso de dados espaciais, debruçando-se apenas sobre SR em geral. Em contraste, o presente artigo foca nos SR que incorporam dados espaciais, abrangendo uma área da literatura ainda pouco investigada.

3 Método da pesquisa

Este estudo adota uma abordagem teórica, exploratória e quantitativa, fundamentada em um Mapeamento Sistemático da Literatura (MSL). Embora semelhantes em estrutura, a revisão sistemática e o mapeamento sistemático possuem finalidades distintas. A revisão sistemática busca responder a uma questão específica com profundidade, avaliando metodologicamente os estudos incluídos (Kitchenham; Charters, 2007). Já o mapeamento sistemático tem como objetivo oferecer uma visão quantitativa da literatura sobre determinado tema, identificando padrões, lacunas e tendências (Kitchenham; Charters, 2007).

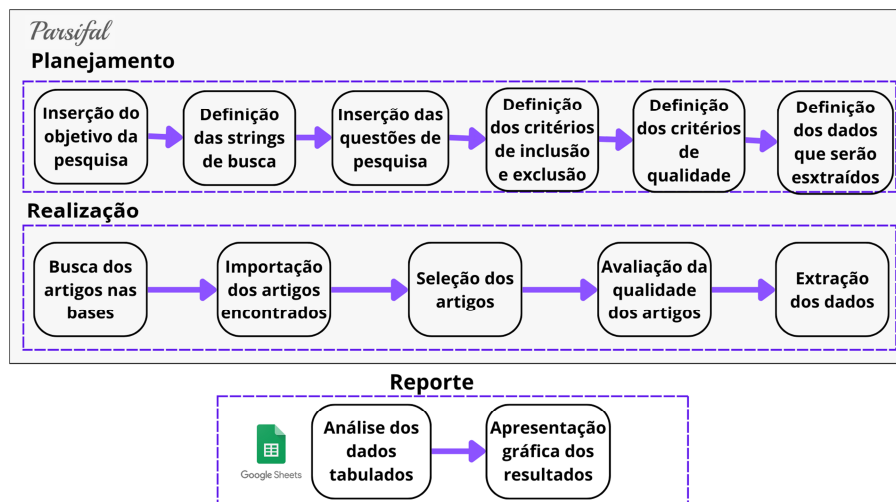
Neste trabalho, optou-se pelo mapeamento sistemático, visto que o objetivo central é identificar como os dados espaciais têm sido utilizados em SRs, verificando quais técnicas são mais recorrentes, quais são as fontes de dados mais utilizadas, os tipos de dados empregados e os métodos de avaliação aplicados.

O caráter teórico permite fundamentar a investigação em conceitos consolidados; a natureza exploratória possibilita examinar diferentes abordagens e aplicações de dados espaciais em SRs; e a abordagem quantitativa viabiliza a categorização mensurável da produção científica da área (Prodanov; Freitas, 2013; Wagner; Carolina; Paula, 2023).

Este MSL segue diretrizes estabelecidas por Kitchenham e Charters (2007), que preconizam rigor metodológico, ampla cobertura na busca de artigos e transparência na extração e análise dos dados. A operacionalização metodológica foi realizada com auxílio da ferramenta *Parsifal*¹, que possibilita organizar protocolos, aplicar filtros e conduzir extrações sistemáticas a partir de critérios claros e replicáveis. O processo metodológico foi dividido em três etapas principais: Planejamento, Realização e Reporte, conforme ilustrado na Figura 2. Cada etapa é detalhada a seguir.

Figura 2 – Etapas do processo metodológico

¹ Link da plataforma *Parsifal*: <https://parsif.al>



Fonte: adaptado de Kitchenham e Charters (2007)

3.1 Planejamento

Nesta etapa foram definidas as questões de pesquisa, os objetivos correspondentes, os critérios de inclusão e exclusão dos estudos, a estratégia de busca e as bases de dados a serem consultadas.

A Tabela 1 apresenta a relação entre as três Questões Primárias de Pesquisa (QP) e os objetivos específicos da investigação. A primeira questão busca identificar quais técnicas são empregadas em SRs que utilizam dados espaciais, com o objetivo de categorizá-las. A segunda questão investiga os tipos de dados espaciais extraídos, suas origens e aplicações nos sistemas analisados. Por fim, a terceira questão visa compreender os métodos empregados para avaliar essas técnicas, considerando critérios experimentais e métricas de comparação.

Tabela 1 – Questões de pesquisa e objetivos específicos

Questão de pesquisa	Objetivo
QP1. Quais são as técnicas utilizadas em Sistemas de Recomendação que utilizam dados espaciais?	Identificar e categorizar as técnicas aplicadas em Sistemas de Recomendação com dados espaciais
QP2. Quais dados espaciais são extraídos e como são utilizados nesses sistemas?	Compreender a origem, o tipo e a aplicação dos dados espaciais utilizados
QP3. Como as técnicas de recomendação são avaliadas nos estudos analisados?	Mapear os métodos e métricas empregados para avaliar os sistemas analisados

Fonte: dados da pesquisa

3.2 Realização

A busca pelos estudos foi realizada em quatro bases científicas amplamente reconhecidas na área de Ciência da Computação: Scopus, IEEE Xplore, ACM Digital Library e ScienceDirect. Essas bases foram escolhidas por sua relevância, abrangência e por incluírem periódicos e conferências de referência, como a SIGSPATIAL e a ISPRS.

A estratégia de busca foi elaborada com base na metodologia PICOC (*Population, Intervention, Comparison, Outcome e Context*), contemplando os seguintes elementos: *Population* (Sistemas de Recomendação), *Intervention* (integração de dados espaciais), *Comparison* (sistemas que utilizam ou não dados espaciais), *Outcome* (melhoria na precisão das recomendações) e *Context* (plataformas digitais e redes sociais com dados de localização).

A expressão de busca adotada foi: ("recommendation" OR "recommender") AND "location", aplicada exclusivamente aos títulos dos artigos.

O recorte temporal compreendeu o período de janeiro de 2003 a junho de 2024. Esse intervalo foi definido de forma empírica, uma vez que os primeiros trabalhos relevantes sobre o uso de dados espaciais em SRs foram encontrados a partir de 2003, alcançando até às pesquisas mais recentes. A busca resultou em 1.217 artigos, distribuídos da seguinte forma: Scopus com 778 publicações (63,9%), IEEE Xplore com 234 (19,2%), ACM Digital Library com 141 (11,6%) e ScienceDirect com 64 (5,3%).

Após a coleta inicial, iniciou-se a seleção dos estudos em duas fases. Na primeira, foram aplicados critérios de inclusão e exclusão com base na leitura de títulos, resumos e palavras-chave. Foram considerados apenas artigos primários, publicados em inglês, com extensão mínima de seis páginas e que apresentassem abordagem teórica voltada à integração de dados espaciais em SRs. Excluíram-se documentos duplicados, capítulos de livros, editoriais, relatórios de workshops, estudos secundários ou terciários, literatura cinzenta e artigos indisponíveis. Ao final desta etapa, 300 artigos permaneceram elegíveis para análise completa.

Na segunda fase, os 300 artigos foram submetidos à leitura integral e avaliação de qualidade. Três critérios foram utilizados: (i) publicação em periódico ou conferência de relevância (classificação Qualis A); (ii) identificação da técnica utilizada no modelo proposto; e (iii) descrição clara e replicável do método de avaliação. Cada critério correspondia a um ponto com o mesmo peso e, para aprovação, o artigo deveria atingir pontuação máxima (3 pontos). Ao final, 199 artigos foram aprovados e selecionados para a extração de dados.

A etapa de extração consistiu na leitura aprofundada dos artigos selecionados, conduzida por um único pesquisador. A leitura integral por apenas um pesquisador foi adotada em virtude da indisponibilidade de outro profissional para realizar essa análise detalhada. Para mitigar essa limitação, foi implementado um processo sistemático de leitura em duas etapas, no qual dúvidas relacionadas à extração eram discutidas com um segundo pesquisador.

A ferramenta *Parsifal* foi utilizada exclusivamente como apoio à seleção e à organização dos estudos. As informações extraídas foram registradas em formulário estruturado, contemplando categorias como identificação do artigo (ID), título, revisor responsável, data da extração e respostas para cada Questão Primária de Pesquisa (QP), além de eventuais Questões Secundárias (QS).

Para determinadas QPs, estabeleceram-se QS específicas que auxiliaram no detalhamento de aspectos mapeáveis. Os dados extraídos foram sistematizados em planilhas, permitindo análises quantitativas. Esses resultados foram agrupados de acordo com as três questões de pesquisa e são apresentados na seção 4, acompanhados de gráficos, tabelas e análises interpretativas.

4 Resultados e discussões

Nesta seção, os resultados são apresentados de forma estruturada, respondendo às três Questões de Pesquisa delineadas previamente. Os achados foram organizados em gráficos, tabelas e análises descritivas, possibilitando uma visão clara sobre as técnicas empregadas, as fontes e os tipos de dados espaciais utilizados, bem como os métodos de avaliação adotados nos estudos analisados.

4.1 Técnicas utilizadas em sistemas de recomendação com dados espaciais

A análise da literatura identificou diversas técnicas empregadas em SRs que integram dados espaciais, atingindo o objetivo específico referente à QP1. Entre as técnicas identificadas, destacam-se o Aprendizado de Máquina (AM), a Filtragem Colaborativa (FC), métodos híbridos que combinam aspectos de colaboração e conteúdo, além da integração de AM com outras abordagens, como Filtragem Colaborativa e Estruturas de Grafos. Como exemplo, estudos híbridos aplicados a recomendações de Pontos de Interesse (POI) têm demonstrado ganhos significativos, superando os métodos de base em termos de *precision* e *recall*. Também foram observadas técnicas diversas, incluindo aquelas baseadas em Inteligência Artificial (IA) e em modelos matemáticos.

A Tabela 2 apresenta a nomenclatura adotada para cada técnica identificada e suas abreviações.


Tabela 2 – Técnicas identificadas e respectivas abreviações

Técnica identificada	Abreviação
Filtragem Colaborativa	FC
Aprendizado de Máquina	AM
Outras Técnicas Baseadas em Modelos Matemáticos	OTMM
Híbrido	H
Estruturas Gráficas ou Espaciais	EGE
Outras Técnicas de IA	OIA
Outras Técnicas	OT
Baseado em Conteúdo	BC
Baseado em Contexto	BX
Baseado em Casos	BCS

Fonte: dados da pesquisa

A Figura 3 apresenta a distribuição percentual de cada técnica. A mais recorrente foi a FC, com 32,7%, seguida por AM, com 26,1%. Abordagens híbridas (H) somaram 10,1%, enquanto OTMM representaram 12,1% e EGE, 8,5%, indicando presença significativa.


Figura 3 – Distribuição percentual das técnicas identificadas



Fonte: dados da pesquisa

A diversidade de técnicas aponta uma evolução da área, com crescimento no uso de estratégias combinadas e fundamentadas em IA. O destaque da FC e do AM demonstra que métodos colaborativos e de aprendizado de máquina são centrais nos sistemas que integram dados espaciais.

A Figura 4 ilustra a evolução temporal das técnicas identificadas entre 2003 e junho de 2024. Nos primeiros anos (2003-2011), observou-se baixa ocorrência, com predominância de FC. A partir de 2012, verificou-se um crescimento expressivo da utilização de AM, coincidente com a expansão de aplicações móveis baseadas em localização, como Uber e iFood.



Fonte: dados da pesquisa

O período de 2015 a 2020 correspondeu ao auge das publicações na área, refletindo o amadurecimento do campo com a consolidação de tecnologias como Big Data e Inteligência Artificial (IA). Entre 2021 e 2024, registrou-se uma leve redução no número de publicações, possivelmente em decorrência da limitação temporal de 2024 e da crescente dispersão das pesquisas relacionadas ao tema. Além disso, há também uma mudança qualitativa, marcada pelo aumento das abordagens híbridas, sobretudo com o uso de grafos e modelos de aprendizado de máquina combinados.

A ascensão dessas estratégias reflete a busca por maior robustez e precisão nas recomendações, superando limitações das abordagens isoladas. Em síntese, os resultados revelam que a FC permanece central, dada sua simplicidade e eficácia histórica. Entretanto, nota-se tendência crescente de adoção de técnicas baseadas em IA e métodos híbridos, impulsionada pela complexidade dos dados espaciais e pelo avanço de aplicações contextuais, personalizadas e em tempo real.


4.2 Extração e uso de dados espaciais nos sistemas de recomendação

Esta subseção aborda os aspectos relacionados à extração, natureza e aplicação dos dados espaciais nos SRs, atendendo ao objetivo da QP2. Foram analisadas sete Questões de Pesquisa Secundárias (QS) que detalham a origem, o tipo de dado espacial extraído e recomendado, bem como as estratégias para cálculo de distância e aprimoramento dos SRs.

4.2.1 Origem dos dados espaciais (QS2.1)

A análise revelou que a principal fonte de dados espaciais corresponde às redes sociais baseadas em localização (como Foursquare, Gowalla e Brightkite), representando 51,3% dos casos, conforme ilustrado na Figura 5. Esses dados refletem a interação dos usuários com locais específicos, sendo amplamente utilizados mesmo após a descontinuação de algumas dessas plataformas. Considerando a dependência de dados oriundos de serviços descontinuados, como Gowalla e Brightkite, essa limitação pode comprometer a replicabilidade dos estudos e a continuidade das pesquisas na área, exigindo que trabalhos futuros considerem fontes alternativas ou estratégias de preservação dos dados históricos.

Figura 5 – Fontes de dados espaciais utilizadas nos estudos



Fonte: dados da pesquisa


Outras fontes identificadas incluem plataformas de turismo (TripAdvisor), serviços web (WS-Dream), aplicativos de mobilidade e *datasets* públicos. Essa predominância evidencia a interdependência entre redes sociais e SRs baseados em localização, nos quais a personalização depende do contexto geográfico dos usuários.

Esse resultado indica a popularização das redes sociais como principal fonte de dados espaciais, o que reflete na crescente interdependência entre essas plataformas e os SRs. Enquanto as redes sociais dependem de algoritmos de recomendação para personalizar conteúdos, maximizar engajamento e manter usuários ativos, os SRs utilizam os dados espaciais coletados para oferecer sugestões mais precisas e contextuais, como recomendações de locais, eventos e serviços.

4.2.2 Tipo de dado espacial extraído (QS2.2)

A Figura 6 apresenta os tipos de dados espaciais extraídos. Os dados envolvem, predominantemente, a localização do usuário (75,3%), seguida pela localização de estabelecimentos, trajetórias e serviços. Vale destacar que a localização mencionada pode ser estática (posição fixa, como cidade ou bairro) ou dinâmica (trajetória em tempo real durante deslocamentos). Esses resultados sugerem que a preferência pelo uso da localização do usuário pode estar associada à facilidade de obtenção dessas informações, sobretudo em dispositivos móveis com geolocalização integrada.

Figura 6 – Percentual dos tipos de dados espaciais extraídos




Fonte: dados da pesquisa

Entretanto, a menor representatividade das demais categorias evidencia possíveis desafios relacionados à coleta e à integração de informações espaciais mais complexas.

Em termos geométricos, conforme a classificação apresentada na Seção 2.1, a maioria dos dados corresponde ao tipo ponto (96%), representando locais com coordenadas específicas, como restaurantes (Figura 7). Dados do tipo linha (rotas) apresentam baixa ocorrência, e praticamente não há menção ao uso de regiões delimitadas.

Figura 7 – Características espaciais dos dados extraídos (ponto, linha, região)




Fonte: dados da pesquisa

4.2.3 O que é recomendado (QS2.3)

A Figura 8 apresenta os elementos recomendados pelos SRs espaciais. A maioria corresponde a Pontos de Interesse (POIs), com 141 ocorrências, abrangendo, de acordo com a literatura, locais turísticos, lojas, restaurantes e serviços específicos. Também foram identificadas recomendações de categorias não espaciais, como serviços, itens, amigos e músicas.

Figura 8 – Tipos de elementos recomendados pelos SRs espaciais




Fonte: dados da pesquisa

4.2.4 Tipo de dado espacial recomendado (QS2.4)

A Figura 9a apresenta a distribuição das características dos dados recomendados nos artigos analisados. Pontos ou localizações destacam-se, sendo mencionados em 141 dos 199 artigos avaliados. Apenas três artigos fazem referência a linhas (rotas ou trajetórias), e não houve menção a regiões (áreas). A baixa ocorrência da menção a linhas pode ser explicada pela maior complexidade desse tipo de métrica, visto que a distância precisa ser computada por meio de um algoritmo de caminho mínimo, por exemplo. Em relação à ausência de regiões, a principal hipótese é que a maioria das consultas se concentram em pontos específicos, embora essa questão demande investigação mais aprofundada.

Figura 9 – Dados recomendados. (a) Tipo de dado recomendado. (b) Recomenda dados espaciais



Fonte: dados da pesquisa

Essa predominância de pontos ou localizações (70% dos trabalhos) indica uma forte tendência ao uso de SRs que recomendam pontos de interesse. Isso sugere que esses sistemas priorizam sugestões de locais específicos, como restaurantes, pontos turísticos e estabelecimentos comerciais, para atender às necessidades dos usuários.

4.2.5 Recomendação espacial (QS2.5)

Nos artigos analisados, a maioria revela que os SRs que incorporam dados espaciais efetivamente os utilizam para fornecer recomendações. A Figura 9b mostra que 73% dos trabalhos analisados indicam que os SRs recomendam dados espaciais, ao passo que 27% não o fazem. Embora menos frequente, a recomendação de serviços, músicas ou outros itens não espaciais também pode ser relevante para os usuários, permitindo-lhes acompanhar tendências ou influências locais.

A partir da análise da Figura 9b, observa-se que os SRs que utilizam dados espaciais têm como objetivo principal recomendar informações baseadas em localização. Esses sistemas, em geral, priorizam pontos de interesse, trajetos ou outras informações geograficamente relevantes. Entretanto, tais dados também podem ser utilizados de forma indireta, a fim de melhorar a precisão e a utilidade de recomendações diversas oferecidas aos usuários.

4.2.6 Cálculo de distância (QS2.6)


Nos artigos analisados, a distância entre o usuário e um item recomendado é calculada de duas formas principais: por medidas espaciais, que consideram a posição geográfica, e por medidas não espaciais, que utilizam comparações baseadas em características textuais, estatísticas ou categóricas.

O primeiro grupo inclui abordagens que medem a distância entre objetos espaciais, como a Distância Euclidiana, o Caminho Mais Curto, entre outras. Essas técnicas, fundamentadas em coordenadas geográficas, permitem calcular a proximidade entre pontos no espaço.

O segundo grupo abrange abordagens que não mensuram diretamente a distância entre objetos espaciais, mas se baseiam em outros critérios para avaliar similaridade ou proximidade. Métodos como a Distância de Jaccard e a Distância de Hamming operam com dados categóricos, estatísticos ou textuais, sendo úteis em cenários em que a recomendação se fundamenta em atributos dos itens, como preferências de usuários e características de produtos.

A Figura 10 apresenta as abordagens utilizadas para o cálculo de distâncias espaciais em SR. A Distância Euclidiana é a mais empregada, sendo mencionada em 43 artigos. Em seguida, o Caminho Mais Curto aparece em 19 artigos, seguido pela Distância de Haversine, com 12 ocorrências. O Método Gaussiano Multicêntrico foi identificado em 6 estudos, enquanto outras abordagens menos recorrentes (Equação Própria do Estudo, Matriz de Proximidade Geográfica, Cálculo de Centróides, Distância de Manhattan, Distância de Vincenty e Distância Ortodrômica) totalizam 7 ocorrências, agrupadas como “Demais Abordagens”.

Figura 10 – Abordagens para cálculo de distância espacial




Fonte: dados da pesquisa

A predominância da Distância Euclidiana indica que esse método é eficiente para calcular a distância direta entre dois pontos, sendo particularmente útil em sistemas que demandam rapidez na estimativa de proximidade. No entanto, técnicas como o Caminho Mais Curto e a Distância de Haversine destacam-se pela aplicabilidade em trajetos reais. A Distância de Haversine, por exemplo, é empregada para calcular distâncias entre coordenadas geográficas expressas em latitude e longitude, sendo essencial em aplicações de mobilidade urbana.

A Figura 11 apresenta as abordagens utilizadas para o cálculo de distâncias não espaciais em SR. Um exemplo é quando um aplicativo sugere um restaurante visitado por um amigo, não com base na localização geográfica, mas em preferências compartilhadas. A abordagem “Por Similaridade” é a mais recorrente, identificada em 58 estudos. A Distância de Jaccard aparece em 7 artigos, enquanto a abordagem “Por Classificação do Usuário” é mencionada em 5 artigos. Outras abordagens menos frequentes, agrupadas como “Demais Abordagens” (Peso de Amostragem, Distância de Bregman, Distância de Hamming, Distância de Kullback-Leibler, Distância de Leibler, Distorção Temporal Dinâmica, Função Vulcão, Lei de Potência Truncada, Limite de Hoeffding, Meta-caminho), somam 11 ocorrências.

O predomínio da abordagem “Por Similaridade” destaca a importância da comparação de atributos, como preferências e comportamentos de usuários, na formulação de recomendações. Isso se relaciona diretamente ao uso de redes sociais, em que a similaridade entre usuários, locais visitados e interações registradas constituem um fator crucial para a personalização das sugestões. Algoritmos de recomendação empregados em plataformas como Facebook, Instagram e Google Maps utilizam esses cálculos para sugerir locais, amigos e serviços com base em padrões comportamentais semelhantes (Das *et al.*, 2007). Essa distinção evidencia a flexibilidade dos SRs em utilizar tanto a localização física quanto padrões de comportamento para definir proximidade e relevância.

Figura 11 – Abordagens para cálculo de distância não espacial



Fonte: dados da pesquisa


O predomínio da abordagem “Por Similaridade” destaca a importância da comparação de atributos, como preferências e comportamentos de usuários, na formulação de recomendações. Isso se relaciona diretamente ao uso de redes sociais, em que a similaridade entre usuários, locais visitados e interações registradas constitui fator crucial para a personalização das sugestões. Algoritmos de recomendação empregados em plataformas como Facebook, Instagram e Google Maps utilizam esses cálculos para sugerir locais, amigos e serviços com base em padrões comportamentais semelhantes. Essa distinção evidencia a flexibilidade dos SRs em utilizar tanto a localização física quanto padrões de comportamento para definir proximidade e relevância.

4.2.7 Técnicas para aprimoramento dos SRs (QS2.7)

As abordagens identificadas para o aprimoramento dos SRs que utilizam dados espaciais foram agrupadas em duas categorias.

A Figura 12 apresenta as abordagens baseadas na interpretação de dados, em que se destacam o uso de informações de contexto, com 8 ocorrências, e a agregação temporal, com 6 ocorrências. Essas abordagens favorecem a personalização das recomendações, considerando variáveis como tempo, localização e histórico.


Figura 12 – Abordagens baseadas na interpretação de dados



Fonte: dados da pesquisa

Já a Figura 13 reúne as abordagens fundamentadas em aprendizado de máquina e modelagem avançada, incluindo fatoração de matriz (16 ocorrências), mineração de dados (9), além de *clusters*, grafos e outras técnicas como a Filtragem Colaborativa, Aprendizado de Máquina, Algoritmo Heurístico e Estimativa de Densidade de Kernel. Essas metodologias complementam as técnicas tradicionais e buscam tratar a complexidade e a heterogeneidade dos dados espaciais.

Figura 13 – Abordagens baseadas em aprendizado de máquina e modelagem avançada



Fonte: dados da pesquisa

Cabe ressaltar que tais técnicas não substituem as abordagens principais já utilizadas, como a Filtragem Colaborativa ou os Algoritmos Baseados em Conteúdo, mas são aplicadas de forma complementar. Essa integração é necessária para lidar com particularidades dos dados espaciais, como a modelagem de relacionamentos complexos entre usuários e localizações ou a identificação de padrões temporais.


Em síntese, a análise da QP2 evidencia que os SRs baseados em dados espaciais fundamentam-se, majoritariamente, em informações de localização do usuário, muitas vezes oriundas de redes sociais baseadas em localização. Os objetos recomendados são, em sua maioria, pontos de interesse, sendo os dados do tipo ponto os mais recorrentes. A Distância Euclidiana e métricas de similaridade são amplamente utilizadas para mensuração de proximidade, enquanto abordagens mais sofisticadas, como fatoração de matriz e agregação de contexto, vêm sendo incorporadas para o aprimoramento das recomendações.

4.3 Avaliação das técnicas identificadas

A avaliação das técnicas utilizadas em SRs com dados espaciais foi conduzida por meio de quatro principais abordagens experimentais: *Baseline*, Simulação, Estudo de Caso e Teste A/B, em consonância com o objetivo da QP3.

A Figura 14 apresenta a distribuição dos métodos de avaliação. O *Baseline* mostrou-se a abordagem predominante, utilizada em 163 estudos (82%), funcionando como referência para comparar o desempenho de novas técnicas com métodos já consagrados. A ampla adoção dessa estratégia evidencia sua relevância como parâmetro objetivo de validação em pesquisas acadêmicas.

Figura 14 – Abordagens de avaliação dos experimentos



Fonte: dados da pesquisa

As simulações foram identificadas em 21 estudos (10,5%), permitindo testes em ambientes controlados, com menor interferência de variáveis externas. Essa abordagem é especialmente relevante para validações em estágios iniciais ou quando não há acesso a dados em tempo real.

Os Estudos de Caso, presentes em 15 artigos (7,5%), demonstram a aplicabilidade das técnicas em contextos reais, como aplicativos de mobilidade urbana ou plataformas de turismo.

Por fim, o Teste A/B apareceu em apenas 1 artigo, configurando uma abordagem rara, apesar de seu potencial para capturar preferências reais de usuários em tempo de execução. Esse cenário provavelmente se deve ao fato de que o teste exige modificações no sistema em tempo real para apresentar dois tipos distintos de resultados, além de requerer a participação ativa de usuários durante o experimento. Esse processo pode levantar questões éticas ou de privacidade, especialmente no que se refere ao uso e à localização dos participantes.

Esses resultados evidenciam a forte dependência do *Baseline* como método principal de avaliação, refletindo a prática comum em SRs e Ciência de Dados, nos quais novos algoritmos devem superar técnicas anteriores para demonstrar seu valor.

Além disso, o uso de simulações revela um esforço para reduzir custos computacionais e garantir reprodutibilidade. Técnicas como Aprendizado por Reforço vêm sendo testadas em ambientes sintéticos antes de sua adoção em produção, o que reforça a importância dessa abordagem mesmo diante de desafios operacionais.

5 Conclusões

Esta pesquisa teve como objetivo mapear o uso de dados espaciais no contexto dos SRs. Para isso, foi conduzido um Mapeamento Sistemático da Literatura, oferecendo uma compreensão abrangente sobre o tema, destacando tendências e lacunas, além de refletir sobre limitações, ameaças à validade, lições aprendidas e direções para novos estudos.

O trabalho seguiu rigorosamente as etapas metodológicas recomendadas para mapeamentos sistemáticos, proporcionando uma estrutura organizada e replicável. Foram analisados 199 artigos publicados ao longo de aproximadamente duas décadas, selecionados a partir de critérios claramente definidos e alinhados à estratégia de busca elaborada com base na metodologia PICOC.

Ao distinguir-se de uma revisão sistemática, este estudo se alinha à proposta de mapeamento sistemático por sua abrangência, foco exploratório e categorização da literatura em temas relevantes. A visualização gráfica dos resultados contribuiu para evidenciar a predominância de algumas técnicas consolidadas, como a Filtragem Colaborativa, ao mesmo tempo em que revelou áreas ainda incipientes, como as técnicas baseadas em contexto.

5.1 Principais contribuições

A análise evidenciou que os SRs que integram dados espaciais utilizam, em sua maioria, técnicas tradicionais, como Filtragem Colaborativa, seguidas por abordagens mais recentes baseadas em Aprendizado de Máquina.

O crescimento expressivo das técnicas híbridas a partir de 2019 destaca uma tendência de integração entre modelos distintos, buscando superar limitações individuais e oferecer recomendações mais precisas e personalizadas.

Quanto ao tipo de dado espacial, a localização do usuário, representada por coordenadas geográficas (pontos), é a mais recorrente. Os sistemas tendem a recomendar Pontos de Interesse (POIs), como lojas, restaurantes e locais turísticos, reforçando a ênfase em recomendações baseadas em proximidade. As métricas de distância mais utilizadas incluem Distância Euclidiana e similaridade por atributos, destacando a importância tanto da posição física quanto do perfil comportamental do usuário.

Outro achado relevante refere-se às abordagens de avaliação experimental: a maioria dos estudos recorre ao uso de *baselines* como referência, evidenciando a importância de comparações com métodos já consolidados. Entretanto, a baixa adoção de Testes A/B e Estudos de Caso em contextos reais revela uma oportunidade para práticas mais centradas no usuário, capazes de refletir melhor a efetividade dos sistemas em cenários práticos.

5.2 Desafios emergentes

Apesar de promissor, o Aprendizado de Máquina ainda enfrenta desafios significativos. Conforme apontado por Weydemann *et al.* (2019), um dos principais entraves consiste em equilibrar a diversidade de itens de localização com a tendência de concentração em opções mais populares. Esse desequilíbrio pode restringir a descoberta de novos itens, reduzindo o potencial inovador dos SRs.

Nesse cenário, o crescimento das técnicas híbridas ganha destaque. A combinação de modelos baseados em Inteligência Artificial com métodos tradicionais possibilita explorar o potencial das abordagens emergentes, ao mesmo tempo em que se beneficia da robustez e maturidade de técnicas já estabelecidas. Essa integração apresenta-se como estratégia promissora para mitigar problemas de diversidade e popularidade nas recomendações.

Além dos desafios técnicos, emerge a questão do uso de dados, especialmente em relação às políticas de privacidade. Aplicativos móveis frequentemente coletam informações espaciais e contextuais de forma contínua e, em muitos casos, pouco transparente para o usuário. Embora a integração desses dados amplie o valor analítico das recomendações, também intensifica riscos relacionados ao rastreamento não autorizado e ao uso indevido de informações pessoais.

5.3 Limitações

A principal limitação desta pesquisa reside na exclusão de estudos secundários e terciários, como revisões sistemáticas e meta-análises, o que restringe a visão global sobre o estado da arte.

Além disso, embora inicialmente quatro questões de pesquisa tenham sido definidas, apenas três foram abordadas em virtude das limitações de tempo. Isso reduziu a abrangência da análise em aspectos complementares, como arquitetura de sistemas e mecanismos de atualização dinâmica.

5.4 Ameaças à validade

As etapas de realização e reporte foram conduzidas por um único pesquisador, configurando ameaça à validade interna e à confiabilidade dos resultados. Para mitigar esse risco, adotou-se um processo de leitura em duas etapas e validação das interpretações junto ao orientador. Ainda assim, reconhece-se a possibilidade de viés subjetivo na categorização e análise de conteúdos ambíguos.

5.5 Lições aprendidas

A utilização da ferramenta Parsifal mostrou-se essencial para garantir rastreabilidade, consistência e economia de tempo na extração e organização dos dados.

Adicionalmente, compreender a estrutura padrão dos artigos (introdução, metodologia, resultados) revelou-se uma estratégia eficiente para sistematizar o processo de análise, aumentando a precisão e a confiabilidade das informações coletadas.

5.6 Trabalhos futuros

Como continuidade deste trabalho, propõe-se a aplicação da estratégia *Snowball* para expandir o conjunto de estudos analisados, além da realização de uma Revisão Sistemática com metanálise, que permitirá um exame mais aprofundado dos resultados obtidos.

Também se recomenda investigar a questão inicialmente planejada e não abordada: *quais os principais componentes arquiteturais presentes em sistemas de recomendação com dados espaciais?* Essa investigação poderá elucidar a forma como módulos como coleta, processamento, modelagem e recomendação se articulam nesses sistemas.

Além disso, sugere-se mapear as principais métricas empregadas para avaliar os SRs, como *precision*, *recall* e *F1-score*.

Financiamento

O autor principal deste artigo recebeu bolsa da Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES) no período de 01/04/2023 a 29/02/2024 para realizar essa pesquisa.

Conflito de interesses

Os autores declaram não haver conflito de interesses.

Nota

Este artigo é derivado de dissertação do curso de Mestrado em Ciência da Computação da Universidade Estadual de Feira de Santana (UEFS), disponível em: <http://tede2.uefs.br:8080/handle/tede/1888>.

Contribuições ao artigo

PEREIRA, A. F.: concepção e desenho do estudo/pesquisa; análise e interpretação dos dados.
ROCHA-JUNIOR, J. B.: concepção e desenho do estudo/pesquisa. Todos os autores participaram da escrita, discussão, leitura e aprovação da versão final do artigo.

Referências

ACHARYA, M.; YADAV, S.; MOHBHEY, K. K. How can we create a recommender system for tourism? A location centric spatial binning-based methodology using social networks. **International Journal of Information Management Data Insights**, v. 3, n. 1, e100161, 2023. DOI: <https://doi.org/10.1016/j.jjime.2023.100161>.

AGGARWAL, C. C. **Recommender systems**. The textbook. Cham: Springer, 2016. DOI: <https://doi.org/10.1007/978-3-319-29659-3>.

ÁLVAREZ, P.; ZARAZAGA-SORIA, F. J.; BALDASSARRI, S. Mobile music recommendations for runners based on location and emotions: the DJ-running system. **Pervasive and Mobile Computing**, v. 67, e101242, 2020. DOI: <https://doi.org/10.1016/j.pmcj.2020.101242>.

ANGELIS, S.; KOTIS, K.; SPILIOTOPOULOS, D. Semantic trajectory analytics and recommender systems in cultural spaces. **Big Data and Cognitive Computing**, v. 5, n. 4, e80, 2021. DOI: <https://doi.org/10.3390/bdcc5040080>.

ARTEMENKO, O.; PASICHNYK, V.; KUNANETS, N. Using mobile location-based recommender systems for providing real time recommendations for social distancing urban route planning. *In*: 2020

IEEE INTERNATIONAL CONFERENCE ON COMPUTER SCIENCES AND INFORMATION TECHNOLOGIES, 15., 2020, Zbarazh. **Proceedings [...]**. Zbarazh: IEEE, 2020, p. 305-308. DOI: <https://doi.org/10.1109/CSIT49958.2020.9321969>.

DAS, A. S.; DATAR, M.; GARG, A.; RAJARAM, S. Google news personalization: scalable online collaborative filtering. *In: INTERNATIONAL CONFERENCE ON WORLD WIDE WEB (WWW)*, 16., 2007, Banff Alberta. **Proceedings [...]**. New York: ACM, p. 271-280, 2007. DOI: <https://doi.org/10.1145/1242572.1242610>.

GRANADO, F. F.; BEZERRA, D. A.; QUEIROZ, I.; OLIVEIRA, N.; FERNANDES, P.; SCHOCK, B. Personalized recommendation of dish and restaurant collections on iFood. **arXiv**, 2025. DOI: <http://dx.doi.org/10.48550/arXiv.2508.03670>.

GÜTING, R. H. An introduction to spatial database systems. **The VLDB Journal**, v. 3, p. 357-399, 1994. DOI: <https://doi.org/10.1007/BF01231602>.

HAN, S.; CHEN, L.; SU, Z.; GUPTA, S.; SIVARAJAH, U. Identifying a good business location using prescriptive analytics: restaurant location recommendation based on spatial data mining. **Journal of Business Research**, v. 179, e114691, 2024. DOI: <https://doi.org/10.1016/j.jbusres.2024.114691>.

IVANOVA, I.; ANDRIĆ, M.; RICCI, F. Content-based recommendations for crags and climbing routes. *In: STIENMETZ, J. L.; FERRER-ROSELL, B.; MASSIMO, D. (ed.). Information and Communication Technologies in Tourism 2022*. ENTER, p. 369-381, 2022. DOI: https://doi.org/10.1007/978-3-030-94751-4_33.

KHUSRO, S.; ALI, Z.; ULLAH, I. Recommender systems: issues, challenges, and research opportunities. *In: KIM, K., JOUKOV, N. (eds) Information Science and Applications (ICISA) 2016*. Lecture Notes in Electrical Engineering, v. 376, p. 1179-1189, Singapore, 2016. DOI: https://doi.org/10.1007/978-981-10-0557-2_112.

KITCHENHAM, B.; CHARTERS, S. **Guidelines for performing systematic literature reviews in software engineering**. Relatório técnico EBSE 2007-001. Keele University; Durham University, 2007. Disponível em: https://legacyfileshare.elsevier.com/promis_misc/525444systematicreviewsguide.pdf. Acesso em: 13 setembro 2025.

LUO, Y.; DUAN, H.; LIU, Y.; CHUNG, F. L. Timestamps as prompts for geography-aware location recommendation. *In: ACM INTERNATIONAL CONFERENCE ON INFORMATION AND KNOWLEDGE MANAGEMENT (CIKM 23)*, 32., 2023, Birmingham. **Proceedings [...]**. New York: ACM, p. 1697-1706, 2023, Birmingham. DOI: <https://doi.org/10.1145/3583780.3615083>.

PEBESMA, E.; BIVAND, R. **Spatial data science: with applications in R**. CRC Press, 2023.

PRODANOV, C. C.; FREITAS, E. C. **Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico**. 2. Ed. Novo Hamburgo: Editora Feevale, 2013. Disponível em: <https://www.feevale.br/institucional/editora-feevale/metodologia-do-trabalho-cientifico---2-edicao>.

ROCHA-JUNIOR, J. B. **Efficient processing of preference queries in distributed and spatial databases**. 2012. Doctoral Thesis (Doutorado em Ciência da Computação) – Norwegian University of Science and Technology, Trondheim, 2012. Disponível em: <https://ntnuopen.ntnu.no/ntnu-xmlui/handle/11250/253131>. Acesso em: 27 agosto 2025.

ROY, D.; DUTTA, M. A systematic review and research perspective on recommender systems. **Journal of Big Data**, v. 9, e59, 2022. DOI: <https://doi.org/10.1186/s40537-022-00592-5>.

TIWARI, S.; KAUSHIK, S.; TIWARI, S.; JAGWANI, P. Location based recommender systems: architecture, trends and research areas. *In*: IET INTERNATIONAL CONFERENCE ON WIRELESS COMMUNICATIONS AND APPLICATIONS (ICWCA 2012), 2012, Kuala Lumpur. **Proceedings [...]**. Kuala Lumpur, 2012. DOI: <https://doi.org/10.1049/cp.2012.2096>.

VAHIDNIA, M. H. Point-of-interest recommendation in location-based social networks based on collaborative filtering and spatial kernel weighting. **Geocarto International**, v. 37, n. 26, p. 13949-13972, 2022. DOI: <https://doi.org/10.1080/10106049.2022.2086626>.

WAGNER, C.; CAROLINA, A.; PAULA, A. **Pesquisa científica na computação**: uma abordagem com revisão sistemática de literatura. Maringá: Viseu, 2023.

WEYDEMANN, L.; SACHARIDIS, D.; WERTHNER, H. Defining and measuring fairness in location recommendations. *In*: ACM SIGSPATIAL INTERNATIONAL WORKSHOP ON LOCATION-BASED RECOMMENDATIONS, GEOSOCIAL NETWORKS AND GEOADVERTISING (LOCALREC'19), 3., 2019, Chicago. **Proceedings [...]**. New York: ACM, 2019. DOI: <https://doi.org/10.1145/3356994.3365497>.

ZANGERLE, E.; BAUER, C. Evaluating recommender systems: survey and framework. **ACM Computing Surveys**, v. 55, n. 8, e170, p. 1-38, 2022. DOI: <https://doi.org/10.1145/3556536>.