



Universidade Estadual de Feira de Santana
Programa de Pós-Graduação em Ciência da Computação

Sistemas de Recomendação que Utilizam Dados Espaciais: Um Mapeamento Sistemático

Aline Ferreira Pereira

Feira de Santana

2025



Universidade Estadual de Feira de Santana
Programa de Pós-Graduação em Ciência da Computação

Aline Ferreira Pereira

Sistemas de Recomendação que Utilizam Dados Espaciais: Um Mapeamento Sistemático

Dissertação apresentada à Universidade
Estadual de Feira de Santana como parte
dos requisitos para a obtenção do título de
Mestre em Ciência da Computação.

Orientador: João Batista da Rocha Junior

Feira de Santana

2025

Ficha Catalográfica - Biblioteca Central Julieta Carteadó - UEFS

P489s

Pereira, Aline Ferreira

Sistemas de recomendação que utilizam dados espaciais: um mapeamento sistemático / Aline Ferreira Pereira . – 2025.
99 f.: il.

Orientador: João Batista da Rocha Junior

Dissertação (mestrado) – Universidade Estadual de Feira de Santana, Programa de Pós-Graduação em Ciência da Computação, Feira de Santana, 2025.

1. Sistemas computacionais. 2.Algoritmos. 3. Sistema de recomendação.
4. Dimensões espaciais. I. Rocha Junior, João Batista da, orient.
II. Universidade Estadual de Feira de Santana. III. Título.

CDU 004.421



UNIVERSIDADE ESTADUAL DE FEIRA DE SANTANA

Autorizada pelo Decreto Federal nº 77.496 de 27/04/1976

Reconhecida pela Portaria Ministerial nº 874 de 19/12/1986

Recredenciada pelo Decreto nº 9.271 de 14/12/2004

Recredenciada pelo Decreto nº 17.228 de 25/11/2016

PROGRAMA DE PÓS-GRADUAÇÃO EM CIÊNCIA DA COMPUTAÇÃO

ATA DA SESSÃO PÚBLICA DE DEFESA DE DISSERTAÇÃO DE MESTRADO EM CIÊNCIA DA COMPUTAÇÃO Nº 39

No dia 28 de abril de 2025, às 9:00, na Sala online do Google Meet em <https://meet.google.com/cpn-kknr-pva>, realizou-se a Sessão Pública de Defesa de Dissertação de Mestrado em Ciência da Computação número 39, do(a) mestrando(a) **Aline Ferreira Pereira**, matrícula nº 23115013, intitulada *Sistemas de Recomendação que utilizam Dados Espaciais: um Mapeamento Sistemático* do Programa de Pós-Graduação em Ciência da Computação (PGCC). Inicialmente, a Banca Examinadora foi instalada, sendo composta pelos seguintes membros: o(a) Orientador(a) do(a) mestrando(a) e Presidente da Banca Examinadora, Dr(a). João Batista da Rocha Junior (UEFS), Dr(a). Frederico Araújo Durão (UFBA) e Dr(a). Larissa Rocha Soares Bastos (UNEB). Em seguida, foram esclarecidos os procedimentos e a palavra foi passada ao(à) mestrando(a), que apresentou o seu trabalho. Ao final da apresentação, a Banca Examinadora passou à arguição do(a) candidato(a). Ato contínuo, a Banca Examinadora reuniu-se para elaborar seu parecer final. Concluída a reunião, foi lido o parecer final sobre a dissertação apresentada, tendo a Banca Examinadora atribuído o conceito **APROVADO** à referida dissertação, sendo esta aprovação um requisito parcial para a obtenção do título de Mestre em Ciência da Computação. O(A) mestrando(a) terá 90 (noventa) dias para realizar modificações consideradas essenciais para a aprovação da dissertação, conforme o parecer exarado pela Banca Examinadora, anexo a este documento. Nada mais havendo a tratar, foi encerrada a sessão e lavrada a presente ata, abaixo assinada pelo Presidente e demais membros da Banca Examinadora.

Feira de Santana, 28 de abril de 2025.

Documento assinado digitalmente



JOAO BATISTA DA ROCHA JUNIOR

Data: 28/04/2025 19:33:46-0300

Verifique em <https://validar.iti.gov.br>

Dr(a). João Batista da Rocha Junior (Presidente)

Documento assinado digitalmente



FREDERICO ARAUJO DURAO

Data: 29/04/2025 11:45:43-0300

Verifique em <https://validar.iti.gov.br>

Dr(a). Frederico Araújo Durão

Documento assinado digitalmente



LARISSA ROCHA SOARES BASTOS

Data: 30/04/2025 14:31:47-0300

Verifique em <https://validar.iti.gov.br>

Dr(a). Larissa Rocha Soares Bastos

Prefácio

Esta dissertação de mestrado foi submetida à Universidade Estadual de Feira de Santana (UEFS) como requisito parcial para obtenção do grau de Mestre em Ciência da Computação.

A dissertação foi desenvolvida no Programa de Pós-Graduação em Ciência da Computação (PGCC), tendo como orientador o Prof. Dr. **João Batista da Rocha Junior**.

Esta pesquisa foi parcialmente financiada, durante um ano, pela CAPES.

Agradecimentos

A Deus, fonte de força, inspiração, serenidade e sabedoria concedidas ao longo desta jornada. Sem Sua presença constante, este trabalho não seria possível.

Ao Programa de Pós-Graduação em Ciência da Computação (PGCC) e à Universidade Estadual de Feira de Santana (UEFS), pela oportunidade de crescimento acadêmico e científico.

Ao meu orientador, Prof. Dr. João Batista da Rocha Junior, cuja orientação precisa, paciência e vasto conhecimento foram determinantes para cada etapa desta pesquisa. Sou profundamente grata por seu comprometimento e disponibilidade ao longo de todo o processo.

À banca examinadora, composta pelas Prof^{as} Larissa Rocha e Claudia Pinto Pereira, pela leitura cuidadosa, valiosas sugestões e contribuições que enriqueceram este trabalho.

À minha família, que esteve sempre presente, oferecendo amor, paciência e apoio incondicional. A vocês, minha gratidão eterna por compreenderem os desafios dessa caminhada e por nunca medirem esforços para me incentivar a seguir em frente.

Ao meu esposo, Márcio Sena de Oliveira, pela parceria constante, pelo carinho e pela compreensão diante de cada momento dessa trajetória. A você, meu mais sincero agradecimento por estar ao meu lado em todos os desafios e conquistas.

E ao meu filho Hugo Gabriel Pereira da Silva, pela presença iluminada e motivadora, que trouxe leveza e alegria mesmo nos períodos mais intensos desta jornada.

A todos que, direta ou indiretamente, contribuíram para a realização deste trabalho, meu mais sincero agradecimento.

“Até aqui nos ajudou o Senhor.”

– 1 Samuel 7:12

Alinhamento com a Linha de Pesquisa

Linha de Pesquisa: Software e Sistemas Computacionais

A dissertação está alinhada com a linha de pesquisa “Software e Sistemas Computacionais” ao investigar Sistemas de Recomendação que utilizam Dados Espaciais, uma área relevante no campo da ciência da computação. O estudo se concentra em analisar técnicas e algoritmos empregados nesses sistemas, com ênfase em como os dados espaciais são integrados para aprimorar a personalização das recomendações. A pesquisa busca mapear as abordagens existentes e identificar tendências na área.

Resumo

A crescente disponibilidade de dados espaciais, impulsionada pelo aumento da conectividade e pelo uso massivo de dispositivos móveis, tem transformado diversas áreas da tecnologia, especialmente os Sistemas de Recomendação. Esses sistemas, que já desempenham um papel crucial na personalização de experiências de usuários em plataformas digitais, beneficiam-se significativamente da integração com dados espaciais, proporcionando recomendações mais precisas. No entanto, não existe um mapeamento abrangente sobre a utilização desses dados nestes sistemas. Esta dissertação preenche esta lacuna, realizando um mapeamento sistemático atual da incorporação de dados espaciais em Sistemas de Recomendação. A abordagem metodológica adotada é de natureza teórica e exploratória, fundamentada em uma investigação bibliográfica documental. O processo compreende etapas definidas de planejamento, execução e apresentação dos resultados. A organização e sistematização dos dados são conduzidas através de uma tabulação estruturada. O objetivo geral é mapear como os dados espaciais estão sendo utilizados no contexto dos Sistemas de Recomendação. Entre os resultados obtidos estão: 1) os Sistemas de Recomendação que utilizam dados espaciais utilizam as técnicas de Aprendizado de Máquina e Filtragem Colaborativa para melhorar a precisão e relevância das recomendações, 2) a integração de dados espaciais envolve um processo complexo de coleta, extração e mapeamento, que geralmente inicia com a obtenção de informações geoespaciais, como coordenadas de latitude e longitude, frequentemente derivadas de Redes Sociais e 3) o *Baseline* é frequentemente utilizado na avaliação dos Sistemas de Recomendação de utilizam dados espaciais.

Palavras-chave: mapeamento sistemático; Sistemas de Recomendação; dados espaciais.

Abstract

The increasing availability of spatial data, driven by greater connectivity and the massive use of mobile devices, has transformed several areas of technology, especially Recommender Systems. These systems, which already play a crucial role in personalizing user experiences on digital platforms, benefit significantly from the integration of spatial data, leading to more accurate recommendations. However, there is no comprehensive mapping of how this data is utilized in these systems. This dissertation addresses this gap by conducting a systematic review of the incorporation of spatial data in Recommender Systems. The adopted methodological approach is theoretical and exploratory, based on bibliographic and documentary research. The process consists of well-defined stages: planning, execution, and presentation of results. data organization and systematization are performed through systematic tabulation. The main objective is to map how spatial data is being utilized in Recommender Systems. The key findings include: (1) Recommender Systems leveraging spatial data apply Machine Learning and Collaborative Filtering techniques to enhance recommendation accuracy and relevance; (2) the integration of spatial data involves a complex process of collection, extraction, and mapping, typically beginning with the acquisition of geospatial information, such as latitude and longitude coordinates, often derived from Social Media; and (3) baseline models are frequently used to evaluate Recommender Systems that incorporate spatial data.

Keywords: systematic mapping, Recommender Systems, spatial data.

Lista de Figuras

2.1	Representação abstrata dos tipos de dados espaciais.	7
2.2	Arquitetura genérica de um sistema de recomendação.	13
2.3	Relação entre usuário e item.	14
3.1	Etapas do processo metodológico.	22
4.1	Processo de execução.	27
4.2	<i>String</i> de busca usada na base ACM Digital Library.	28
4.3	<i>String</i> de busca usada na base IEEE Xplore.	29
4.4	<i>String</i> de busca usada na base ScienceDirect.	29
4.5	<i>String</i> de busca usada na base Scopus.	30
4.6	Quantitativo de artigos por bases.	33
4.7	Quantitativo de artigos.	34
5.1	Comparação entre número de ocorrências e percentual das técnicas identificadas.	38
5.2	Distribuição das técnicas ao longo dos anos.	39
5.3	Fonte dos dados.	41
5.4	Percentual dos dados espaciais extraídos.	43
5.5	Característica espacial dos dados extraídos.	44
5.6	Dados recomendados.	45
5.7	Dados recomendados.	45
5.8	Abordagens de cálculo de distância por métricas espaciais.	47
5.9	Abordagens de cálculo de distância por métricas não espaciais.	47
5.10	Abordagens baseadas na interpretação de dados.	49
5.11	Abordagens baseadas em aprendizado de máquina e modelagem avan- çada.	49
5.12	Avaliação dos experimentos.	51

Lista de Tabelas

1.1	Questão de pesquisa versus objetivo	4
2.1	Comparação entre Revisão Sistemática de Literatura e Mapeamento Sistemático de Literatura, adaptada de Kitchenham et al. (2007). . .	18
5.1	Técnicas identificadas e suas abreviações.	38
B.1	Técnicas identificadas.	79
B.2	Agrupamento das técnicas identificadas.	80
B.3	Fonte de origem dos dados.	81
B.4	Dados espaciais extraídos.	81
B.5	Dados recomendados.	82
B.6	Abordagens de cálculo de distância por métricas espaciais.	83
B.7	Abordagem de cálculo de distância por métricas não espaciais.	83
B.8	Abordagens baseadas na interpretação de dados.	84
B.9	Abordagens baseadas em aprendizado e modelos avançados.	85
B.10	Abordagens de avaliação utilizadas nos experimento	86

Sumário

1	Introdução	1
1.1	Objetivo	3
1.2	Questões de Pesquisa	4
1.3	Questão de Pesquisa versus Objetivo	5
1.4	Organização do Trabalho	5
2	Fundamentação Teórica	6
2.1	Dados Espaciais	6
2.2	Sistemas de Recomendação	8
2.2.1	Principais técnicas utilizadas em Sistemas de Recomendação	8
2.2.2	Avaliação nos Sistemas de Recomendação	11
2.2.3	Arquitetura dos Sistemas de Recomendação	12
2.3	Sistemas de Recomendação que Utilizam Dados Espaciais	15
2.4	Revisões Sistemáticas Relacionadas	16
2.5	Revisão Sistemática versus Mapeamento Sistemático	17
2.6	Ferramentas de Suporte ao Mapeamento Sistemático	19
3	Metodologia	21
3.1	Planejamento	22
3.2	Realização	23
3.3	Reporte	24
3.4	Avaliação do Mapeamento Sistemático	24
4	Execução	26
4.1	Estratégia de Busca	27
4.2	Seleção dos Estudos	30
4.2.1	Critérios de Inclusão da Primeira Etapa	30
4.2.2	Critérios de Exclusão da Primeira Etapa	31
4.2.3	Questões de qualidade - Segunda Etapa	32
4.3	Execução da Seleção dos Estudos	33
4.4	Extração de Dados	35
4.5	Avaliação do Mapeamento Sistemático de Literatura	35
5	Resultados e Discussões	37

5.1	Questão de Pesquisa Primária 1	37
5.2	Questão de Pesquisa Primária 2	41
5.3	Questão de Pesquisa Primária 3	50
6	Considerações Finais	53
6.1	Principais Contribuições	54
6.2	Limitações	56
6.3	Ameaças à Validade	56
6.4	Lições Aprendidas	57
6.5	Trabalhos Futuros	57
	Referências	58
A	Artigos selecionados	61
B	Tabelas da análise dos dados	78

Capítulo 1

Introdução

“O coração do homem traça o seu caminho, mas o Senhor lhe dirige os passos.”

– Provérbios 16:9

A crescente demanda por otimização de tempo e por respostas rápidas durante a tomada de decisão em diversas áreas tem se tornado cada vez mais relevante no contexto atual (Weydemann et al., 2019; Acharya et al., 2023). Nesse cenário, os Sistemas de Recomendação emergem como ferramentas cruciais. Segundo Angelis et al. (2021), esses sistemas são conceituados como plataformas voltadas para aprimorar a experiência do usuário e fornecer sugestões personalizadas e relevantes que se adaptem às suas preferências individuais.

Os dados espaciais são uma categoria especial de dados que descrevem fenômenos relacionados a dimensões espaciais e representam a localização geográfica de objetos, tanto estáticos quanto em movimento. Podem ser classificados em três principais tipos: pontos, que fornecem coordenadas de latitude e longitude para identificar posições específicas, como uma cidade; linhas, que traçam trajetórias conectando pelo menos dois pontos, podendo representar cursos d’água, estradas ou trilhas; e regiões, que definem áreas delimitadas por pontos e linhas, como regiões geográficas ou limites territoriais (Güting, 1994).

A integração desses dados espaciais com Sistemas de Recomendação permite aprimorar os serviços de recomendação oferecidos. Esses sistemas têm o papel crucial de ampliar o engajamento e a satisfação dos usuários, facilitando a descoberta de novos itens, filtrando informações em ambientes com grande volume de dados e melhorando a qualidade da interação do usuário com o serviço usado. Por exemplo, um e-commerce pode sugerir produtos relacionados com base nas compras anteriores do usuário, tornando a experiência de compra mais personalizada e eficiente.

Alguns Sistemas de Recomendação incorporam dados espaciais para aprimorar a qualidade das recomendações. Um exemplo significativo disso é o estudo de Vahidnia (2022), que enfatiza a importância da inclusão de informações de localização geográfica. Ele destaca que considerar a geolocalização pode ser particularmente valioso, uma vez que os padrões de localização do usuário influenciam diretamente nas sugestões recomendadas.

Além de aprimorar as recomendações, os Sistemas de Recomendação estão expandindo suas funcionalidades para incluir a recomendação de dados espaciais, como pontos, rotas e áreas de interesse. A exemplo, Ivanova et al. (2022) propuseram um Sistema de Recomendação de Rotas de Escalada. Outro exemplo é a recomendação de pontos, rotas e áreas, (Artemenko et al., 2020), que aborda a recomendação de pontos, rotas e áreas durante deslocamentos para minimizar engarrafamentos e aglomerações.

Tendo em vista essa expansão das aplicações e o crescente uso de dispositivos móveis que capturam automaticamente dados de localização, torna-se cada vez mais pertinente estudar os Sistemas de Recomendação que integram informações espaciais. Esses dados, disponíveis de forma abundante e contínua, permitem que esses sistemas ofereçam sugestões mais contextualizadas, considerando não apenas as preferências explícitas dos usuários, mas também seu posicionamento geográfico.

Essa necessidade de considerar o fator geográfico nas recomendações tornou-se ainda mais evidente em uma experiência pessoal durante a busca por um veículo em plataformas de e-commerce. Após inserir filtros como modelo, ano e faixa de preço, as sugestões retornadas eram tecnicamente adequadas, porém localizadas em cidades muito distantes. Considerando que a compra de um carro exige uma análise presencial, essas recomendações não foram úteis. Essa experiência reforça a motivação desta pesquisa, que busca compreender como a integração dos dados espaciais pode ser aprimorada nos modelos atuais.

Sendo assim, mapear essa área de pesquisa pode contribuir na identificação de quais abordagens e técnicas têm sido utilizadas, como os dados espaciais são incorporados nas recomendações e quais tipos de itens ou serviços estão sendo sugeridos. Além disso, tal mapeamento pode orientar novos esforços de pesquisa e desenvolvimento, visando atender às necessidades contextualizadas de usuários cada vez mais exigentes e conectados.

A expansão dos Sistemas de Recomendação que empregam dados espaciais apresenta um outro desafio significativo devido à dispersão das informações relevantes na literatura (Roy e Dutta, 2022). Essa dispersão cria uma lacuna na pesquisa, dificultando a síntese e compreensão abrangente das práticas, métodos e tendências relacionadas a esses sistemas (Roy e Dutta, 2022). Um exemplo concreto dessa dispersão é observado na diversidade de formas em que esses dados são utilizados nos Sistemas de Recomendação, abrangendo desde sua utilização como entrada de dados para aprimorar os próprios Sistemas de Recomendação, até sua utilização como saída de dados, gerando recomendações de objetos espaciais em si. Além disso, observa-se

uma combinação híbrida desses usos, evidenciando a complexidade e a versatilidade dessa área.

Portanto, existe a necessidade de mapear esses conhecimentos dispersos para fornecer um panorama abrangente, identificar *gaps*, técnicas emergentes, áreas mais e menos exploradas na incorporação de dados espaciais em Sistemas de Recomendação, além de descrever as técnicas padrão utilizadas, seja para aprimorar os Sistemas de Recomendação tradicionais, seja para realizar recomendações de dados espaciais estáticos ou em movimento.

Ademais, a importância de entender e mapear a incorporação de dados espaciais torna-se ainda mais evidente à medida que a variedade de aplicações que dependem dessas informações, como o *app* de entrega de comida *i-Food*, continuam a expandir-se. Isso ressalta não apenas a relevância, mas também a amplitude do impacto potencial desta pesquisa. Por exemplo, no caso de pedidos do *i-Food*, ao usar dados de localização, é possível identificar padrões de consumo e preferências similares entre pessoas que moram próximas umas das outras. Essa análise pode otimizar recomendações personalizadas de restaurantes e pratos, aumentando a satisfação do cliente e a eficiência do serviço de entrega.

Além disso, essa falta de estruturação na disseminação do conhecimento também impacta a pesquisa acadêmica, uma vez que dificulta a identificação de tendências e lacunas no campo. Um mapeamento devidamente estruturado permite uma compreensão panorâmica das várias maneiras pelas quais os dados espaciais estão sendo utilizados nos Sistemas de Recomendação, o que facilita futuras pesquisas nesse campo, além de contribuir para a construção de Sistemas de Recomendação mais eficazes e adaptados à dimensão espacial.

1.1 Objetivo

1. Mapear de forma abrangente e sistemática como os dados espaciais estão sendo utilizados no contexto dos Sistemas de Recomendação. Isso implica na identificação das técnicas e ferramentas relacionadas à incorporação desses dados espaciais em Sistemas de Recomendação.
 - (a) Investigar as técnicas utilizadas em Sistemas de Recomendação que são empregadas nesses sistemas que utilizam dados espaciais.
 - (b) Investigar os métodos e técnicas utilizados na extração e no mapeamento de dados espaciais, analisando como essas informações são processadas e integradas para alimentar os Sistemas de Recomendação no processo de recomendação.
 - (c) Investigar como as técnicas identificadas são avaliadas, a exemplo: qualitativa, quantitativa ou estudo controlado.

Tabela 1.1: Questão de pesquisa versus objetivo

Questões	Objetivos
QP1: Quais técnicas são utilizadas em Sistemas de Recomendação que utilizam dados espaciais?	Listar as técnicas utilizadas em Sistemas de Recomendação que utilizam dados espaciais.
QP2: Como são extraídos e mapeados os dados espaciais para alimentar os Sistemas de Recomendação?	Identificar a estratégia de extração e mapeamento de dados espaciais mais usado em Sistemas de Recomendação que utilizam dados espaciais. Exemplo: a fonte de origem dos dados.
QS2.1 Qual a origem desses dados?	Identificar as plataformas digitais de onde os dados são extraídos ex: redes sociais, serviços de transportes, etc.
QS2.2 Quais dados espaciais são extraídos?	Identificar qual tipo de dado espacial é extraído. Exemplo: localização ou trajeto (rota).
QS2.3 O que é recomendado?	Identificar o que é recomendado. Exemplo: Amigo, ponto de interesse ou filme.
QS2.4 Qual tipo de dado espacial é recomendado?	Identificar qual tipo de dado espacial é recomendado. Exemplo: ponto, rota ou área.
QS2.5 Dados espaciais são recomendados?	Saber se se um item recomendado é um objeto espacial.
QS2.6 Como é calculada a distância no experimento?	Identificar a abordagem de distância que é utilizada nos experimentos. Exemplo: distância Euclidiana, caminho mais curto ou outro.
QS2.7 Qual técnica é utilizada para melhorar o desempenho dos Sistemas de Recomendação?	Identificar a técnica utilizada para melhorar os Sistemas de Recomendação. Exemplo, utilização do contexto do usuário, técnica de Aprendizado de Máquina, etc.
QP3: Como as técnicas identificadas são avaliadas?	Identificar a técnica utilizada para avaliar o modelo. Exemplo, <i>Baselines</i> e teste A/B.

1.2 Questões de Pesquisa

Diante do vasto potencial e dos desafios inerentes à integração de dados espaciais em Sistemas de Recomendação, emergem as seguintes Questões de Pesquisa:

1. Quais técnicas são utilizadas em Sistemas de Recomendação que utilizam dados espaciais?
2. Como são extraídos e mapeados os dados espaciais para alimentar os Sistemas de Recomendação?
 - (a) Qual a origem desses dados?
 - (b) Quais dados espaciais são extraídos?
 - (c) O que é recomendado?
 - (d) Qual tipo de dado espacial é recomendado?
 - (e) Dados espaciais são recomendados?
 - (f) Como é calculada a distância no experimento?
 - (g) Qual técnica é utilizada para melhorar o desempenho dos Sistemas de Recomendação?
3. Como as técnicas identificadas são avaliadas?

1.3 Questão de Pesquisa versus Objetivo

A Tabela 1.1 contém as questões de pesquisa e os objetivos a serem alcançados para cada uma dessas questões. A primeira coluna é composta pelas Questões Primárias (QP) e Secundárias (QS). A segunda coluna é composta pelos objetivos associados a cada questão. Nem todas as questões primárias possuem questões secundárias. Por exemplo, a QP1 não possui questões secundárias (QS). Os objetivos associados às questões de pesquisa permitem delinear os dados a serem extraídos. Por exemplo, para a questão secundária QS2.2, o objetivo é “identificar os dados espaciais que estão sendo extraídos: ponto, rota ou área”.

1.4 Organização do Trabalho

O Capítulo 2 contempla o referencial teórico, seguido pelo Capítulo 3 que detalha a metodologia adotada. Posteriormente, no Capítulo 4, é apresentado o processo de execução da pesquisa, o Capítulo 5 contém a apresentação dos resultados e as discussões, concluindo com o Capítulo 6, que apresenta as considerações finais e trabalhos futuros. A relação dos artigos analisados estão disponíveis no Apêndice A. As tabelas referentes a análise dos dados estão disponíveis no Apêndice B.

Capítulo 2

Fundamentação Teórica

“Com sabedoria edifica-se a casa, e com a inteligência ela se firma; pelo conhecimento os seus cômodos se enchem de toda espécie de bens preciosos e desejáveis.”

– Provérbios 24:3-4

Neste capítulo são abordados de forma sintetizada os conceitos fundamentais para o delineamento desta pesquisa. A Seção 2.1 explora a definição e importância dos dados espaciais, a Seção 2.2 apresenta as principais técnicas e características dos Sistemas de Recomendação. Além disso, na Seção 2.3, são apresentados os Sistemas de Recomendação que utilizam dados espaciais, os quais exploram estudos sobre a interseção entre dados espaciais e Sistemas de Recomendação, na Seção 2.4 são apresentadas revisões sistemáticas relacionadas, a Seção 2.5 destaca a diferença entre Revisão Sistemática de Literatura e Mapeamento Sistemático de Literatura, ressaltando as contribuições específicas de cada abordagem metodológica e, por fim, na Seção 2.6 são apresentadas ferramentas de suporte a realização de mapeamentos sistemáticos.

2.1 Dados Espaciais

Os dados espaciais estão diretamente ligados a dimensões espaciais, representando objetos no espaço que possuem identidade, extensões físicas e localizações geográficas com relações bem definidas, conforme ressaltado por Güting (1994). Esses dados são comumente expressos por meio de coordenadas geográficas, como apontado por Pebesma e Bivand (2023), com o propósito de identificar a posição de objetos.

Esses dados espaciais podem ser representados de maneira abstrata como sendo de três tipos, incluindo:

- *Pontos* específicos, como cidades ou marcos geográficos;
- *Linhas* que retratam características lineares, como rios ou estradas;
- *Regiões* que definem áreas delimitadas, como países ou cidades.

Conforme destacado por Pebesma e Bivand (2023); Güting (1994), cada uma dessas abstrações desempenha um papel crucial na representação de informações geográficas complexas e na compreensão do ambiente espacial.




Figura 2.1: Representação abstrata dos tipos de dados espaciais.

Na Figura 1 (a), o ponto representa o aspecto geométrico de um objeto com foco exclusivo em sua localização, conforme Güting (1994), e permitem a identificação precisa de entidades específicas no espaço, apontado por Rocha-Junior (2013), como cidades ou pontos de interesse. Por exemplo, ao representar uma cidade em um mapa de grande escala, um ponto pode representar sua localização.

A linha, na Figura 1 (b) é uma abstração essencial para representar trajetos e conexões no espaço, como estradas, rios e redes de comunicação, desempenhando um papel vital na compreensão da infraestrutura física e na conectividade espacial (Güting, 1994). Por serem frequentemente representadas por polilinhas ou sequências de segmentos de linha, elas fornecem uma representação eficaz de elementos lineares complexos, como redes de transporte e cursos d'água (Rocha-Junior, 2013).

A abstração de região, Figura 1 (c), no espaço 2D permite a representação de áreas extensas, como países e reservas ambientais, incluindo complexidades como buracos e divisões disjuntas (Güting, 1994) além de áreas menores como lagos e condomínios.

As regiões proporcionam uma compreensão mais abrangente da geografia de uma região específica, permitindo uma análise mais detalhada e precisa das características das áreas observadas (Rocha-Junior, 2013).

Por meio da utilização dessas abstrações, é possível desenvolver representações precisas e completas de objetos, facilitando uma compreensão mais profunda da distribuição e das características do espaço.

Os bancos de dados espaciais compreendem um conjunto de dados inter-relacionados, especialmente projetado para suportar a gerência de informações espaciais. De acordo com Güting (1994), essa terminologia está intrinsecamente ligada à ideia de que bancos de dados espaciais abrigam conjuntos de objetos espaciais, diferenciando-se de simples imagens ou representações abstratas de um ambiente. Sua distinção fundamental reside na capacidade de lidar com tipos de dados espaciais de maneira eficiente, levando em consideração suas dimensões, modelagens e relações específicas no espaço.

2.2 Sistemas de Recomendação

Os Sistemas de Recomendação, conforme apontado por Zangerle e Bauer (2022), são tipos de sistemas de filtragem de informações que têm a finalidade de auxiliar os usuários a lidar com a sobrecarga de informações e opções, fornecendo previsões e sugestões de itens relevantes. Tais sistemas desempenham um papel crucial em várias plataformas online, como em serviços de streaming de filmes como Netflix, que recomendam filmes ou séries com base no histórico de visualização e avaliações anteriores.

Os Sistemas de Recomendação são ferramentas complexas que empregam uma variedade de técnicas para analisar os padrões de comportamento e preferências do usuário (Aggarwal et al., 2016), com o objetivo de oferecer sugestões personalizadas de produtos, serviços e conteúdos relevantes. De acordo com Roy e Dutta (2022), eles utilizam três técnicas principais: Baseada em Conteúdo, Filtragem Colaborativa e Híbrida. Esses sistemas normalmente utilizam métricas diversas para coletar e avaliar os dados provenientes das interações do usuário com itens específicos. Além disso, a arquitetura dos Sistemas de Recomendação pode variar consideravelmente, abrangendo desde modelos simples Baseados em Conteúdo até técnicas mais avançadas, como Filtragem Colaborativa e Híbrida.

2.2.1 Principais técnicas utilizadas em Sistemas de Recomendação

Dentre as diversas técnicas utilizadas em Sistemas de Recomendação, destacam-se algumas que têm sido abordadas tanto na literatura quanto em aplicações práticas e representam um panorama da área em termos de técnicas utilizadas para personalizar sugestões e otimizar a experiência do usuário. A seguir, apresentam-se as principais técnicas, com uma breve descrição de suas características.

- A **Filtragem Colaborativa** é uma técnica que se baseia nas opiniões e preferências de um grupo de usuários, identificando padrões e informações relevantes. Essa abordagem se baseia no histórico de visualização e avaliações de usuários com gostos semelhantes (Aggarwal et al., 2016). Por exemplo, se um usuário A , assistiu aos filmes F_1 , F_2 e F_3 e um usuário B assistiu os filmes F_1 , F_2 , F_3 e F_4 , percebe-se que A e B possuem gostos similares, pois ambos assistiram aos filmes F_1 , F_2 , F_3 . Portanto, neste caso, o filme F_4 que o usuário B assistiu, mas o usuário A ainda não assistiu, é recomendado para o usuário A , baseando-se na ideia de que usuários com históricos similares provavelmente terão gostos e preferências semelhantes.
- A abordagem **Baseada em Conteúdo** se concentra na análise de itens previamente avaliados por um usuário, criando um perfil de interesses com base nessas avaliações. Nesse processo, o sistema compara o perfil desse usuário com os atributos dos itens da aplicação, recomendando itens similares de acordo com as suas preferências (Aggarwal et al., 2016). Por exemplo, em um aplicativo de *streaming* de música, o sistema usa as preferências musicais do usuário para recomendar faixas com características semelhantes, como gênero, ritmo e tom, fornecendo uma recomendação compatível com o perfil deste usuário.
- A abordagem **Baseada em Contexto** considera informações adicionais sobre a situação do usuário no momento da recomendação, como localização, horário e dispositivo utilizado, para fornecer sugestões mais relevantes. Diferentemente de técnicas que analisam apenas preferências passadas, esse método adapta as recomendações conforme as condições específicas em que o usuário se encontra, preferências estáticas (Xia et al., 2017). Por exemplo, em um aplicativo de entrega de comida, o sistema pode recomendar restaurantes diferentes dependendo da hora do dia, da previsão do tempo ou da localização do usuário. Assim, um usuário que procura por refeições ao meio-dia pode receber sugestões de restaurantes próximos com opções de almoço, enquanto à noite, as recomendações podem priorizar estabelecimentos que oferecem jantar ou *delivery* rápido.
- A abordagem **Baseada em Casos** é uma técnica utilizada em sistemas de recomendação que se apoia em um banco de dados de problemas previamente resolvidos e suas respectivas soluções para sugerir itens relevantes aos usuários. Nesse processo, o sistema compara a consulta do usuário, composta por atributos específicos de interesse, com casos armazenados na base, utilizando uma função de similaridade para identificar aqueles mais compatíveis. Dessa forma, a recomendação é feita com base na adaptação de soluções passadas para contextos atuais, permitindo que o sistema aprenda com experiências anteriores e refine suas sugestões (Panteli e Boutsinas, 2023). Por exemplo, em plataformas de suporte técnico, um sistema baseado em casos pode recomendar soluções para problemas reportados por usuários, associando a consulta atual a incidentes semelhantes resolvidos anteriormente.

- O **Aprendizado de Máquina** permite a análise automatizada de grandes volumes de dados para a identificação de padrões e preferências dos usuários. Nesse contexto, algoritmos como o de aprendizado supervisionado e não supervisionado são empregados para modelar o comportamento dos usuários e prever itens de interesse com base em interações passadas (Han et al., 2024). Por exemplo, em aplicações como a recomendação de locais para negócios, a utilização de Aprendizado de Máquina possibilita a identificação de padrões geográficos e demográficos relevantes para a escolha de um ponto comercial estratégico.
- Além do Aprendizado de Máquina, outras técnicas da área da Inteligência Artificial, como **Clusters e algoritmos baseados em Lógica Fuzzy**, também são utilizadas em Sistemas de Recomendação. Por exemplo, a Lógica Fuzzy possibilita lidar com a incerteza e a subjetividade nas preferências dos usuários, refinando as sugestões com base em múltiplos critérios (Álvarez et al., 2020).
- A **Fatoração de Matriz** é uma técnica baseada em modelo matemático que explora conceitos da Álgebra Linear para decompor grandes matrizes de interações entre usuários e itens. Dessa maneira, mesmo que um usuário não tenha interagido diretamente com um item específico, o sistema pode prever seu interesse com base em padrões similares observados em outros usuários (Sohrabort e Taleai, 2021). Por exemplo, em plataformas de *streaming* de filmes, a Fatoração de Matriz permite recomendar títulos a um espectador analisando as avaliações de usuários com gostos semelhantes, mesmo que ele nunca tenha assistido ou avaliado esses filmes.
- O **Grafo** é uma estrutura gráfica matemática que consiste em um conjunto de vértices (ou nós) e arestas (ou conexões) que os ligam, representando relações entre os elementos do Sistemas de Recomendação. Os vértices podem representar usuários, itens ou conteúdos, enquanto as arestas indicam interações ou relações entre eles, como avaliações, compras ou visualizações. Essa estrutura permite modelar de maneira eficiente conexões complexas, identificando padrões que podem ser explorados para fazer recomendações mais precisas (Canturk et al., 2023). Por exemplo, em plataformas de *streaming* de música, um Grafo pode conectar usuários com gostos musicais semelhantes, artistas, álbuns ou faixas, permitindo ao sistema sugerir novos conteúdos com base nas interações e proximidade entre os elementos na rede.
- A abordagem **Híbrida**, por exemplo, combina de forma sinérgica técnicas como a Filtragem Colaborativa e Baseada em Conteúdo, somando os benefícios de ambas para aprimorar a qualidade das recomendações. Essa abordagem é empregada com o objetivo de não considerar apenas as preferências de usuários semelhantes e as características intrínsecas dos itens recomendados, mas também aplicar técnicas de análise de grandes volumes de dados (Roy e Dutta, 2022). Isso resulta em recomendações mais refinadas e adaptadas.

2.2.2 Avaliação nos Sistemas de Recomendação

A avaliação no contexto dos Sistemas de Recomendação é fundamental para compreender a experiência do usuário durante a interação com o sistema, podendo ser representada por um *feedback* dado por esse usuário, conforme discutido por Zangerle e Bauer (2022). Ela abrange todo o ambiente de uso dos Sistemas de Recomendação, desde aspectos como configuração, coleta de informações, métricas empregadas até uma definição clara do perfil do usuário.

As avaliações podem ser expressas de diversas formas, variando de acordo com as diferentes plataformas e contextos (Zangerle e Bauer, 2022). Isso pode incluir uma classificação numérica gerada manualmente, como uma escala de 1 a 5 estrelas (Qian et al., 2022). Em outros casos, a avaliação pode ser mais simples, envolvendo uma avaliação que indica se o usuário gostou ou não do item (Liu et al., 2023), e ainda se o usuário o adquiriu. Tais avaliações são cruciais para os Sistemas de Recomendação, uma vez que ajudam a compreender as preferências e interesses dos usuários, otimizando o processo de recomendação de itens ou produtos relevantes para usuários individuais (Qian et al., 2022). Esses tipos de *feedback* podem ser classificados como Explícitos ou Implícitos.

O *Feedback* Explícito é fornecido diretamente pelo usuário, capturando de maneira direta a percepção deste usuário sobre um item específico. Os Sistemas de Recomendação incorporam métodos que permitem aos usuários expressar suas preferências por um determinado item, seja por meio de escalas de avaliação, como a popular escala de cinco estrelas, ou através de recursos como curtidas, polegares para cima ou para baixo, avaliações positivas e negativas distintas, como *Gosto* ou *Não Gosto*, ou também adicionar um item ao carrinho (Zangerle e Bauer, 2022; Qian et al., 2022).

O *Feedback* Implícito, por outro lado, é derivado do comportamento observável e mensurável do usuário durante a interação com um Sistema de Recomendação. Isso pode incluir a finalização de compras, cliques para visualizar detalhes do item ou o tempo de permanência em determinada página. Ao depender do *feedback* implícito, as avaliações presumem que um item consumido representa uma escolha de qualidade, enquanto todos os outros itens são considerados irrelevantes. Isso caracteriza um *feedback* positivo em relação ao item, sem necessariamente haver uma expressão explícita de preferência pelo usuário (Zangerle e Bauer, 2022; Qian et al., 2022).

Zangerle e Bauer (2022) relatam que no *feedback* implícito, embora predominantemente positivo, a ausência de informações não implica necessariamente que o usuário não tenha interesse em um item. Por exemplo, a falta de interação com uma faixa de música não significa necessariamente que o usuário não gosta dela. Alguns casos permitem oportunidades para *feedback* implícito negativo, como pular faixas ou ouvir parcialmente. Além disso, o *feedback* implícito pode ser usado para inferir preferências relativas, como quando um usuário assiste a um filme várias vezes em comparação com outros filmes. É importante interpretar o *feedback* implícito com

cuidado, pois certos comportamentos podem ter outras causas, como interrupções ou distrações. Desse modo, o *feedback* implícito pode ser mapeado em uma escala contínua, indicando vários graus de preferência do usuário (Zangerle e Bauer, 2022).

Os Sistemas de Recomendação dependem fortemente de dados de avaliação para gerar recomendações. No entanto, ao lidar com a ausência dessas informações, surge o desafio da *partida a frio*, que consiste em gerar recomendações eficazes quando há pouca ou nenhuma informação prévia sobre novos usuários ou itens, o que impossibilita a precisão na recomendação devido à falta de dados suficientes sobre o usuário ou o item em questão (Zangerle e Bauer, 2022). Para tanto, para aprimorar ainda mais as recomendações, é possível incorporar a construção de um perfil de usuário por meio de seus metadados, itens ou contexto.

O perfil de um usuário é construído com base em suas interações diretas com o sistema, que são capturadas por meio de pesquisas padronizadas, proporcionando uma visão quantitativa que busca a generalização e padronização. Por outro lado, uma abordagem mais qualitativa para a obtenção desses dados inclui por exemplo entrevistas, as quais são registradas na forma de notas ou vídeos (Zangerle e Bauer, 2022). Esses métodos de coleta de dados de usuários, combinados com os *feedbacks* explícitos e implícitos, proporcionam uma compreensão do comportamento e das preferências dos usuários, e contribui para a construção de recomendações mais precisas.

2.2.3 Arquitetura dos Sistemas de Recomendação

A arquitetura de um Sistema de Recomendação refere-se à estrutura fundamental que define os componentes e o funcionamento do sistema. De acordo com Tiwari et al. (2012), um Sistema de Recomendação é formalmente composto por um conjunto de usuários (U) e um conjunto de itens disponíveis para recomendações (I), onde uma função operacional ($f: U \times I \rightarrow R$), é responsável por mapear as interações dos usuários com os itens, sendo R um conjunto ordenado de um ou mais números positivos em um determinado intervalo, o qual dar-se por exemplo por meio de uma classificação em escala cinco estrelas, ou binária, de *Gostei* (1) ou *Não Gostei* (0), conforme descrito por Khusro et al. (2016) em seu trabalho. Esta arquitetura serve como base para compreender a complexidade e o funcionamento dos Sistemas de Recomendação em relação a seus usuários.

As interações entre usuários e itens são classificadas em relações fundamentais que desempenham papéis cruciais na construção desses sistemas (Lü et al., 2012). Por exemplo, nas plataformas de *stream*, três tipos principais de interação podem ser identificados. Primeiramente, a relação de visualização de um item $VER(u_i, i_j)$ reflete a ação do usuário u_i ao assistir um item i_j . Em segundo lugar, a marcação de preferência $GOSTAR(u_i, i_j)$ revela a opinião do usuário u_i sobre o item i_j , indicando se ele gostou ou não do item. A terceira relação envolve a adição de um item à lista de favoritos, expressa como $ADD(u_i, i_j)$, representando a ação do usuário u_i ao adicionar o item i_j a uma lista pessoal de preferências. Além disso, o Sistema de




Figura 2.2: Arquitetura genérica de um sistema de recomendação.

Recomendação considera informações detalhadas sobre os itens, levando em conta características específicas do item i_j que atraem o usuário u_i , contribuindo para recomendações mais personalizadas e relevantes (Khusro et al., 2016).

A Figura 2.2 representa um Sistema de Recomendação genérico, ilustrando as interações entre usuários individuais ou grupos de usuários com perfis semelhantes e o Sistema de Recomendação de Filmes. Considerando que todos os filmes possuem características como gênero e ano, na primeira interação, o usuário *João* visualizou o Filme *A*, o adicionou à lista de favoritos e expressou sua preferência positiva pelo Filme *B*. Na sequência, usuários com perfis semelhantes ao usuário *João* visualizaram o Filme *B*, adicionaram o Filme *C* em suas listas de favoritos e expressaram sua preferência positiva por ele. Por fim, o usuário *João* interage com o sistema e recebe recomendações, o filme *C*. Essas interações descritas são capturadas por processo denominado Coletor de Interações, sendo então armazenadas em uma Base de Dados que alimenta o Sistema de Recomendação, que pode utilizar técnicas tanto Baseado em Conteúdo quanto por Filtragem Colaborativa, por exemplo.

A Abordagem Baseada em Conteúdo foca nas preferências do usuário em relação a características específicas dos itens recomendados, conforme explicado por Khusro et al. (2016). A Figura 2.3 ilustra como as preferências do usuário são utilizadas para recomendar itens relacionados. A partir da relação entre o usuário Ana u_1 , ilustrada na primeira tupla da Figura 2.3 (a), e o item i_2 *A Fera*, cujos gêneros são romance e fantasia, ilustrado na segunda tupla da Figura 2.3 (b), suponha que ela tenha assistido ao filme *A Fera*, conforme ilustrado na primeira tupla da Figura 2.3

u1	Ana	i1	Avatar; 2009; Ficção Científica / Fantasia
u2	João	i2	A Fera; 2011; Romance / Fantasia
u3	Maria	i3	Os Vingadores; 2012; Ficção Científica / Ação
u4	Pedro	i4	Star Wars; 2015; Ficção Científica / Fantasia
u5	Lucas	i5	Aquaman; 2018, Fantasia / Ação

a) Usuário b) Item

(u1,i2)
(u2,i1)
(u3,i1)
(u4,i4)
(u5,i1)

c) VER

(u1,i2)
(u2,i1)
(u3,i1)
(u4,i4)
(u5,i1)

d) GOSTAR

(u1,i2)
(u2,i1)
(u3,i2)
(u4,i4)
(u5,i1)

e) ADD

Figura 2.3: Relação entre usuário e item.

(c) (u_1, i_2) , o marcado com *Gostei*, ilustrado na Figura 2.3 (d) e ainda o adicionado à sua lista de preferências, como ilustrado na Figura 2.3 (e). Nesse contexto, baseado em Conteúdo, o Sistema de Recomendação sugere filmes ao usuário João u_2 , cujos gêneros se assemelham aos do filme *A Fera*, como o filmes *Avatar* e *Star wars*, visando atender às preferências individuais do usuário e promover uma experiência de visualização personalizada.

No caso da Filtragem Colaborativa, as relações entre usuários e itens recomendados são estabelecidas com base nas interações entre usuários semelhantes, conforme descrito por Khusro et al. (2016). Conforme ilustrado na Figura 2.3, se o usuário João, e o usuário Maria, ilustrado na Figura 2.3 (a), demonstraram preferência semelhante pelo item *Avatar*, cujo gêneros são ficção científica e fantasia, ilustrado na Figura 2.3 (b), é provável que esses usuários compartilhem gostos semelhantes. Dessa forma, se o usuário Maria adicionou o item *A Fera* à sua lista de favoritos, conforme ilustrado na Figura 2.3(e) e o usuário João ainda não o assistiu, o Sistema de Recomendação pode sugerir o item *A Fera* para o usuário João, com base na similaridade de gostos entre os usuários João e Maria.

Quanto à Abordagem Híbrida, Khusro et al. (2016) relatam que as relações entre usuários e itens recomendados são consideradas a partir de uma combinação de características do item assistido e das preferências de usuários semelhantes. Por

exemplo, a Figura 2.3 ilustra a adição de um item a uma lista pessoal de favoritos, conforme ilustrado na Figura 2.3 (e) e indica que o usuário u_5 , ilustrado na Figura 2.3 (a), atribuiu um valor especial ao item i_1 . A partir dessa relação e das relações apresentadas em cada abordagem acima é possível capturar características do item e as preferências de usuários com interesses similares, resultando em uma recomendação e personalizada, como exemplo a recomendação dos itens como i_5 , i_2 e i_4 para o usuário u_5 .

A formalização da arquitetura dos Sistemas de Recomendação desempenha um papel importante no entendimento de como esses sistemas operam. Ao analisar as características fundamentais, é possível compreender as complexidades envolvidas na seleção e otimização das recomendações. Portanto, essa formalização serve como base para a pesquisa científica e compreensão do funcionamento de sistemas emergentes.

2.3 Sistemas de Recomendação que Utilizam Dados Espaciais

Os Sistemas de Recomendação que utilizam dados espaciais podem ser empregados de duas formas principais: melhorar as recomendações com base em informações espaciais ou recomendar diretamente um dado espacial. Por exemplo, Sheng et al. (2022) utiliza dados espaciais para otimizar a recomendação de amigos em redes sociais, enquanto Luo et al. (2023) propõe um sistema que recomenda pontos de interesse ao usuário com base na sua localização. A seguir, são apresentados outros estudos relevantes que exploram diferentes abordagens para integrar dados espaciais em Sistemas de Recomendação.

O estudo conduzido por Jiao e Chiang (2021) se destaca por propor uma nova abordagem em Sistemas de Recomendação que utilizam dados espaciais. Essa abordagem integra algoritmos de recomendação baseados em conteúdo com informações espaciais. Além disso, a pesquisa investiga o impacto de vários métodos de redução de dimensão na qualidade das recomendações, explorando diversas técnicas que já são comumente utilizadas em Sistemas de Recomendação.

O estudo conduzido por Artemenko et al. (2020) investiga de forma detalhada a origem e a extração de dados espaciais em Sistemas de Recomendação. Ele oferece uma análise abrangente das estratégias e recursos disponíveis para o desenvolvimento de sistemas de recomendação baseados em localização móvel. Com foco na orientação ao contexto espacial em que o usuário se encontra, o qual considera aspectos como: histórico de popularidade da área e influências e restrições de quarentena, esse estudo se concentra no planejamento de rotas de distanciamento social em ambientes urbanos. A abordagem adotada propõe Sistemas de Recomendação que incorporam informações do contexto em que o usuário está inserido para extrair dados essenciais e assim calcular os riscos associados à aglomeração como uma região em quarentena.

O estudo de Acharya et al. (2023) aposta em uma abordagem Baseada em Conteúdo, e faz a recomendação de objetos estáticos, nesse caso também recomendação de ponto de interesse turístico, agrupando os locais próximos aos visitados anteriormente. Usa recomendação de locais baseado em redes sociais para definir pontos de interesse para um determinado usuário. Considera inicialmente a localização do usuário, e em seguida mede a distância entre os pontos de interesse. A partir disso, os pontos de interesse são categorizados, e em seguida são classificados e agrupados por região. Após, o sistema fornece as recomendações. Este trabalho mostrou-se relevante por atingir o objetivo de reduzir o esforço humano na escolha de pontos turísticos para visitação.

No estudo conduzido por Vahidnia (2022), uma inovadora abordagem é proposta para melhorar os sistemas de recomendação tradicionais de Pontos de Interesse. Este método procura identificar a influência geográfica nas Redes Sociais Baseadas em Localização, a fim de recomendar Pontos de Interesse. Essa abordagem utiliza uma técnica de ponderação espacial de kernel, inspirada no conceito de média ponderada por similaridade. O diferencial dessa proposta está na consideração simultânea da interação entre o efeito da distância e da preferência. A Filtragem Colaborativa é incorporada, abrangendo abordagens baseadas em usuário e em itens. Na baseada em usuário, a similaridade é entre usuários, enquanto na baseada em item, a similaridade ocorre entre itens, neste caso, os Pontos de Interesse.

2.4 Revisões Sistemáticas Relacionadas

O estudo de Weydemann et al. (2019) é um trabalho de revisão sistemática que foca na investigação da categorização precisa das avaliações em Sistemas de Recomendação espaciais. Ele explora as decisões algorítmicas desses sistemas ao recomendar objetos espaciais, como pontos de interesse e áreas geográficas. Além disso, busca quantificar os critérios de equidade adotados, especialmente em relação aos vieses derivados da popularidade de locais, muitas vezes influenciados pelos perfis de usuários que moldam as preferências dos grupos nesses sistemas. Embora este estudo compartilhe a metodologia de revisão sistemática com o nosso trabalho, o trabalho de Weydemann et al. (2019) foca exclusivamente na avaliação dos Sistemas de Recomendação. Em contraste, este estudo oferece um mapeamento sistemático mais abrangente, explorando outras temáticas relevantes.

O estudo de Tiwari et al. (2012), é um trabalho de revisão sistemática que investiga trabalhos desenvolvidos na área de Sistemas de Recomendação que utilizam dados espaciais, voltados para fornecer recomendações automatizadas a usuários móveis, com base em 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. Também aborda os desafios de implementação e avaliação, além das aplicações potenciais em áreas como turismo, medicina, arqueologia e estudos ambientais. Embora este estudo compartilhe a metodologia de revisão sistemática com o nosso trabalho, o trabalho de Tiwari

et al. (2012) se debruça sobre uma análise qualitativa dos desafios encontrados durante o desenvolvimento desses sistemas. Em contraste, este estudo oferece uma visão quantitativa da área, acerca de técnicas e abordagens utilizadas.

O artigo proposto por Roy e Dutta (2022) é um trabalho de revisão sistemática que analisa a crescente importância dos Sistemas de Recomendação como ferramentas cruciais para filtrar informações online, destacando sua popularidade em meio às mudanças nos hábitos dos usuários que acessam à Internet. Já o artigo de Zangerle e Bauer (2022), que também é uma revisão sistemática, busca sistematizar e consolidar o conhecimento disperso sobre a avaliação do desempenho dos Sistemas de Recomendação, através da construção de uma estrutura sobre a avaliação desses sistemas. Embora estes estudos compartilhem da abordagem de revisão sistemática semelhante ao nosso trabalho, não abordam a utilização de dados espaciais, apenas se debruçam sobre Sistemas de Recomendação. Em contraste, este estudo foca em Sistemas de recomendação que utilizam dados espaciais.

2.5 Revisão Sistemática versus Mapeamento Sistemático

A pesquisa acadêmica e científica se baseia na análise da literatura existente sobre tópicos específicos. Para sistematizar esse processo, duas abordagens se destacam: a Revisão Sistemática de Literatura e o Mapeamento Sistemático de Literatura. Ambas possuem procedimentos metodológicos estruturados para identificar e agregar evidências de pesquisas (Kitchenham et al., 2007). Além de desempenharem um papel crucial na organização e síntese do conhecimento acumulado, essas abordagens têm propósitos e métodos distintos.

A Revisão Sistemática de Literatura é uma abordagem rigorosa e sistemática que busca responder a perguntas de pesquisa específicas. Kitchenham et al. (2007) identificam em seu estudo três fases essenciais para o processo: Planejamento, Condução/Realização e Relato/Reporte. O Planejamento se inicia com a definição de um protocolo. Em seguida, na Condução, a qualidade metodológica dos estudos selecionados é avaliada. Por fim, no Relato, a síntese dos resultados são apresentados. A revisão sistemática pode ser conduzida de maneira quantitativa, como em um estudo mais aprofundado, como a meta-análise, ou qualitativamente, a fim de verificar a consistência ou contradições nos resultados, promove uma análise aprofundada dos estudos e oferece conclusões embasadas em evidências sólidas.

Além disso, Dermeval et al. (2020) relatam que a revisão sistemática desempenha um papel crucial na identificação de lacunas e inconsistências na literatura, especialmente em estudos empíricos. Essa abordagem é relevante em áreas com uma extensa quantidade de estudos, nas quais há uma necessidade urgente de consolidar resultados. Embora não exija um grande volume de estudos, é essencial que cada estudo seja examinado minuciosamente, o que proporciona uma síntese dos resultados (Kitchenham et al., 2007).

Por outro lado, o Mapeamento Sistemático de Literatura apresenta um escopo quantitativo maior. Sua principal finalidade reside em mapear e categorizar a literatura existente em um determinado campo de pesquisa, sem a necessidade de responder a uma pergunta de pesquisa específica (Dermeval et al., 2020). Enquanto a Revisão Sistemática adota critérios de inclusão rigorosos na etapa do Planejamento, o mapeamento, como destacado por Kitchenham et al. (2007), pode ser mais abrangente e inclusivo, incorporando na etapa da Realização uma diversidade de estudos e documentos. Assim, a fase de Reporte fornece uma visão geral das tendências, dos temas recorrentes e das áreas de foco na literatura.

De acordo com Kitchenham et al. (2007), um Mapeamento Sistemático desempenha um papel fundamental para os pesquisadores que buscam compreender a perspectiva geral de um campo de pesquisa, identificar lacunas e definir direções para futuras investigações, incluindo a identificação de grupos de estudos relacionados a um mesmo tema. Além disso, o mapeamento pode ser útil para identificar tendências emergentes e áreas de pesquisa saturadas.

Tabela 2.1: Comparação entre Revisão Sistemática de Literatura e Mapeamento Sistemático de Literatura, adaptada de Kitchenham et al. (2007).

Aspectos	Revisão Sistemática	Mapeamento Sistemático
Abordagem	Rigorosa e sistemática	Abrangente e inclusiva
Finalidade	Responder a perguntas de pesquisa específicas	Mapear e categorizar a literatura existente
Processo de Busca	Definida pelas questões de pesquisa	Pelo tópico da área
Estratégia de Pesquisa	Mais rigorosa, abrangendo todos os estudos relevantes	Menos rigorosa, precisa e exaustiva, com critérios de inclusão/exclusão precisos
Síntese dos Resultados	Pode ser quantitativa (meta-análise) ou qualitativa	Oferece uma visão quantitativa das tendências e temas recorrentes
Aplicação	Análise aprofundada e conclusões baseadas em evidências sólidas	Identificação de lacunas, direcionamento de pesquisas futuras

A Tabela 2.1 oferece uma comparação entre a Revisão Sistemática de Literatura e o Mapeamento Sistemático de Literatura, ressaltando as principais diferenças entre essas duas metodologias de pesquisa em termos de Abordagem, Finalidade, Processo de Busca, Estratégia de Pesquisa, Síntese dos Resultados e Aplicação (Kitchenham et al., 2007).

Em resumo, tanto a Revisão Sistemática de Literatura quanto o Mapeamento Sistemático de Literatura desempenham papéis importantes na pesquisa acadêmica. Enquanto a Revisão Sistemática se concentra em responder a perguntas de pesquisa específicas com uma análise aprofundada dos estudos, o Mapeamento Sistemático oferece uma visão geral abrangente do conhecimento existente em um campo. A escolha entre essas abordagens depende dos objetivos da pesquisa e do escopo da investigação.

2.6 Ferramentas de Suporte ao Mapeamento Sistemático

O Mapeamento Sistemático é um método robusto para sintetizar e organizar o conhecimento em uma área de pesquisa. Para garantir a eficácia e a precisão desse processo, é fundamental contar com ferramentas de suporte que auxiliem na organização, rastreabilidade e documentação de todas as etapas. Entre as ferramentas disponíveis destacam-se o *Parsifal* (<https://parsif.al/>), o *Rayyan* (<https://www.rayyan.ai>) e o *Covidence* (<https://www.covidence.org>), por serem amplamente utilizadas para revisões e mapeamentos sistemáticos, facilitar a triagem de estudos, e oferecer funcionalidades para revisões colaborativas.

Essas plataformas proporcionam funcionalidades avançadas que ajudam pesquisadores a conduzir revisões e mapeamentos sistemáticos de forma estruturada e eficiente. Entre essas opções, o *Parsifal* será descrito nesta pesquisa por sua interface intuitiva e suporte a múltiplas etapas do processo metodológico (Parsifal, 2021), embora as demais ferramentas também apresentem funcionalidades semelhantes.

O *Parsifal* oferece um ambiente integrado e baseado na web, que possibilita a colaboração entre pesquisadores durante todas as etapas do processo metodológico. A interface intuitiva e bem estruturada facilita o gerenciamento de projetos, desde o planejamento inicial até a etapa de relatório final, seguindo a metodologia de Kitchenham et al. (2007). Essa organização é fundamental para revisões sistemáticas, que frequentemente envolvem um grande volume de dados e etapas rigorosas de análise.

Um dos principais componentes do *Parsifal* é o módulo de “Planejamento”, onde os objetivos da pesquisa, as questões de pesquisa e as *strings* de busca podem ser definidos. Nesse módulo, os usuários podem configurar a metodologia utilizada, como o PICOC (Population, Intervention, Comparison, Outcome, Context), facilitando a construção de estratégias de busca claras e direcionadas. Além disso, o *Parsifal* permite o registro detalhado dos critérios de inclusão e exclusão, que são essenciais para garantir a consistência na seleção dos estudos.

Outro recurso importante é o módulo de “Condução”, onde são realizadas as etapas de busca, seleção e avaliação dos estudos. O *Parsifal* possibilita a importação de referências diretamente das bases de dados, como IEEE Xplore, Scopus e ACM Digital Library, automatizando parte do processo e reduzindo erros manuais. Durante a seleção, a ferramenta apresenta funcionalidades para a triagem inicial e a avaliação de cada estudo, com opções para marcar, incluir ou excluir artigos, justificando as decisões tomadas.

Ainda no módulo de “Condução”, a aba “Extração de Dados” é outra funcionalidade relevante. Nela, os pesquisadores podem criar formulários personalizados para coletar e organizar informações específicas de cada estudo selecionado. Isso permite uma análise mais detalhada e estruturada, além de facilitar a visualização dos dados extraídos, otimizando o processo de síntese dos resultados.

Por fim, o módulo de “Relatório” ajuda na documentação e geração de relatórios detalhados sobre as etapas do mapeamento sistemático. O *Parsifal* permite a exportação das informações do planejamento, execução e dos resultados em formatos, como DOC, CSV e PDF, garantindo a rastreabilidade e a transparência do processo. Essa funcionalidade é especialmente útil para apresentar os resultados da pesquisa de maneira clara e organizada, seja para publicação ou para compartilhamento entre os membros da equipe.

Além desses componentes, o *Parsifal* se destaca por ser uma ferramenta colaborativa. Ele permite que múltiplos pesquisadores trabalhem simultaneamente em um projeto, promovendo a troca de ideias e a divisão de tarefas de maneira eficiente. A possibilidade de atribuir papéis específicos para cada membro da equipe torna o processo mais dinâmico e alinhado às necessidades do grupo.

Portanto, a utilização de ferramentas como o *Parsifal* desempenham um papel essencial no mapeamento sistemático, pois proporciona um ambiente centralizado e funcional para planejar, conduzir e documentar cada etapa do processo. Simplifica tarefas complexas e eleva a qualidade e a confiabilidade dos resultados obtidos.

Capítulo 3

Metodologia

A presente pesquisa adota uma abordagem teórica e exploratória. Segundo de Sousa et al. (2021), a abordagem teórica visa fundamentar o estudo em bases sólidas, permitindo a análise de conceitos e teorias relevantes no campo. A natureza exploratória, por sua vez, é utilizada para uma investigação aberta e flexível das diversas abordagens existentes. Finalmente, a pesquisa bibliográfica desempenha um papel fundamental ao revisar e sintetizar criticamente a literatura disponível.

Esta pesquisa adota uma abordagem metodológica quantitativa. Esse tipo de abordagem é adotada para realizar um levantamento mensurável da produção acadêmica, a fim de mapear essa área de estudo (Wagner et al., 2023). A fundamentação para esta escolha metodológica é respaldada pela perspectiva de Prodanov e De Freitas (2013), que destaca a importância da pesquisa científica para compreender os aspectos relacionados a um determinado tema. Assim, esta metodologia está alinhada com o objetivo desta pesquisa.

O Mapeamento Sistemático de Literatura, conforme abordado por Kitchenham et al. (2007), é caracterizado por um rigor metodológico que inclui uma ampla cobertura na busca dos artigos, e uma extração sistemática de dados, realizadas de maneira transparente e consistente. De acordo com Donthu et al. (2021), essa abordagem, alinhada aos princípios do método científico, assegura a integridade da pesquisa, proporcionando uma base sólida para as conclusões apresentadas e contribuições valiosas ao conhecimento no campo de estudo.

Ainda segundo Kitchenham et al. (2007), a condução de um Mapeamento Sistemático de Literatura segue um rigor metodológico que assegura a replicabilidade e a transparência do processo. Para garantir esses princípios, pode-se utilizar ferramentas como o *Parsifal* (Seção 2.6) que facilitam a aplicação das diretrizes propostas pelos autores. Essas ferramentas permitem a criação de protocolos robustos para a seleção de artigos, organização dos critérios de inclusão e exclusão, além de auxiliar na extração dos dados e na avaliação de qualidade dos artigos selecionados. Assim, a aplicação prática dessa metodologia, mediada por tecnologia, promove a sistema-




Figura 3.1: Etapas do processo metodológico.

tização do processo de análise e proporciona maior eficiência na condução do estudo, alinhando-se às melhores práticas recomendadas na literatura.

Um Mapeamento Sistemático de Literatura é composto fundamentalmente por três fases bem definidas: Planejamento, descrito na Seção 3.1; Realização, na Seção 3.2; e Reporte, abordado na Seção 3.3. A Figura 3.1, apresenta esse processo em uma sequência lógica, que inicia-se no Planejamento, com definição geral do protocolo, em seguida Realização, para a busca e extração dos dados e a avaliação da qualidade dos artigos e conclui-se no Reporte, com a análise e apresentação dos resultados, conforme delineado por Kitchenham et al. (2007). Finalmente, a Seção 3.4 discorre sobre a Avaliação da Metodologia adotada no Mapeamento Sistemático de Literatura.

3.1 Planejamento

Durante a fase de planejamento, visando assegurar a solidez e a abrangência do Mapeamento Sistemático de Literatura, o protocolo de revisão deve ser meticulosamente elaborado, de modo que seja imparcial e reproduzível (Kitchenham et al., 2007). Este protocolo incorpora uma série de *strings* de busca cuidadosamente delimitadas, a definição criteriosa de bases de dados coerentes à pesquisa, e a aplicação de critérios específicos de inclusão e exclusão de trabalhos acadêmicos, todos orientados pelas Questões de Pesquisa definidas.

Strings de Busca. Conjunto de consultas a serem submetidas para as bases de dados. Esse conjunto é composto por diversas combinações de termos relevantes ao escopo de estudo abordado. O idioma utilizado frequentemente é o inglês, considerando a predominância dessa língua nas publicações científicas na área, incorporando sinônimos e variações linguísticas pertinentes ao campo de estudo. Além disso, são empregadas palavras-chave específicas de acordo com as características técnicas e conceituais do escopo do estudo, assegurando, assim, que a busca engloba os artigos pertinentes ao tema proposto (Kitchenham et al., 2007).

Fontes de Informação. Conjunto de repositórios renomados contendo artigos científicos. Bases de dados renomadas são exploradas para garantir uma cobertura da literatura existente sobre a temática. Estas bases podem oferecer uma ampla gama de artigos, proporcionando acesso a uma diversidade de perspectivas e descobertas no âmbito da pesquisa (Kitchenham et al., 2007).

Crítérios de Inclusão e Exclusão. Os critérios de inclusão e exclusão são regras que devem ser atendidas para manter ou retirar um artigo da seleção de artigos a serem avaliados. Esses critérios buscam garantir a consistência e a validade na seleção dos artigos, contribuindo para a qualidade e reprodutividade dos resultados da pesquisa (Kitchenham et al., 2007).

3.2 Realização

Essa pesquisa possui uma abordagem estruturada, envolvendo busca, seleção, avaliação de qualidade e extração de dados. A busca em bases relevantes é seguida por uma seleção criteriosa, seguida pela avaliação da qualidade dos artigos escolhidos antes da extração detalhada de dados relevantes. Essa abordagem visa obter resultados sólidos e confiáveis no Mapeamento Sistemático de Literatura, proporcionando uma análise sobre a temática estudada (Donthu et al., 2021).

Busca de estudos. Na primeira fase do processo, um conjunto inicial de artigos relevantes é extraído a partir de bases de dados previamente definidas. A busca conduzida utiliza critérios específicos, como termos-chave, títulos e resumos, data de publicação para garantir a abrangência e sensibilidade na identificação de trabalhos pertinentes à integração de dados espaciais em Sistemas de Recomendação. Essa abordagem inicial visa estabelecer uma fundação sólida para a revisão subsequente, proporcionando um conjunto de trabalhos candidatos para a análise (Donthu et al., 2021).

Seleção dos Estudos. A seleção dos artigos é dividida em duas etapas. Na primeira etapa é realizada uma leitura crítica dos títulos, resumos e palavras-chave dos trabalhos encontrados. Este processo é pautado por critérios de inclusão e exclusão previamente estabelecidos. Na segunda etapa é realizada uma leitura completa dos trabalhos selecionados na etapa anterior, fazendo uma avaliação da qualidade desses artigos.

Avaliação da qualidade dos estudos. A avaliação da relevância dos artigos selecionados é conduzida mediante uma revisão por pares (Kitchenham et al., 2007). Cada estudo é submetido a uma revisão crítica, considerando a clareza e profundidade com que aborda a integração de dados espaciais, a metodologia adotada e a consistência entre objetivos da pesquisa e resultados observados. Além disso, é avaliada a atualidade e pertinência dos artigos em relação ao panorama atual da pesquisa na área. Essa análise criteriosa possibilita identificar e priorizar os artigos mais relevantes, contribuindo para a precisão e solidez das conclusões obtidas (Wagner et al., 2023).

Extração de Dados. Nessa etapa, é realizada a leitura integral de cada trabalho em ordem cronológica decrescente, para verificar se surgem novas tendências e tópicos relevantes a serem abordados. Os dados relevantes são identificados, extraídos e organizados de acordo com um sistema de tabulação.

3.3 Reporte

A análise e apresentação dos dados desempenham um papel importante nesta pesquisa, proporcionando *insights* sobre a interseção entre Sistemas de Recomendação e Dados Espaciais. Nesta fase, os dados são examinados cuidadosamente para identificar padrões e tendências relevantes, conforme Kitchenham et al. (2007), contribuindo para uma melhor compreensão do estado atual da literatura. A apresentação segue uma abordagem clara e organizada, utilizando gráficos e tabelas para facilitar a interpretação dos resultados. Essa fase possibilita consolidar e comunicar de maneira eficaz as descobertas obtidas, promovendo uma contribuição ao entendimento desse campo de pesquisa.

Análise dos Resultados. A análise dos resultados obtidos após a extração dos dados também é submetida a um processo de revisão por pares para assegurar a confiabilidade das conclusões obtidas (Kitchenham et al., 2007). Assim, suas contribuições e sugestões são avaliadas para que sejam incorporadas à análise final. Durante a análise dos dados é possível identificar padrões distintos que respondam às Questões de Pesquisa. Além disso, é possível validar as conclusões por meio de uma abordagem adicional. Para isso, são realizadas sessões de discussão e validação com outros pesquisadores na área da pesquisa. Essa abordagem proporciona uma perspectiva externa valiosa, contribuindo para a validação adicional da análise dos resultados.

Apresentação dos Resultados. A apresentação dos dados é aplicada de forma estruturada e organizada para oferecer clareza e acessibilidade aos leitores. Os resultados são apresentados de maneira tabular, categorizados por temas e subtemas derivados da taxonomia estabelecida e das respostas às Questões de Pesquisa. A utilização da tabela para apresentar os resultados proporciona uma visão consolidada das principais características dos artigos, incluindo detalhes técnicos sobre o tema. Além disso, gráficos são incorporados para ilustrar estatísticas referentes a tendências, variações e relações entre diferentes dados. Essas abordagens visuais enriquecem a compreensão global dos resultados, permitindo uma interpretação mais rápida e intuitiva (Kitchenham et al., 2007).

3.4 Avaliação do Mapeamento Sistemático

A avaliação da qualidade desse Mapeamento Sistemático é realizada concomitante a cada Etapa (Napoleão et al., 2017). Quanto à definição dos Objetivos e das Questões de Pesquisa, são discutidos quanto a sua aplicabilidade e reprodutividade. O planejamento, realização e apresentação dos dados também precisam ser avaliados, por meio da execução de testes de todo percurso metodológico delineado em uma base de dados específica. Durante a execução do teste, é possível avaliar a abrangência e a qualidade das strings de busca utilizadas, verificando se foi possível extrair um quantitativo relevante nessa fase.

Após a extração dos dados também é avaliada a qualidade e a relevância dos artigos

obtidos, para verificar se eles oferecem panoramas relevantes, atendem aos objetivos propostos e respondem às questões de pesquisa. Após a etapa de extração, é realizada uma análise e interpretação dos resultados obtidos. Por fim, é observado se estes resultados foram apresentados de forma sistemática e objetiva e se foi possível explorar o escopo da pesquisa e propor contribuições para a área.

Capítulo 4

Execução

O processo metodológico deste trabalho foi conduzido de forma sistemática e estruturada, abrangendo etapas essenciais para garantir a relevância e a qualidade dos estudos selecionados. Nesse contexto, a ferramenta *Parsifal* (Seção 2.6) desempenhou um papel central, auxiliando de forma integrada nas fases de planejamento, condução e reporte. A ferramenta proporcionou suporte para a organização, rastreabilidade e padronização de todas as etapas do processo, desde a definição das estratégias de busca até a análise e documentação dos resultados.

Inicialmente, na plataforma *Parsifal*, foram inseridos os objetivos da pesquisa (Seção 1.1) e as *strings* de busca foram definidas com base na metodologia PICOC (Seção 2.6). Em seguida, foram estabelecidas as questões de pesquisa (Seção 1.2), bem como os critérios de inclusão e exclusão e qualidade, visando selecionar estudos que abordam diretamente Sistemas de Recomendação que utilizam dados de espaciais (localização). Também foram especificados, no formulário da plataforma, quais dados seriam extraídos de cada artigo selecionado.

Posteriormente as bases de dados da pesquisa foram selecionadas com base na sua abrangência e relevância na área de Ciência da Computação e no tema desta pesquisa. Na sequência, foram realizadas buscas em cada base. Todos os artigos encontrados em suas respectivas bases foram importados para a plataforma *Parsifal*. Essa plataforma ofereceu funcionalidades que facilitaram a aplicação dos critérios de inclusão e exclusão, além da avaliação dos critérios de qualidade, permitindo uma triagem sistemática dos estudos mais relevantes.

A plataforma *Parsifal* também permite agrupar os artigos em categorias de aprovados ou reprovados, conforme os critérios estabelecidos. Após essa triagem, foi realizada a leitura dos artigos aprovados, e os dados que respondem às questões de pesquisa foram inseridos no formulário disponibilizado pela própria plataforma. Posteriormente, os dados coletados foram exportados para uma planilha, a fim de facilitar a organização e análise das informações.

Por fim, os dados foram analisados e apresentados por meio de representações gráfi-

cas (gráficos de barras ou de pizza), elaboradas com o auxílio da ferramenta *Google Sheets*. Para facilitar o agrupamento e a interpretação das informações, foram aplicados filtros em cada coluna da planilha, o que permitiu uma visualização objetiva dos dados extraídos.

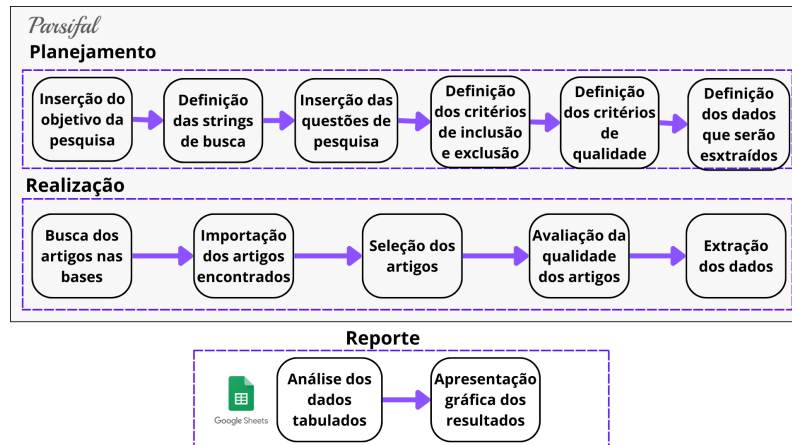


Figura 4.1: Processo de execução.

A Figura 4.1 contém a execução do processo metodológico adotado nesta pesquisa, com base nas funcionalidades da plataforma *Parsifal* e do *Google Sheets*, que ofereceram suporte ao planejamento, à realização e ao reporte deste Mapeamento Sistemático. O processo está organizado em duas macro etapas: no primeiro quadro está ilustrada a primeira macro etapa, contendo o planejamento e a realização que foram organizados na plataforma *Parsifal*. Já o segundo quadro que ilustra a segunda macro etapa, contém o reporte, que foi organizado na ferramenta *Google Sheets*. Cada quadro contém os passos realizados de forma sequencial durante a execução do processo metodológico.

Este capítulo está organizado da seguinte forma: na Seção 4.1 descreve a Estratégia de Busca, seguida pela Seção 4.2 que apresenta a Seleção dos Estudos. Por fim, a Seção 4.4 discorre sobre a Extração dos Dados.

4.1 Estratégia de Busca


A busca por publicações foi realizada nas bases ACM Digital Library¹, IEEE Xplore², ScienceDirect³ e Scopus⁴. Essas bases foram escolhidas por conterem uma vasta quantidade de dados na área de computação e por incluírem conferências relevantes, como a SIGSPATIAL (*International Conference on Advances in Geographic Infor-*

¹<http://portal.acm.org>

²<http://ieeexplore.ieee.org>

³<http://www.sciencedirect.com>

⁴<http://www.scopus.com>



The screenshot shows the ACM Digital Library search interface. At the top, it says "Search" and "Search anything within the ACM Digital Library or go to your [Saved Searches](#)". Below this, there is a section "Search items from:" with a dropdown menu set to "The ACM Full-Text collection" and an information icon. Underneath, there is a section "Search Within" with a dropdown menu set to "Title" and a search bar containing the text "recommendation AND location". There is also a plus icon next to the search bar.

Figura 4.2: *String* de busca usada na base ACM Digital Library.

mation Systems) e ISPRS (*International Journal Of Geo Information*), que abordam dados espaciais e de localização.

Em seguida, adotou-se a metodologia PICOC, estabelecendo os seguintes elementos: Population: Sistemas de Recomendação; Intervention: integração de dados espaciais em sistemas de recomendação; Comparison: Sistemas de Recomendação que utilizam dados espaciais e aqueles que não utilizam; Outcome: melhoria na precisão e relevância das recomendações e Context: plataformas online ou redes sociais que utilizam dados espaciais.

Para assegurar a busca de termos sinônimos, conforme identificado no PICOC, foi definida a seguinte estratégia de busca. Optou-se pelos termos “*recommender*” ou “*recommendations*” sem incluir o termo “*system*”, para se referir a Sistemas de Recomendação. Para relacionar as recomendações a Dados de Espaciais, foi incluído o termo “*location*” na *string* de busca. Assim, a combinação “*recommendation AND location*” foi utilizada como base para selecionar artigos que tratam da interseção entre Sistemas de Recomendação e Dados Espaciais. A busca foi realizada apenas nos títulos dos artigos.

Cada base de dados possui características específicas que influenciam como as consultas são interpretadas e os resultados são retornados. A exemplo disso, bases como a ACM Digital Library, retornam sinônimos, enquanto bases como IEEE Xplore e Scopus retornam variações de singular e plural.

Na ACM Digital Library as consultas frequentemente retornam sinônimos das palavras-chave utilizadas. Desse modo a busca por “*recommendation*” também retorna a variação “*recommender*”. Para esta base, utilizou-se a *string* de busca “*recommendation AND location*” exclusivamente no título dos artigos.

A Figura 4.2 é um print do formulário de busca de artigos da ACM Digital Library, preenchido com a *String* de busca. O primeiro campo indica que a busca é feita em toda a coleção da ACM (*The ACM Full-Text collection*). A segunda seção (Search Within) é sobre a busca dos artigos de interesse, restringindo a busca ao título dos artigos, utilizando as palavras “*recommendation AND location*”.

The screenshot shows the IEEE Xplore search interface with the title "Enter keywords and select fields." It contains four search rows. Each row has a "Search Term" input field, a connector dropdown menu, and a field selection dropdown menu. The first row has "recommendation" in the search term and "Document Title" in the field selection. The second row has a dropdown menu set to "AND", "location" in the search term, and "Document Title" in the field selection. The third row has a dropdown menu set to "OR", "recommender" in the search term, and "Document Title" in the field selection. The fourth row has a dropdown menu set to "AND", "location" in the search term, and "Document Title" in the field selection.

Figura 4.3: *String* de busca usada na base IEEE Xplore.

The screenshot shows the ScienceDirect "Advanced Search" interface. It features the ScienceDirect logo and "Journals & Books" text in the top right. The main heading is "Advanced Search". Below it, there is a "Title" label and a search input field containing the query "(recommendation AND location) OR (recommender AND location)". A "Search tips" link is visible on the left.

Figura 4.4: *String* de busca usada na base ScienceDirect.

Nas bases de dados IEEE Xplore e ScienceDirect, diferentemente da ACM Digital Library, as consultas não retornam sinônimos, apenas variações entre singular e plural. Para replicar um comportamento similar ao encontrado na base da ACM, utilizamos o conectivo OR. Para fazer a busca tanto pelo termo “*recommender*” quanto pelo termo “*recommendation*”, ampliando a busca, usando expressões distintas, de modo a alcançar um ou outro sinônimo. Portanto, as strings de busca definidas para esta base são “(*recommendation* AND *location*) OR (*recommender* AND *location*)”, aplicada exclusivamente nos títulos dos artigos.

A Figura 4.3 é um print do formulário de busca de artigos na IEEE Xplore. O primeiro campo exibe o primeiro termo usado na pesquisa “*recommendation*” com a restrição da busca apenas nos títulos dos documentos (*Document Title*). O segundo campo exibe o conectivo AND entre os dois primeiros campos, o segundo termo da busca é “*location*” e a indicação que o termo pesquisado se restringe apenas nos títulos do documento. O terceiro campo exibe o conectivo OR, entre as duas primeiras expressões e as duas últimas, possibilitando ampliar as buscas contemplando as duas consultas. E o termo a ser pesquisado “*recommender*” e a restrição da busca apenas nos títulos do documento. O último campo exibe o conectivo AND, o quarto termo usado na busca “*location*” e a restrição da busca a apenas o título dos documentos.

A Figura 4.4 é um print do formulário de busca avançada (*Advanced Search*) de artigos na ScienceDirect. O primeiro campo exibe o termo usado da pesquisa (“*recommendation*” AND “*location*”) OR (“*recommender*” AND “*location*”) com a restrição da busca apenas nos títulos dos documentos (*Title*).

Search within Article title	Search documents * recommender
OR	
Search within Article title	Search documents recommendation
AND	
Search within Article title	Search documents location

Figura 4.5: *String* de busca usada na base Scopus.

Na base Scopus, a interpretação das consultas de busca é semelhante à da base IEEE e ScienceDirect, retornando apenas variações entre singular e plural, o que requer a complementação com sinônimos. No entanto, diferente da IEEE, ela retorna em sua consulta, por meio de uma única string de busca, expressões sinônimas como “*recommendation*” ou “*recommender*”, sem duplicar a busca por “*location*”. Para esta pesquisa, foi utilizada a string de busca “(*recommendation* OR *recommender*) AND *location*” exclusivamente nos títulos dos artigos. Além disso, observa-se que a Scopus indexa publicações da ACM e IEEE, possibilitando encontrar artigos duplicados.

A Figura 4.5 é um print da busca de artigos na Scopus. O primeiro campo exibe a restrição da busca a apenas dentro do título dos artigos e o termo escolhido para a busca “*recommender*” (*Search within Article Title - Search documents*). O segundo campo exibe o conectivo OR. O terceiro campo exibe a restrição da busca a apenas dentro do título dos artigos e o termo da busca nos documentos “*remommendation*”. O quarto campo é o conectivo AND. O quinto campo exibe a restrição da busca a apenas dentro do título dos artigos e o termo da busca nos documentos “*location*”.

4.2 Seleção dos Estudos

Nesta Seção, são apresentados os critérios utilizados para inclusão e exclusão dos artigos, além dos critérios de qualidade aplicados. A execução da seleção dos estudos, que foi realizada em duas etapas, iniciando com uma triagem preliminar baseada nos títulos e resumos, seguida pela leitura integral dos artigos elegíveis.

4.2.1 Critérios de Inclusão da Primeira Etapa

Nesta etapa inicial, foram definidos critérios de inclusão específicos para assegurar que os estudos selecionados estivessem alinhados com os objetivos da pesquisa.

- **Artigos publicados até junho de 2024**, trabalhos publicados em qualquer data, até junho de 2024, que estão disponíveis nas plataformas de busca ACM Digital Library, IEEE Xplore, ScienceDirect e Scopus;

- **Estudos primários**, estudos do tipo experimentos e estudos de caso, pois esses artigos fornecem dados originais e detalhados diretamente provenientes de investigações científicas.
- **Objeto de estudo**, trabalhos que integram explicitamente Dados Espaciais em Sistemas de Recomendação

4.2.2 Critérios de Exclusão da Primeira Etapa

Para garantir a relevância dos dados analisados, estabelecemos os seguintes critérios de exclusão.

- **Artigos duplicados**. Surgem quando um mesmo estudo é publicado em mais de uma fonte, podendo ocasionar redundância. Portanto, optamos por excluir esses textos;
- **Livro, capítulo de livro ou Editorial**. Em geral, os assuntos discutidos em livros já foram previamente abordados em artigos científicos. Além disso, muitos capítulos de livro não estão disponíveis para acesso. Portanto, optamos por excluir esses textos;
- **Relatório do workshop**. Em geral são frequentemente indexados separadamente dos relatórios publicados. Além disso, muitos desses relatórios não estão disponíveis para acesso público. Por esses motivos, optamos por excluir esses documentos.
- **Artigos que não estão publicados originalmente em inglês**, esses trabalhos frequentemente seguem padrões internacionais de metodologia, estrutura e rigor científico, facilitando a comparação entre estudos e a replicabilidade dos resultados;
- **Artigos fora do período especificado**. Artigos publicados após junho de 2024 foram excluídos para estabelecer um recorte temporal alinhado à linha do tempo da pesquisa;
- **Artigos resumidos**. Artigos que possuem até 6 páginas frequentemente oferecem uma análise limitada do tema, o que pode não ser suficiente para uma compreensão aprofundada do assunto em estudo. Portanto, optamos por excluir esses textos;
- **Artigos não disponíveis**. Alguns artigos não podem ser acessados através do convênio existente na UEFS, ou suas páginas de repositório não podem ser encontradas. Isso limita a acessibilidade e a verificação das informações contidas nesses documentos. Por esses motivos, optamos por excluir esses textos;
- **Estudos primários do tipo Surveys**. Esses estudos geralmente coletam dados qualitativos e quantitativos por meio de questionários ou entrevistas, podem introduzir vieses e fornecer informações que não são diretamente aplicáveis

à análise aprofundada necessária para este trabalho. Portanto, optamos por excluir esses textos. Ademais, surveys mais relevantes, relacionados ao tema, já foram incluídos na seção de trabalhos relacionados;

- **Estudos secundários e terciários.** Esses estudos contêm dados já analisados ou revisões sobre o tema. Esses documentos podem introduzir vieses de interpretação e repetição de informações. Portanto, optamos por excluir esses textos.
- **Literatura Cinza.** Embora a literatura cinza (como teses, dissertações, relatórios técnicos e documentos não publicados) possa conter informações valiosas, ela frequentemente não passa por revisões rigorosas por pares, o que pode comprometer sua validade científica. Portanto, optamos por excluir esses trabalhos.
- **Abordagem teórica requerida.** Artigos que não abordam a integração de Dados Espaciais em Sistemas de Recomendação foram excluídos, pois não atendem ao foco central da pesquisa.

4.2.3 Questões de qualidade - Segunda Etapa

Nesta etapa, foram elaboradas questões de qualidade para avaliar de forma criteriosa a qualidade dos estudos selecionados previamente.

- O estudo foi publicado em periódicos ou conferências relevantes?

Resposta: Sim ou Não

Justificativa: Priorizar trabalhos publicados em periódicos acadêmicos ou conferências reconhecidas na área de Sistemas de Recomendação, Dados Espaciais ou áreas relacionadas, com classificação Qualis A no Brasil, assegura a qualidade e a relevância científica das fontes selecionadas.

- Foi possível identificar a técnica utilizada no modelo proposto?

Resposta: Sim ou Não

Justificativa: Identificar a técnica utilizada é essencial para compreender a abordagem metodológica do estudo e avaliar sua aplicabilidade e inovação. Sem essa informação, não é possível validar a eficácia do modelo ou compará-lo adequadamente com outras técnicas.

- A técnica utilizada para avaliar o modelo é bem descrita e replicável?

Resposta: Sim ou Não

Justificativa: A utilização de técnicas de avaliação como *baseline*, é crucial para medir o desempenho do modelo proposto em relação a soluções existentes. Isso proporciona um contexto para avaliar melhorias e inovações, garantindo que o novo modelo oferece benefícios claros em relação a abordagens anteriores.




Figura 4.6: Quantitativo de artigos por bases.

4.3 Execução da Seleção dos Estudos

A seleção dos estudos foi dividida em duas etapas: a primeira etapa consiste na seleção a partir da leitura crítica dos títulos, resumos e palavras-chave. Na segunda contém a seleção a partir da leitura completa e aplicação de critérios de qualidade. Para auxiliar nestas etapas foi utilizado a ferramenta *Parsifal* para fazer a importação dos artigos, classificá-los e avaliar a sua qualidade.

A pesquisa inicial nas bases de dados ACM Digital Library, IEEE Xplore, ScienceDirect e Scopus, resultou em um total de 1.217 (um mil duzentos e dezessete) artigos, publicados em qualquer tempo, entre os anos de 1979 até junho de 2024. A Figura 4.6 apresenta o quantitativo de artigo encontrados por cada base, extraído da ferramenta *Parsifal*, a ScienceDirect com 64 artigos que equivalem a 5,3%; ACM Digital Library com 141 artigos que equivale a 11,6%; IEEE Digital Library com 234 artigos que equivale a 19,2%; e a Scopus com 778 artigos que equivalem a 63,9%.

Na primeira etapa, o *Parsifal* foi utilizado também na importação dos artigos encontrados por base pesquisada, na seleção de artigos como aceitos ou rejeitados, conforme critérios de exclusão e inclusão previamente definidos (Seções 4.2.1 e 4.2.2).

Destes, foram excluídos 401 (quatrocentos e um) artigos duplicados. Nos demais critérios de exclusão, 72 (setenta e dois) capítulos de livros ou editoriais, 21 (vinte e um) relatórios de workshop, 26 (vinte e seis) artigos que não estavam publicados em inglês, 6 (seis) artigos fora do período especificado, 66 (sessenta e seis) artigos resumidos com até 6 (seis) páginas, 246 (duzentos e quarenta e seis) artigos inacessíveis ou indisponível para download, 11 (onze) artigos do tipo *Survey*, 10 (dez) estudos secundários ou terciários, 5 (cinco) artigos da literatura cinza e 53 (cinquenta e três) artigos que não contemplam a abordagem teórica requerida. Finalmente, 300 (trezentos) artigos atenderam a todos os critérios de exclusão da primeira etapa e foram incluídos na segunda etapa de seleção.




Figura 4.7: Quantitativo de artigos.

Na segunda etapa, que compreende a leitura completa dos 300 (trezentos) trabalhos selecionados após a primeira fase de seleção, o *Parsifal* foi utilizado para auxiliar em responder às questões que assegurem a qualidade dos estudos. Na ferramenta é estabelecido uma pontuação para cada questão, se atender positivamente às questões estabelecidas obtém-se a pontuação 1 (um) caso contrário a pontuação obtida é 0 (zero). Em que o score deve ser igual a 3 para atingir o critério de qualidade.

Inicialmente após consulta do Qualis⁵, dos 300 (trezentos) artigos, foram excluídos (Seção 4.2.3) 58 (cinquenta e oito) classificados com Qualis B, 3 (três) com Qualis C e 37 (trinta sete) não classificados. Estes artigos excluídos obtiveram pontuação igual a 2 (dois). Permanecendo 202 (duzentos e dois) artigos com pontuação igual a 3 (três)

Após uma leitura superficial, mas completa, dos 202 (duzentos e dois) artigos, foram excluídos (Seção 4.2.3) 3 (três) por não por não identificarem a técnica aplicada no modelo, Estes artigos obtiveram pontuação igual a 2 (dois). Totalizando um quantitativo de 101 artigos reprovados pelos critérios de qualidade estabelecidos.

Finalmente, 199 (cento e noventa e nove) estudos atenderam a todos os critérios de inclusão e exclusão e foram incluídos na fase de extração dos dados. A Figura 4.7 apresenta de forma resumida o resultado quantitativo das buscas, classificação e avaliação dos artigos, total de artigos encontrados 1217 (um mil duzentos e dezessete), a classificação dos estudos foram 401 (quatrocentos e um) duplicados, 300 (trezentos) aceitos e 516 (quinhentos e dezesseis) excluídos. Com relação aos critérios de qualidade, dos 300 (trezentos) artigos aceitos, 199 (cento e noventa e nove) foram aprovados e 101 (cento e um) reprovados. Estes 199 (cento e noventa e nove) estudos aprovados forneceram dados relevantes para responder às questões de pesquisa propostas.

⁵Sistema de avaliação de periódicos científicos no Brasil, desenvolvido e mantido pela Coordenação de Aperfeiçoamento de Pessoal de Nível Superior (CAPES), vinculada ao Ministério da Educação (MEC).

4.4 Extração de Dados

Nesta etapa realizou-se a leitura integral dos 199 (cento e noventa e nove) artigos. Essa leitura dos artigos foi realizada por um único pesquisador ao longo de um período de seis meses. Cada artigo foi lido no mínimo duas vezes, seguindo um protocolo sistemático. Na primeira leitura, foram priorizadas as seções de introdução, metodologia e experimentos, com o objetivo de identificar indícios de respostas às perguntas de pesquisa previamente definidas. Em uma segunda leitura, mais aprofundada e integral, buscou-se confirmar a presença e a veracidade dessas respostas, garantindo a consistência das informações extraídas. Além disso, em alguns casos, foi realizada uma leitura direcionada por meio da busca de palavras-chave específicas. Por exemplo, a palavra “distância” ou termos correlatos, foram utilizadas com o intuito de localizar explicitamente informações que respondessem à questão de pesquisa: Como a distância é calculada no experimento?

Para a extração dos dados de cada artigo lido e analisado, foi utilizado o *Parsifal* a partir de um formulário previamente definido. Este formulário incluiu categorias como ID, título do trabalho, revisor responsável, data da extração e, crucialmente, as respostas para cada Questão Primária de pesquisa (QP) e possíveis Questões Secundárias de pesquisa (QS). Para algumas QPs, foi necessário estabelecer Qs específicas que contribuem com aspectos mapeáveis sobre cada questão.

Ao final da extração, e preenchimento completo desse formulário, os dados foram exportados em uma planilha ⁶ que continha os dados extraídos devidamente tabulados.

4.5 Avaliação do Mapeamento Sistemático de Literatura

A avaliação da qualidade deste Mapeamento Sistemático foi realizada pelo professor orientador de forma contínua em cada etapa proposta. Isso incluiu a Estratégia de Busca, a Seleção dos Estudos, a Extração dos Dados e a Análise dos Resultados.

A definição dos objetivos e das questões de pesquisa mostrou-se eficaz e reproduzível, resultando em uma análise satisfatória. A aplicabilidade das questões foi confirmada pelas respostas obtidas e pelas análises apresentadas. Os objetivos foram alcançados, especialmente considerando que todas as questões de pesquisa foram respondidas.

Para o objetivo proposto de “Investigar as técnicas utilizadas em Sistemas de Recomendação que são empregadas nesses sistemas que utilizam dados espaciais”, nesses sistemas, a resposta apresentou uma lista detalhada dessas técnicas, conforme descrito na Seção 5.1. Quanto ao objetivo de “Investigar os métodos e ferramentas

⁶https://docs.google.com/spreadsheets/d/1Lq-h0yD5c2bAg1NAYBz19oXJMvS-tlr_RPjm30kvznE/edit?usp=sharing

utilizados na extração e mapeamento de dados espaciais relevantes para esses sistemas e sua influência no processo de recomendação”, a resposta foi detalhada na Seção 5.2. Já para o objetivo proposto “Investigar como as técnicas identificadas são avaliadas, a exemplo: qualitativa, quantitativa ou estudo controlado”, a resposta foi detalhada na Seção 5.3.

Os critérios de inclusão e exclusão adotados nesta pesquisa contribuíram para garantir a qualidade e a relevância dos estudos selecionados. Após a análise dos resultados, a avaliação é positiva, pois foi possível apresentar dados quantitativos que oferecem panoramas relevantes, atendem aos objetivos propostos e respondem às questões de pesquisa.

Quanto à análise dos dados, foi possível realizar uma avaliação sistemática e apresentar os resultados de forma clara e objetiva. Isso assegura que as contribuições para a área são consistentes e bem fundamentadas.

Capítulo 5

Resultados e Discussões

Esta seção apresenta os resultados e discussões obtidos a partir dos dados extraídos, com uma análise detalhada das tendências e padrões identificados. Busca-se responder às questões de pesquisa, organizadas em três subseções: a Seção 5.1 contém uma análise dos resultados obtidos, visando responder a Questão de Pesquisa Primária 1 (QP1), que aborda as principais técnicas utilizadas em Sistemas de Recomendação com dados espaciais; a Seção 5.2 contém uma análise dos resultados obtidos, visando responder a Questão de Pesquisa Primária 2 (QP2), que discute os processos de extração e mapeamento desses dados; e a Seção 5.3 contém uma análise dos resultados obtidos, visando responder a Questão de Pesquisa Primária 3 (QP3), que apresenta as formas de avaliação das técnicas identificadas.

5.1 Questão de Pesquisa Primária 1

As técnicas identificadas em Sistemas de Recomendação que utilizam dados espaciais são diversas e abrangem uma variedade de abordagens, incluindo Aprendizado de Máquina, técnicas tradicionais como Filtragem Colaborativa, métodos Híbridos que combinam aspectos de colaboração e conteúdo e também o Aprendizado de Máquina com outras técnicas, como a Filtragem Colaborativa e Grafos, além de diversas técnicas, inclusive de Inteligência Artificial (IA).


A Tabela 5.1 contém as principais técnicas (Seção 2.2.1) e suas respectivas abreviações. O objetivo dessa tabela é listar todas as técnicas e suas abreviaturas, facilitando a leitura do texto. A primeira coluna contém as técnicas, enquanto a segunda coluna é composta por suas abreviações, por exemplo, “Filtragem Colaborativa” usa a abreviação FC.

A Figura 5.1a apresenta uma visão quantitativa das técnicas de recomendação identificadas, agrupadas por abordagem. A técnica com o maior número de citações é Filtragem Colaborativa (FC), tendo sido mencionada 65 (sessenta e cinco) vezes, seguido pelo Aprendizado de Máquina (AM) com 52 (cinquenta e duas) menções. A técnica menos citada foi a Baseada em Casos (BSC), com apenas 1 citação.

Tabela 5.1: Técnicas identificadas e suas 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

Ocorrência das Técnicas Identificadas



(a) Ocorrências por técnica identificada.

Percentual das Técnicas Identificadas



(b) Percentual das técnicas identificadas.

Figura 5.1: Comparação entre número de ocorrências e percentual das técnicas identificadas.

A Figura 5.1b mostra a distribuição percentual das principais técnicas utilizadas em Sistemas de Recomendação, destacando que a FC possui 32,7%, seguida pelo AM com 26,1%, OTMM com 12,1%, técnicas H com 10,1%, EGE 8,5% e outras abordagens somam 10,6%. A predominância da FC é evidente devido sua simplicidade e eficácia em diversas aplicações e também por ser uma técnica pioneira em Sistemas de Recomendação. O AM também se faz presente. A presença de outras técnicas, mesmo em menor número, indica uma diversidade de abordagens exploradas para melhorar os sistemas de recomendação.

As Figuras 5.1a e 5.1b ilustra as técnicas utilizadas em Sistemas de Recomendação que utilizam dados espaciais. O destaque das técnicas mais utilizadas, como FC e AM, demonstram que métodos colaborativos e baseados em aprendizado de máquina são centrais em sistemas que integram dados espaciais.

O mapeamento entre as técnicas identificadas e os respectivos identificadores (IDs) dos artigos que as mencionam está disponível na Tabela B.1 do Apêndice B. Adicionalmente, a Tabela B.2, também do Apêndice B, apresenta os agrupamentos das técnicas e detalhes sobre cada um deles, ambas organizadas em ordem decrescente pelo número de identificadores.

A Figura 5.2 contém a distribuição das técnicas agrupadas por ano. Cada cor




Figura 5.2: Distribuição das técnicas ao longo dos anos.

representa uma técnica, EGE (laranja), H (roxo), OTMM (verde), AM (vermelho) e FC (azul). A análise dos 199 (cento e noventa e nove) artigos, distribuídos entre os anos de 2003 a junho de 2024, ilustra como as técnicas utilizadas em Sistemas de Recomendação foram mencionadas ao longo desse período de aproximadamente 20 anos.

Entre 2003 e 2011, observa-se uma baixa presença de técnicas identificadas, com a predominância da categoria FC em pequenos valores isolados. A partir de 2012, há um crescimento gradual, marcado pela diversificação das categorias, com a introdução de AM, enquanto a FC continua a desempenhar um papel relevante. Esse crescimento se torna mais expressivo entre 2015 e 2020, especialmente nas categorias FC e AM.

O ano de 2020 foi o ponto alto desse período de aproximadamente 20 anos, com uma representação significativa de múltiplas categorias. Enquanto EGE e H também começam a ganhar destaque a partir de 2019. Nos anos mais recentes, entre 2021 e 2024, nota-se um declínio no número de menções das técnicas FC, AM, OTMM, H e EGE em 2021, seguido por uma leve recuperação. O declínio é justificado em 2024 pois foram considerados apenas os 6 primeiros meses do ano. Nesse período, a categoria H mostra crescimento contínuo, especialmente em 2023 e 2024, enquanto AM e FC permanecem relevantes.

A partir da análise da Figura 5.2 é possível identificar uma correlação entre avanços

tecnológicos e o aumento do interesse por Sistemas de Recomendação, especialmente aqueles que utilizam dados espaciais. Entre 2003 e 2011, a baixa presença de técnicas reflete um período inicial em que a personalização de recomendações ainda era incipiente. O crescimento gradual a partir de 2012 coincide com o surgimento e a popularização de *apps* baseados em localização, como *Uber* (lançado em 2010)¹ e *i-Food* (lançado em 2011)². Esses serviços trouxeram forte demanda por Sistemas de Recomendação baseados em localização.

Entre 2015 e 2020, o aumento exponencial do uso de técnicas avançadas está alinhado à consolidação de tecnologias de Big Data, Inteligência Artificial e ao crescimento de plataformas. *Apps* como *Airbnb*³ e *Google Maps*⁴, que utilizam fortemente dados espaciais, tornaram-se populares nesse período, ampliando a necessidade de modelos preditivos e recomendações personalizadas. Assim, o aumento no uso de FC e AM está diretamente relacionado à transformação digital e ao crescimento do mercado de serviços baseados em localização.

A análise revela o domínio da categoria FC, que predomina na maior parte do período analisado, refletindo sua relevância ao longo dos anos. Paralelamente, a categoria AM experimentou um crescimento significativo entre 2016 e 2020, indicando uma adoção crescente antes de se estabilizar. Um marco importante foi a variedade de técnicas observadas em 2019 e 2020, sugerindo maior experimentação e avanços em diferentes áreas. Nos últimos anos, destaca-se o crescimento consistente da categoria H, que desponta como uma das mais promissoras, especialmente entre 2023 e 2024. Com a presença de modelos híbridos de Aprendizado de Máquina com Estruturas Gráficas ou Espaciais (Grafos).

Nesta seção foram apresentadas as técnicas identificadas em Sistemas de Recomendação que utilizam dados espaciais, totalizando 59 (cinquenta e nove) abordagens distintas, alcançando o objetivo 1a. Observa-se a presença contínua de técnicas tradicionais, como a Filtragem Colaborativa (FC), ao longo do período analisado, evidenciando sua robustez e ampla aplicabilidade. Paralelamente, novas abordagens vêm se consolidando, acompanhando tendências atuais, como algoritmos para análise de grandes volumes de dados e técnicas baseadas em Inteligência Artificial (IA), que ampliam a capacidade de capturar padrões complexos. Métodos híbridos também se destacam, ao combinar diferentes estratégias para superar limitações individuais e aumentar a eficácia das recomendações.

¹<https://www.uber.com/pt-BR/newsroom/fatos-e-dados-sobre-uber/>

²<https://institucional.ifood.com.br/sobre/>

³<https://news.airbnb.com/br/o-surgimento-de-um-novo-padroao-de-pertencimento-com-a-nossa-maior-noite/>

⁴<https://www.clubedecriacao.com.br/ultimas/google-maps-15-anos/>




Figura 5.3: Fonte dos dados.

5.2 Questão de Pesquisa Primária 2

Esta seção aborda a Questão de Pesquisa Primária 2 (QP2): Como são extraídos e mapeados os dados espaciais para alimentar os Sistemas de Recomendação? e as seguintes Questões de Pesquisa Secundárias

(QS), que permitem responder a (QP2), (QS2.1) Qual a origem desses dados? (QS2.2) Quais dados espaciais são extraídos? (QS2.3) O que é recomendado? (QS2.4) Tipo de Dado Espacial Recomendado? (QS2.5) Dados espaciais são recomendados? (QS2.6) Como é calculada a distância nestes artigos? (QS2.7) Qual técnica é utilizada para melhorar os sistemas de recomendação?

QS2.1 Qual a origem desses dados?

Os dados mencionados pelos artigos identificados nesta pesquisa foram coletados de diversas fontes, por exemplo: Aplicativos e Ferramentas de Coleta de Dados como o Talking Data e o LearNex, Dados de Mapeamento ou Localização Geográfica como o Global Positioning System (GPS), Dataset de Serviços Web como WS-Dream, Plataforma de Avaliação de Restaurantes ou Turismo como o Yelp e TripAdvisor, Plataforma de Recomendação de Filmes como o MovieLens e Redes Sociais Baseadas em Localização como o Foursquare e Gowalla. É importante destacar que alguns artigos recorreram a mais de uma fonte de dados.

A Figura 5.3 apresenta o quantitativo da fonte dos dados. A maior parte dos dados, 51,3%, provém de Redes Sociais Baseadas em Localização (BrightKite, Foursquare, Gowalla), esses dados refletem a centralidade dessas plataformas na coleta de dados espaciais, refletindo a crescente interação dos usuários com serviços e locais específicos, o que fornece uma visão rica sobre comportamentos e preferências geoespaciais. A predominância dessas fontes pode ser explicada pela popularização de aplicativos que incentivam a geolocalização e pelo volume de dados gerados nessas plataformas.

Outras fontes representam 48,7% dos dados, fontes como: Plataforma de Avaliação

de Restaurantes ou Turismo 12,9%, Aplicativos e Ferramentas de Coleta de Dados 5,2%, Dataset de Serviços Web 4,7%, Dados de Mapeamento 4,3%, Dados de Tráfego ou Mobilidade Urbana e Plataforma de Recomendação de Filmes 3,4% cada, Demais Fontes 14,7%. A diversidade dessas fontes sugere uma ampliação do uso de *datasets*, buscando não apenas a interação direta dos usuários, mas também informações sobre ambientes urbanos, preferências de entretenimento e rotas de mobilidade.

A partir da análise desses dados também pode-se observar que muitos desses *datasets* são oriundos de redes sociais, mesmo quando essas já não estão mais ativas ou tiveram suas funções alteradas, como é o caso do Gowalla, Brightkite e da antiga versão do Foursquare. Apesar da descontinuação dessas plataformas, os dados coletados continuam sendo utilizados em pesquisas voltadas à experimentação em Sistemas de Recomendação que utilizam dados espaciais.

A Figura 5.3 ilustra a popularização das redes sociais como principal fonte de dados espaciais, isso reflete na crescente interdependência entre essas plataformas e os Sistemas de Recomendação. As redes sociais dependem de algoritmos de recomendação para personalizar conteúdos, maximizar engajamento e manter os usuários ativos, enquanto os Sistemas de Recomendação, por sua vez, utilizam dados espaciais coletados dessas plataformas para oferecer sugestões mais precisas e contextuais, como recomendações de locais, eventos e serviços.

O mapeamento entre as fontes dos dados espaciais utilizadas nos experimentos, os identificadores dos artigos correspondentes e o quantitativo de artigos que utilizaram cada fonte está organizado em ordem decrescente pelo quantitativo de artigos na Tabela B.3 do Apêndice B.

QS2.2 Quais dados espaciais são extraídos?

Os dados espaciais extraídos incluem uma ampla variedade de informações, como a localização do usuário, o histórico de localizações, os locais visitados, a localização de fotos capturadas e a localização de estabelecimentos, como lojas, empresas, hotéis, farmácias e imóveis. Além disso, englobam a localização de eventos, de serviços, de sinais digitais, de táxis ou veículos, localização de amigos, pontos de interesse, regiões geográficas, rotas de estradas e ferrovias, bem como trajetórias de táxis e trajetórias dos usuários.

A Figura 5.4 apresenta a distribuição desses dados. A “Localização do usuário” está presente em 75,4% dos artigos analisados, enquanto os demais dados representam 24,6%. Dentre esses, a “Localização de estabelecimento” (lojas, empresas, hotéis, restaurantes, etc) está presente em 7,9% dos artigos analisados, “Trajetórias dos usuários” aparecem com 4,8% dos artigos, seguidos pela “Localização de serviços” (servidores de dados) com 3,5%. Os dados restantes correspondem a 8,4% do total.

Esses resultados sugerem que a preferência pelo uso da localização do usuário pode estar relacionada à facilidade de obtenção desses dados, especialmente em dispositivos móveis com geolocalização integrada. Contudo, a menor representatividade


Dados Espaciais Extraídos

Figura 5.4: Percentual dos dados espaciais extraídos.

de outras categorias indica possíveis desafios relacionados à coleta e integração de informações espaciais mais complexas.

A Figura 5.4 contém o percentual dos dados espaciais extraídos. A localização do usuário corresponde à maior parcela dos dados espaciais extraídos (72,8%), evidenciando a centralidade desse dado para sistemas baseados em geolocalização. Esse fenômeno está diretamente relacionado à coleta de informações em redes sociais, que utilizam a localização dos usuários para personalizar anúncios, sugerir conexões, recomendar locais e otimizar algoritmos de engajamento.

O mapeamento entre os dados espaciais extraídos, os identificadores e o quantitativo de artigos que utilizaram esses dados espaciais, está organizado em ordem decrescente pelo quantitativo de artigos na Tabela B.4 do Apêndice B.

A Figura 5.5 apresenta uma amostra detalhada dos diferentes tipos de dados espaciais extraídos, categorizando-os de acordo com suas características espaciais, como ponto, linha ou região, conforme Seção (2.1). A maioria dos artigos analisados, 192 (cento e noventa e dois) dos 199 (cento e noventa e nove) artigos, utilizam dados do tipo ponto, enquanto (quatorze) refere-se a Linha, e apenas 1 (uma) menção para região. Isso indica que os Sistemas de Recomendação frequentemente utilizam dados de latitude e longitude, que representam localizações específicas.

Esses dados podem incluir localização em tempo real do usuário, restaurantes, lojas, pontos turísticos ou outros pontos de interesse, representados por coordenadas de latitude e longitude. A predominância dos dados do tipo ponto sugere que o foco principal dos Sistemas de Recomendação que utilizam dados espaciais é oferecer sugestões baseadas em locais precisos (latitude, longitude) onde os usuários podem desejar visitar ou utilizar serviços.

QS2.3 O que é recomendado?



Figura 5.5: Característica espacial dos dados extraídos.

Os Sistemas de Recomendação que utilizam dados espaciais abrangem uma ampla diversidade de itens recomendados. A Figura 5.6 contém a distribuição dos dados recomendados. Dentre as categorias mais frequentes, destaca-se o “Ponto de Interesse” com 141 (cento e quarenta e uma) ocorrências, refletindo na demanda de recomendação de dados espaciais. Outras categorias de destaque incluem “Serviço” 17 (dezesete), “Item” 13 (treze), “Amigos” 7 (sete) e “Música” com 4 (quatro) ocorrências, evidenciando a variedade de elementos contextuais e funcionais que compõem essas recomendações. Além disso, há também recomendações menos frequentes, como “Cliente”, “Notícias” e “Rota”, que possuem apenas uma ou duas ocorrências cada, totalizando 19 (dezenove) menções.

Foram agrupados na categoria “Ponto de Interesse” os dados extraídos dos artigos com características semelhantes, conforme representado na Figura 5.6. Essa categoria inclui os seguintes dados: Grupo de Ponto de Interesse, Ponto para Instalar Restaurante, Local para Grupo, Local Turístico, Próximo Local, Local de Viagem, Localização, Localização de Loja, Local, Local de Coleta de Carona, Localização de Hotel, Localização de Instalações, Localização de Restaurante, Localização Personalizada, Local Candidato, Localização de Empresas, Localização de Estação de Monitoramento de Qualidade do Ar, Localização de Instalação de Sinal Digital, Localização de um Ponto de Negócio e Localização em Redes de Transporte Dinâmica.

A análise da Figura 5.6 revela que 70% do que é recomendado identificado nos artigos analisados é composto por “Pontos de Interesse”, destacando-se como o principal foco dos Sistemas de Recomendação baseados em dados espaciais. Isso indica que esses sistemas priorizam sugestões de locais específicos, como restaurantes, pontos turísticos e estabelecimentos comerciais, para atender às necessidades dos usuários.

Além disso, a Figura 5.6 também evidencia a presença de recomendações de dados não espaciais, como “Serviço”, como por exemplo, serviços de previsão do tempo, com 17 (dezesete) ocorrências e “Item”, como produtos de um *e-commerce*, com




O que é Recomendado

Figura 5.6: Dados recomendados.

Tipo de Dado Recomendado

(a) Tipo de dado recomendado.

Recomenda Dados Espaciais

(b) Recomenda dados espaciais.

Figura 5.7: Dados recomendados.

13 (treze) ocorrências. Embora menos frequentes, a recomendação de elementos não espaciais desempenham um papel relevante nos Sistemas de Recomendação que utilizam dados espaciais, contribuindo para o aprimoramento das sugestões oferecidas aos usuários.

O mapeamento entre o que é recomendado, os identificadores dos artigos que recomenda tais categorias e o quantitativo dos artigos está organizado em ordem decrescente pelo quantitativo identificado na Tabela B.5.

QS2.4 Tipo de Dado Espacial Recomendado?

A Figura 5.7a apresenta o quantitativo da característica do dado recomendado nos artigos analisados. Pontos ou localizações destacam-se, sendo mencionados em 141 (cento e quarenta e um) dos 199 (cento e noventa e nove) artigos analisados, enquanto 3 (três) artigos fazem referência a linhas (rotas ou trajetórias) e nenhuma menção para região (área). Essa predominância de pontos ou localizações, representando

70% dos trabalhos indica uma forte tendência dos usuários à utilização de Sistemas de Recomendação que recomendam um ponto de interesse.

A análise da Figura 5.7a, em conjunto com os dados apresentados na Figura 5.6, ilustra o que é recomendado pelos Sistemas de Recomendação. Os dados espaciais do tipo ponto são amplamente utilizados em diversos Sistemas de Recomendação que utilizam dados espaciais, sendo adaptados a distintos contextos para fornecer recomendações específicas de localização.

QS2.5 Dados espaciais são recomendados?

Nos artigos analisados, a maioria dos trabalhos revela que os sistemas de recomendação que incorporam dados espaciais efetivamente os utilizam para fornecer recomendações de dados espaciais. A Figura 5.7b apresenta que 73% dos trabalhos analisados mostram que os sistemas de recomendação, de fato, recomendam dados espaciais. Em contraste, apenas 27% dos trabalhos indicam que esses sistemas não recomendam dados espaciais.

A partir da análise da Figura 5.7b é possível identificar que, os Sistemas de Recomendação que utilizam dados espaciais têm como objetivo principal recomendar informações baseadas em localização. Isso significa que esses sistemas são projetados para recomendar pontos de interesse, trajetos, ou outras informações geograficamente relevantes, porém também podem utilizar esses dados espaciais para melhorar a precisão e a utilidade das diversas recomendações fornecidas aos usuários.

QS2.6 Como é calculada a distância nestes artigos?

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. No entanto, em 34 (trinta e quatro) artigos não foi possível identificar a abordagem utilizada para calcular a distância.

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

Já o segundo grupo engloba abordagens que não medem diretamente a distância entre objetos espaciais, mas utilizam outros critérios para avaliar similaridade ou proximidade. Métodos como a Distância de Jaccard, a Distância de Hamming operam com dados categóricos, estatísticos ou textuais, sendo úteis em cenários onde a recomendação se baseia em atributos dos itens recomendados, como preferências dos usuários e características dos produtos.

A Figura 5.8 apresenta as abordagens utilizadas para calcular distâncias espaciais em Sistemas de Recomendação. A Distância Euclidiana é a mais empregada, sendo mencionada em 43 (quarenta e três) artigos. Em seguida, o Caminho Mais Curto




Figura 5.8: Abordagens de cálculo de distância por métricas espaciais.




Figura 5.9: Abordagens de cálculo de distância por métricas não espaciais.

aparece em 19 (dezenove) artigos, seguido pela Distância de Haversine, com 12 (doze) ocorrências. O Método Gaussiano Multicêntrico foi identificado em 6 (seis), enquanto outras abordagens menos recorrentes (Equação Própria do Estudo, Matriz de Proximidade Geográfica, Cálculo do Centróides, Distância de Manhattan Distância de Vincenty e Distância Ortodrômica) somam 7 (sete) ocorrências, categorizadas como Demais Abordagens.

A predominância da Distância Euclidiana, mencionada em 43 (quarenta e três) artigos, indica que este é um método 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, com 19 (dezenove) menções e a Distância de Haversine com 12 (doze) menções se destacam por sua aplicabilidade em trajetos reais. A Distância de Haversine, por exemplo, é amplamente utilizada para calcular distâncias entre coordenadas geográficas expressas em latitude e longitude, tornando-se essencial para aplicações em mobilidade urbana.

A Figura 5.9 contém as abordagens utilizadas para calcular distâncias não espaciais

em Sistemas de Recomendação, por exemplo, quando um *app* sugere um restaurante que um amigo visitou, não com base na localização geográfica, mas sim em preferências compartilhadas. Por Similaridade é a mais recorrente, sendo empregada em 58 (cinquenta e oito) estudos. A Distância de Jaccard aparece em 7 (sete) artigos, enquanto a abordagem Por Classificação do Usuário é mencionada em 5 (cinco) 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 (onze) ocorrências.

O predomínio da abordagem Por Similaridade com 58 (cinquenta e oito) menções destaca a importância da comparação de atributos, como preferências e comportamentos dos usuários, na formulação de recomendações. Isso está diretamente relacionado ao uso de redes sociais, onde a similaridade entre usuários, locais visitados e interações registradas é um fator crucial para a personalização das sugestões. Por exemplo, algoritmos de recomendação, como os empregados pelo Facebook, Instagram e Google Maps, utilizam esses cálculos para sugerir locais, amigos e serviços com base em padrões de comportamento semelhantes.

O mapeamento entre contém as abordagens empregadas para calcular a distância, os identificadores dos artigos que empregaram essas técnicas e o quantitativo das técnicas empregadas está ordenado em ordem decrescente pelo quantitativo identificado nas Tabelas B.6 e B.7 do Apêndice B.

QS2.7 Qual técnica é utilizada para melhorar os sistemas de recomendação?

As técnicas identificadas para melhorar os sistemas de recomendação são variadas e refletem a complexidade e a inovação nesse campo. Essas técnicas foram classificadas com base na forma como os dados espaciais são organizados e processados nos experimentos, considerando sua contribuição para a melhoria das recomendações. Assim, foram agrupadas em duas categorias principais: abordagens baseadas na interpretação de dados, que destacam o uso do contexto e da análise semântica, e abordagens baseadas em aprendizado de máquina e modelagem avançada, que incluem métodos computacionais mais robustos, como aprendizado profundo e aprendizado de métricas.

A Figura 5.10 contém as abordagens mais frequentemente mencionadas entre as baseadas na interpretação de dados. A “Informação de Contexto” lidera com 8 (oito) ocorrências. Em seguida, destaca-se a “Agregação Temporal”, mencionada 6 (seis) vezes, enquanto as abordagens “Preferência do Usuário” e “Informação Multi-contexto” obtiveram 5 (cinco) menções cada. As demais abordagens apresentaram menor frequência, com 1 (uma) ou 2 (duas) menções cada. Essa baixa frequência das demais abordagens pode indicar áreas ainda pouco exploradas.

A análise dos dados apresentados na Figura 5.10 ilustra que a “Informação de Contexto” é a abordagem mais mencionada na interpretação de dados, com 8 (oito)




Figura 5.10: Abordagens baseadas na interpretação de dados.




Figura 5.11: Abordagens baseadas em aprendizado de máquina e modelagem avançada.

ocorrências, refletindo sua importância no aprimoramento das recomendações. Esse destaque é especialmente relevante em redes sociais e plataformas de avaliação de serviços, onde fatores situacionais, como localização, horário e histórico de interações, influenciam diretamente a experiência do usuário. A “Agregação Temporal”, presente em 6 (seis) artigos, reforça essa tendência ao considerar a variação das preferências ao longo do tempo, sendo amplamente empregada em serviços como *delivery*, turismo e eventos.

Outras abordagens, como “Preferência do Usuário” e “Informação Multi-contexto”, foram mencionadas 5 (cinco) vezes cada, indicando a crescente integração de múltiplas fontes de dados para aprimorar a precisão das sugestões. Em contrapartida, abordagens com menor frequência, registrando apenas uma ou duas menções, sugerem áreas ainda pouco exploradas.

A Figura 5.11 contém as abordagens mais frequentemente citadas entre as baseadas em aprendizado de máquina e modelagem avançada. A “Fatoração de Matriz” lidera

com 16 (dezesseis) ocorrências. Em seguida, a “Mineração de Dados”, com 9 (nove) ocorrências, e as abordagens “Clusters” e “Grafos”, ambas com 8 (oito) menções. A “Filtragem Colaborativa” foi mencionada 6 (seis) vezes, enquanto o “Aprendizado de Máquina” teve 5 (cinco) menções. Já as abordagens “Algoritmo Heurístico” e “Estimativa de Densidade de Kernel” foram mencionadas 4 (quatro) vezes cada. As demais abordagens registraram entre 1 (uma) e 3 (três) menções cada.

A análise dos dados apresentados na Figura 5.11 ilustra que a “Fatoração de Matriz” é a abordagem mais citada, com 16 (dezesseis) ocorrências, destacando sua relevância na modelagem de sistemas de recomendação baseados em Filtragem Colaborativa. Essa técnica é amplamente empregada para decompor grandes conjuntos de dados em fatores latentes, permitindo prever preferências de usuários com base em interações passadas. A “Mineração de Dados”, com 9 (nove) menções, complementa essa estratégia ao identificar correlações entre variáveis, explorando grandes volumes de dados para aprimorar a precisão das sugestões.

Um ponto relevante é que essas técnicas não substituem as técnicas principais já empregadas, como Filtragem Colaborativa ou Algoritmos Baseados em Conteúdo, mas são integradas de forma complementar. Isso ocorre para tratar particularidades dos dados espaciais, como a modelagem de relacionamentos complexos entre usuários e localizações ou a identificação de padrões temporais.

O mapeamento entre as técnicas identificadas para melhorar os Sistemas de recomendação, os identificadores dos artigos que empregaram essas técnicas e o quantitativo das técnicas empregadas está ordenado em ordem decrescente pelo quantitativo identificado nas Tabelas B.8 e B.9 do Apêndice B.

Nesta seção, foi apresentado como os dados são extraídos e mapeados para alimentar os Sistemas de Recomendação, alcançando o objetivo 1b. Os dados provêm principalmente de redes sociais baseadas em localização, que fornecem informações cruciais sobre a localização do usuário e seus check-ins. A abordagem mais comum é a recomendação de dados de ponto, ou seja, locais específicos para os usuários, com base em suas interações e preferências anteriores. Para o tratamento desses dados espaciais, são aplicados cálculos de distância, como a similaridade entre usuários e a distância Euclidiana, que ajudam a identificar afinidades geográficas e preferências de proximidade. Além disso, as técnicas de agregação são frequentemente utilizadas para combinar diferentes abordagens, como a filtragem colaborativa e as baseadas em conteúdo, a fim de melhorar a precisão das recomendações espaciais e lidar de maneira mais eficaz com a diversidade de dados geoespaciais.

5.3 Questão de Pesquisa Primária 3

As técnicas identificadas são avaliadas por meio de diferentes abordagens experimentais, que incluem *Baseline*, Estudos de Casos, Simulações e Testes A/B. A Figura 5.12 contém a distribuição das abordagens utilizadas para avaliar os experimentos.



Figura 5.12: Avaliação dos experimentos.

O *Baseline* é a estratégia mais utilizada, sendo adotada em 163 (cento e sessenta e três) artigos, como referência para comparação de desempenho entre os métodos propostos e outros existentes. Simulações estão presentes em 21 (vinte e um) artigos, permitem testar os métodos em condições controladas, simulando ambientes complexos. Estudo de Caso, utilizados em 15 (quinze) trabalhos, são empregados para avaliar a aplicabilidade das técnicas em cenários reais ou específicos. Por fim, Testes A/B foram utilizados em apenas 1 (um) trabalho, caracterizando uma abordagem menos comum, embora eficaz para comparar diretamente as preferências dos usuários em contextos reais.

A predominância do uso do *Baseline* reflete a sua importância como ponto de comparação crucial para mensurar a eficácia das técnicas de recomendação, proporcionando uma referência clara em relação a métodos já estabelecidos. A alta incidência de Simulações indica a busca por um controle rigoroso sobre variáveis externas, permitindo que os pesquisadores validem suas técnicas em ambientes controlados antes de aplicá-las em contextos reais.

A Figura 5.12 ilustra a alta dependência de *Baselines* na avaliação das técnicas identificadas. Isso sugere que, durante o desenvolvimento de algoritmos, a validação inicial é feita comparando novas abordagens com modelos já estabelecidos. Isso é comum na pesquisa acadêmica e na área de banco de dados, onde algoritmos precisam superar métodos antecedentes a este antes de serem considerados viáveis.

Outrossim, com a popularização do Aprendizado de Máquina, há um movimento crescente para testar algoritmos em ambientes controlados antes da produção. Métodos de simulação, como Aprendizado por Reforço e ambientes de teste sintéticos, estão sendo cada vez mais utilizados, mas a adoção desses métodos pode ser considerada desafiadora devido ao alto custo computacional.

O mapeamento entre os métodos de avaliação aplicados às técnicas analisadas, os identificadores dos artigos que utilizaram cada método e o quantidade de artigos que

empregaram cada técnica está ordenado em ordem decrescente pelo quantitativo na Tabela B.10 do Apêndice B.

Nesta seção, foram apresentadas as diferentes abordagens experimentais utilizadas para avaliar as técnicas de recomendação, alcançando o objetivo 1c, com destaque para a predominância da estratégia *Baseline*, seguida pelas Simulações, Estudos de Caso e Testes A/B. O uso do *Baseline* como referência central para comparação de desempenho mostra sua relevância na avaliação das técnicas propostas.

Capítulo 6

Considerações Finais

Esta pesquisa teve como objetivo mapear o uso de dados espaciais no contexto dos Sistemas de Recomendação. Para isso, por meio de um Mapeamento Sistemático da Literatura, buscou-se oferecer uma compreensão abrangente sobre o tema, destacando **tendências**, **lacunas** e **oportunidades para futuras investigações**, além das limitações, ameaças à validade, lições aprendidas e trabalhos futuros.

Este trabalho foi conduzido de forma sistemática, seguindo rigorosamente as etapas previstas no processo de Mapeamento Sistemático da Literatura. Essa abordagem metodológica garantiu uma estrutura organizada e consistente, permitindo a coleta, análise e síntese de informações relevantes sobre o tema investigado. A adoção dessa sequência lógica teve como objetivo assegurar a reprodutibilidade e a confiabilidade dos resultados, além de possibilitar uma visão abrangente da literatura.

Considerando as diferenças entre Revisão Sistemática e Mapeamento Sistemático (Seção 2.5), este estudo se alinha às principais características do mapeamento. A começar pela **abordagem** abrangente e inclusiva, evidenciada pela análise de um número expressivo de artigos, 199 (cento e noventa e nove), ao longo de um período de aproximadamente 20 (vinte) anos. Destaca-se também a **estratégia de pesquisa**, respaldada pela definição e aplicação criteriosa de 17 (dezessete) critérios de inclusão e exclusão, incluindo avaliação de qualidade, com o objetivo de garantir que apenas estudos relevantes fossem considerados.

O **processo de busca** foi direcionado aos tópicos centrais da área de estudo, utilizando os termos “Sistemas de Recomendação” e “dados espaciais”, com o apoio da metodologia PICOC para elaborar as *strings* de busca. A etapa de **síntese dos resultados** também foi conduzida conforme os princípios do mapeamento sistemático: os dados extraídos foram organizados e apresentados por meio de representações gráficas, oferecendo uma visão quantitativa clara sobre o estado da arte.

Por fim, no que diz respeito à **aplicação** e **finalidade**, o mapeamento permitiu identificar padrões, tendências e lacunas na literatura investigada. A visualização gráfica dos dados categorizados contribuiu para evidenciar áreas ainda pouco exploradas,

como a técnica “Baseada em Contexto”. Com base nessa lacuna identificada, pode-se propor novas intervenções, como por exemplo, a modelagem de um Sistema de Recomendação que integre essa técnica a outras pouco exploradas.

6.1 Principais Contribuições

A pesquisa permitiu identificar que, nos artigos analisados, os Sistemas de Recomendação empregam diversas técnicas para aprimorar a qualidade das sugestões oferecidas. Destacam-se, entre as abordagens mais utilizadas, os algoritmos de Aprendizagem de Máquina, e os métodos tradicionais, como a Filtragem Colaborativa. Ademais, a análise das técnicas utilizadas em Sistemas de Recomendação ao longo de 20 (vinte) anos mostra a Filtragem Colaborativa como abordagem predominante, mostrando-se importante na área, seguida pelo crescimento do Aprendizado de Máquina entre 2016 e 2020.

Observa-se que os estudos sobre Sistemas de Recomendação, em sua maioria, concentram-se em técnicas consolidadas, como a Filtragem Colaborativa e, mais recentemente, os algoritmos de Aprendizado de Máquina, com foco na otimização e no aprimoramento desses métodos. Essa ênfase em abordagens já estabelecidas contribui para uma evolução gradual do campo, o que pode ser observado na ampla adoção, nos últimos anos, de modelos híbridos que combinam diferentes estratégias de recomendação.

Nesse cenário, identifica-se uma lacuna relevante relacionada à compreensão do comportamento das técnicas aplicadas ao longo do tempo em sistemas que integram dados espaciais. Ainda são incipientes os estudos que analisam de forma sistemática se a incorporação desses dados contribui efetivamente para a transformação do cenário técnico dos Sistemas de Recomendação ou se sua utilização apenas reforça as práticas já predominantes na área.

Observou-se também que a extração e o mapeamento de dados espaciais para alimentar os Sistemas de Recomendação envolvem um conjunto diversificado de métodos e ferramentas. O processo normalmente inicia-se com a coleta de informações geoespaciais, compostas por coordenadas de latitude e longitude. Essas informações são, em grande parte, extraídas de Redes Sociais Baseadas em Localização, que fornecem dados valiosos para enriquecer as recomendações com elementos contextuais baseados na posição geográfica dos usuários.

No entanto, uma questão relevante a ser considerada diz respeito à origem desses dados, especialmente nos experimentos que ainda utilizam conjuntos provenientes de redes sociais atualmente descontinuadas, como o Foursquare. Mesmo em estudos recentes, como os identificados pelos IDs 66 e 11 (Tabela B.3), publicados respectivamente em 2024 e 2023, observa-se a persistência no uso de datasets legados, o que pode comprometer a representatividade dos resultados. Essa prática mostra uma lacuna na área, relacionada à necessidade de explorar novas fontes de dados espaciais que refletem comportamentos mais contemporâneos dos usuários.

Esses dados são posteriormente processados e convertidos em formatos compatíveis com os interesses dos usuários, permitindo a geração de recomendações mais precisas e relevantes. Essa abordagem possibilita que as sugestões sejam alinhadas ao contexto geográfico dos usuários, tornando-as mais contextualizadas e personalizadas.

Outro ponto identificado é que, em muitos Sistemas de Recomendação que integram dados espaciais, as sugestões geradas estão diretamente relacionadas às localizações e pontos específicos. Essas recomendações podem incluir desde estabelecimentos comerciais, como restaurantes e lojas, até atrações turísticas, eventos locais e serviços próximos ao usuário. Essa abordagem é particularmente valiosa em cenários onde a proximidade geográfica é um fator determinante para a relevância das sugestões.

Foi identificado também que abordagens como “Por Similaridade” e a “Distância Euclidiana” se destacaram como as principais abordagens utilizadas para calcular a distância entre o usuário e o item recomendado, especialmente quando se trata de sistemas que envolvem uma localização específica. Nesse contexto, a localização desempenha um papel crucial na personalização das recomendações, ajustando-as não apenas com base no perfil e nas preferências do usuário, mas também considerando sua proximidade geográfica a locais de interesse relevantes.

Os resultados desta pesquisa também evidenciam a diversidade de técnicas utilizadas para aprimorar sistemas de recomendação, e que as técnicas podem ser classificadas em duas categorias principais: aquelas baseadas na interpretação de dados, como o uso de informação de contexto e agregação temporal, e aquelas fundamentadas em aprendizado de máquina e modelagem avançada, como Fatoração de Matriz e Mineração de Dados. A predominância da informação de contexto entre as abordagens interpretativas reforça a importância de variáveis contextuais na personalização de recomendações, enquanto a Fatoração de Matriz se destacou como a técnica mais citada na modelagem computacional, sendo utilizada junto com a Filtragem Colaborativa. Esses achados demonstram que a melhoria dos sistemas de recomendação não se limita a uma única abordagem, mas sim à integração de diferentes métodos.

Outra contribuição significativa foi a identificação do uso de *Baselines* como estratégia para avaliar a eficácia de Sistemas de Recomendação que incorporam dados espaciais. Esses *Baselines* atuam como pontos de referência, permitindo a comparação do desempenho dos algoritmos propostos com abordagens já consolidadas ou com métodos mais simples e amplamente utilizados. A utilização de *Baselines* não apenas possibilita mensurar ganhos de desempenho, mas também contribui para a validação da robustez e da relevância das novas soluções desenvolvidas. Contudo, identifica-se uma oportunidade de avanço nesse aspecto, especialmente no que se refere à definição de *Baselines* mais específicos para cenários que integram a utilização de dados espaciais.

Conclui-se que, nos últimos anos, houve um crescimento expressivo na adoção de modelos híbridos em Sistemas de Recomendação que utilizam dados espaciais, os quais combinam, por exemplo, técnicas de Aprendizado de Máquina com Estruturas Gráficas, a fim de lidar com a complexidade dos dados e melhorar a qualidade

das recomendações. Apesar desse avanço, ainda são pouco exploradas técnicas que integrem técnicas Baseadas em Casos ou Baseadas em Contexto com métodos de Inteligência Artificial, mesmo sendo estas técnicas fortemente orientadas ao uso de informações contextuais. Tal lacuna revela a necessidade de ampliar os estudos que investigam como diferentes estratégias de IA podem ser incorporadas a técnicas pioneiras de Sistemas de Recomendação.

Diante disso, propõe-se como contribuição final o desenvolvimento de um sistema híbrido de recomendação que integre dados espaciais em todas as etapas do processo, da coleta à entrega da sugestão, utilizando métricas tanto espaciais quanto não espaciais para calcular a distância entre o usuário e o item recomendado, e sendo avaliado a partir de *Baselines* especificamente desenhados para esse tipo de dado.

Essa proposta busca responder à demanda crescente por modelos mais contextuais e precisos, acompanhando a evolução observada na literatura ao longo dos anos, com marcos importantes no aumento do uso de IA em recomendações, especialmente a partir do ano de 2019, período em que se intensificaram pesquisas voltadas à personalização inteligente e ao uso de múltiplas fontes de dados.

6.2 Limitações

Uma limitação desta pesquisa é a exclusão de artigos secundários e terciários, focando apenas em artigos primários. Essa escolha restringiu a análise a estudos originais, sem considerar, por exemplo, revisões sistemáticas que poderiam oferecer uma visão mais ampla sobre as tendências e avanços nas técnicas de recomendação. A inclusão dessas fontes secundárias e terciárias poderiam fornecer um panorama mais abrangente, permitindo uma avaliação mais aprofundada das abordagens empregadas ao longo do tempo.

Outra limitação identificada desta pesquisa diz respeito ao escopo das questões de pesquisa. Inicialmente, foram formuladas quatro questões, mas, devido ao prazo reduzido, optou-se por manter apenas três, concentrando os esforços naquelas que melhor se alinhavam aos objetivos do estudo. Essa decisão pode ter impactado a abrangência da investigação, deixando de lado aspectos complementares que poderiam enriquecer a compreensão sobre a evolução das técnicas analisadas.

6.3 Ameaças à Validade

A ameaça à validade identificada neste Mapeamento Sistemático está relacionada ao fato de que as etapas de Realização e Reporte (Seções 3.2 e 3.3) foram conduzidas por um único pesquisador. Essa condição configura uma ameaça à validade da conclusão, pois pode haver viés na categorização e interpretação dos dados extraídos. Também representa uma ameaça à validade interna, uma vez que julgamentos subjetivos como a interpretação de trechos ambíguos, não passaram por validação interavaliadora.

Como estratégia de mitigação, foi adotado um processo sistemático de leitura dos artigos em duas etapas. Além disso, pontos com maior grau de subjetividade foram discutidos e avaliados com o orientador da pesquisa, buscando reduzir o viés individual e fortalecer a confiabilidade das decisões tomadas.

6.4 Lições Aprendidas

Uma das lições aprendidas foi a importância do uso de ferramentas especializadas, como o Parsifal, para facilitar a organização e análise dos dados. O *Parsifal*, ao automatizar a rastreabilidade dos artigos e processos de extração de dados, contribuiu na redução do trabalho manual e na complexidade envolvida nesse processo.

Outra lição aprendida foi a importância de utilizar a estrutura dos artigos como um guia para auxiliar na identificação e extração de dados. Ao compreender e seguir seções padronizadas dos estudos como: introdução, metodologia, resultados dos experimentos, tornou-se mais fácil localizar informações relevantes de forma sistemática. Essa abordagem não apenas otimizou o processo de extração, como também garantiu maior consistência e precisão na coleta dos dados.

6.5 Trabalhos Futuros

Como esta pesquisa apresenta um Mapeamento Sistemático da Literatura e aplica critérios rigorosos de inclusão e exclusão, a utilização da metodologia *Snowball* pode viabilizar a inclusão de novos estudos relevantes, possibilitando a obtenção de dados adicionais e, conseqüentemente, a geração de novos resultados. Essa estratégia expande o escopo da pesquisa ao explorar referências citadas nos artigos selecionados, aumentando a abrangência e a robustez do levantamento bibliográfico. Paralelamente, a realização de uma Revisão Sistemática da Literatura com o suporte de uma metanálise permitiria uma interpretação mais aprofundada e integrada dos resultados, promovendo uma análise qualitativa robusta e capaz de identificar tendências e padrões significativos na literatura estudada.

Adicionalmente, como trabalho futuro, sugere-se a investigação da questão de pesquisa que ficou em aberto: Quais os principais componentes identificados na arquitetura dos Sistemas de Recomendação que utilizam dados espaciais? A análise desses componentes pode proporcionar uma visão mais detalhada sobre as camadas e módulos que podem compor esses sistemas, permitindo compreender como os dados espaciais são processados e integrados às técnicas de recomendação.

Referências

- Acharya, M., Yadav, S., e Mohbey, K. K. (2023). 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*, páginas 100–161.
- Aggarwal, C. C. et al. (2016). *Recommender systems*. Springer.
- Álvarez, P., Zarazaga-Soria, F. J., e Baldassarri, S. (2020). Mobile music recommendations for runners based on location and emotions: The dj-running system. *Pervasive and Mobile Computing*, 67:101242.
- Angelis, S., Kotis, K., e Spiliotopoulos, D. (2021). Semantic trajectory analytics and recommender systems in cultural spaces. *Big Data and Cognitive Computing*, página 80.
- Artemenko, O., Pasichnyk, V., e Kunanets, N. (2020). Using mobile location-based recommender systems for providing real time recommendations for social distancing urban route planning. In *2020 IEEE 15th International Conference on Computer Sciences and Information Technologies (CSIT)*, páginas 305–308.
- Canturk, D., Karagoz, P., Kim, S.-W., e Toroslu, I. H. (2023). Trust-aware location recommendation in location-based social networks: A graph-based approach. *Expert Systems with Applications*, 213:119048.
- de Sousa, A. S., de Oliveira, G. S., e Alves, L. H. (2021). A pesquisa bibliográfica: princípios e fundamentos. *Cadernos da FUCAMP*.
- Dermeval, D., Coelho, J. A. d. M., e BITTENCOURT, I. I. (2020). Mapeamento sistemático e revisão sistemática da literatura em informática na educação. *Metodologia de Pesquisa Científica em Informática na Educação: Abordagem Quantitativa*.
- Donthu, N., Kumar, S., Mukherjee, D., Pandey, N., e Lim, W. M. (2021). How to conduct a bibliometric analysis: An overview and guidelines. *Journal of business research*, páginas 285–296.
- Güting, R. H. (1994). An introduction to spatial database systems. *the VLDB Journal*, páginas Pag. 357–399.

- Han, S., Chen, L., Su, Z., Gupta, S., e Sivarajah, U. (2024). Identifying a good business location using prescriptive analytics: Restaurant location recommendation based on spatial data mining. *Journal of Business Research*, 179:114691.
- Ivanova, I., Andrić, M., e Ricci, F. (2022). Content-based recommendations for crags and climbing routes. In *Information and Communication Technologies in Tourism 2022: Proceedings of the ENTER 2022 eTourism Conference.*, páginas 369–381.
- Jiao, Y. e Chiang, Y.-Y. (2021). Src: Incorporating geographic information for building a location-based recommendation system. In *Proceedings of the 29th International Conference on Advances in Geographic Information Systems*, páginas 680–681.
- Khusro, S., Ali, Z., e Ullah, I. (2016). Recommender systems: issues, challenges, and research opportunities. In *Information science and applications.*, páginas 1179–1189.
- Kitchenham, B., Charters, S., et al. (2007). Guidelines for performing systematic literature reviews in software engineering.
- Liu, Y., Medlar, A., e Glowacka, D. (2023). What we evaluate when we evaluate recommender systems: Understanding recommender systems’ performance using item response theory. In *Proceedings of the 17th ACM Conference on Recommender Systems*, página 658–670.
- Lü, L., Medo, M., Yeung, C. H., Zhang, Y.-C., Zhang, Z.-K., e Zhou, T. (2012). Recommender systems. *Physics reports*, páginas 1–49.
- Luo, Y., Duan, H., Liu, Y., e Chung, F.-L. (2023). Timestamps as prompts for geography-aware location recommendation. In *Proceedings of the 32nd ACM International Conference on Information and Knowledge Management*, páginas 1697–1706.
- Napoleão, B., Felizardo, K. R., de Souza, É. F., e Vijaykumar, N. L. (2017). Practical similarities and differences between systematic literature reviews and systematic mappings: a tertiary study. In *SEKE*, páginas 85–90.
- Panteli, A. e Boutsinas, B. (2023). Improvement of similarity–diversity trade-off in recommender systems based on a facility location model. *Neural Computing and Applications*, 35(1):177–189.
- Parsifal (2021). About parsifal. <https://parsif.al/about/> [Acessado em: 09 jan. 2024.].
- Pebesma, E. e Bivand, R. (2023). *Spatial data science: With applications in R*. CRC Press.

- Prodanov, C. C. e De Freitas, E. C. (2013). *Metodologia do trabalho científico: métodos e técnicas da pesquisa e do trabalho acadêmico-2ª Edição*. Editora Feevale.
- Qian, X., Rossi, R. A., Du, F., Kim, S., Koh, E., Malik, S., Lee, T. Y., e Ahmed, N. K. (2022). Personalized visualization recommendation. *ACM Transactions on the Web*, páginas 1–47.
- Rocha-Junior, J. B. (2013). *Efficient Processing of Preference Queries in Distributed and Spatial Databases*. Tese de Doutorado, Citeseer.
- Roy, D. e Dutta, M. (2022). A systematic review and research perspective on recommender systems. *Journal of Big Data*, página 59.
- Sheng, X., Wang, F., Zhu, Y., Liu, T., e Chen, H. (2022). Personalized recommendation of location-based services using spatio-temporal-aware long and short term neural network. *IEEE Access*, 10:39864–39874.
- Sojahrood, Z. B. e Taleai, M. (2021). A poi group recommendation method in location-based social networks based on user influence. *Expert Systems with Applications*, 171:114593.
- Tiwari, S., Kaushik, S., e Jagwani, P. (2012). Location based recommender systems: Architecture, trends and research areas.
- Vahidnia, M. H. (2022). Point-of-interest recommendation in location-based social networks based on collaborative filtering and spatial kernel weighting. *Geocarto international*, páginas 13949–13972.
- Wagner, M., Carolina, A., e Paula, A. (2023). Pesquisa científica na computação: Uma abordagem com revisão sistemática de literatura. *IEEE Transactions on Mobile Computing*.
- Weydemann, L., Sacharidis, D., e Werthner, H. (2019). Defining and measuring fairness in location recommendations. In *Proceedings of the 3rd ACM SIGSPATIAL international workshop on location-based recommendations, geosocial networks and geoadvertising*, páginas 1–8.
- Xia, B., Ni, Z., Li, T., Li, Q., e Zhou, Q. (2017). Vrer: context-based venue recommendation using embedded space ranking svm in location-based social network. *Expert Systems with Applications*, 83:18–29.
- Zangerle, E. e Bauer, C. (2022). Evaluating recommender systems: survey and framework. *ACM Computing Surveys*, páginas 1–38.

Apêndice A

Artigos selecionados

1. Yue-Qiang, R., Ze, W., Xiao-Na, S., & Shi-Min, S. (2019). A multi-element hybrid location recommendation algorithm for location based social networks. *IEEE Access*, 7, 100416-100427.
2. Sarwat, M., Levandoski, J. J., Eldawy, A., & Mokbel, M. F. (2014). Lars*: An efficient and scalable location-aware recommender system. *IEEE Transactions on Knowledge & Data Engineering*, 26(06), 1384-1399.
3. Yin, Y., Chen, L., & Wan, J. (2018). Location-aware service recommendation with enhanced probabilistic matrix factorization. *IEEE Access*, 6, 62815-62825.
4. Zhang, Y., Yin, C., Wu, Q., He, Q., & Zhu, H. (2019). Location-aware deep collaborative filtering for service recommendation. *IEEE Transactions on Systems, Man, and Cybernetics: Systems*, 51(6), 3796-3807.
5. Tang, M., Jiang, Y., Liu, J., & Liu, X. (2012, June). Location-aware collaborative filtering for QoS-based service recommendation. In *2012 IEEE 19th international conference on web services* (pp. 202-209). IEEE.
6. Hao, F., Li, S., Min, G., Kim, H. C., Yau, S. S., & Yang, L. T. (2015). An efficient approach to generating location-sensitive recommendations in ad-hoc social network environments. *IEEE Transactions on Services Computing*, 8(3), 520-533.
7. Chen, C., Meng, X., Xu, Z., & Lukasiewicz, T. (2017). Location-aware personalized news recommendation with deep semantic analysis. *IEEE Access*, 5, 1624-1638.
8. Ren, Y., Tomko, M., Salim, F. D., Chan, J., Clarke, C. L., & Sanderson, M. (2017). A location-query-browse graph for contextual recommendation. *IEEE Transactions on Knowledge and Data Engineering*, 30(2), 204-218.

9. Lin, W., Zhang, X., Qi, L., Li, W., Li, S., Sheng, V. S., & Nepal, S. (2020). Location-aware service recommendations with privacy-preservation in the Internet of Things. *IEEE Transactions on Computational Social Systems*, 8(1), 227-235.
10. Brunato, M., & Battiti, R. (2003, March). PILGRIM: A location broker and mobility-aware recommendation system. In *Proceedings of the First IEEE International Conference on Pervasive Computing and Communications, 2003.(PerCom 2003)*. (pp. 265-272). IEEE.
11. Pan, X., Cai, X., Song, K., Baker, T., Gadekallu, T. R., & Yuan, X. (2022). Location recommendation based on mobility graph with individual and group influences. *IEEE Transactions on Intelligent Transportation Systems*, 24(8), 8409-8420.
12. Gong, X., Ning, Z., Guo, L., Wei, X., & Song, Q. (2016). Location-recommendation-aware virtual network embedding in energy-efficient optical-wireless hybrid networks supporting 5G models. *IEEE Access*, 4, 3065-3075.
13. Canturk, D., & Karagoz, P. (2021). Sgwalk: Location recommendation by user subgraph-based graph embedding. *IEEE Access*, 9, 134858-134873.
14. Sheng, X., Wang, F., Zhu, Y., Liu, T., & Chen, H. (2022). Personalized recommendation of location-based services using spatio-temporal-aware long and short term neural network. *IEEE Access*, 10, 39864-39874.
15. Lu, J., & Indeché, M. A. (2020). Multi-context-aware location recommendation using tensor decomposition. *IEEE Access*, 8, 61327-61339.
16. Zhu, X., Hao, R., Chi, H., & Du, X. (2016, December). Personalized location recommendations with local feature awareness. In *2016 IEEE Global Communications Conference (GLOBECOM)* (pp. 1-6). IEEE.
17. Ding, D., Zhang, M., Pan, X., Yang, M., & He, X. (2020, November). Modeling personalized out-of-town distances in location recommendation. In *2020 IEEE International Conference on Data Mining (ICDM)* (pp. 112-121). IEEE.
18. Luo, Y., Duan, H., Liu, Y., & Chung, F. L. (2023, October). Timestamps as Prompts for Geography-Aware Location Recommendation. In *Proceedings of the 32nd ACM International Conference on Information and Knowledge Management* (pp. 1697-1706).
19. Teoman, H. A., & Karagoz, P. (2022, April). Group oriented trust-aware location recommendation for location-based social networks. In *Proceedings of the 37th ACM/SIGAPP symposium on applied computing* (pp. 1779-1788).
20. Rao, X., Chen, L., Liu, Y., Shang, S., Yao, B., & Han, P. (2022, August). Graph-flashback network for next location recommendation. In *Proceedings of the 28th ACM SIGKDD conference on knowledge discovery and data mining* (pp. 1463-1471).

21. Fu, Z., Yu, L., & Niu, X. (2022). TRACE: Travel reinforcement recommendation based on location-aware context extraction. *ACM Transactions on Knowledge Discovery from Data (TKDD)*, 16(4), 1-22.
22. Luo, Y., Liu, Q., & Liu, Z. (2021, April). Stan: Spatio-temporal attention network for next location recommendation. In *Proceedings of the web conference 2021* (pp. 2177-2185).
23. Li, R., Wu, X., Wu, X., & Wang, W. (2020, April). Few-shot learning for new user recommendation in location-based social networks. In *Proceedings of The Web Conference 2020* (pp. 2472-2478).
24. Dadoun, A., Troncy, R., Ratier, O., & Petitti, R. (2019, May). Location embeddings for next trip recommendation. In *Companion Proceedings of The 2019 World Wide Web Conference* (pp. 896-903).
25. Gao, C., Huang, C., Yu, Y., Wang, H., Li, Y., & Jin, D. (2019). Privacy-preserving cross-domain location recommendation. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 3(1), 1-21.
26. Yao, L., Sheng, Q. Z., Wang, X., Zhang, W. E., & Qin, Y. (2018). Collaborative location recommendation by integrating multi-dimensional contextual information. *ACM Transactions on Internet Technology (TOIT)*, 18(3), 1-24.
27. Cheng, Z., & Shen, J. (2016). On effective location-aware music recommendation. *ACM Transactions on Information Systems (TOIS)*, 34(2), 1-32.
28. Gao, H., Tang, J., Hu, X., & Liu, H. (2013, October). Exploring temporal effects for location recommendation on location-based social networks. In *Proceedings of the 7th ACM conference on Recommender systems* (pp. 93-100).
29. Liu, Y., Wei, W., Sun, A., & Miao, C. (2014, November). Exploiting geographical neighborhood characteristics for location recommendation. In *Proceedings of the 23rd ACM international conference on conference on information and knowledge management* (pp. 739-748).
30. Zhang, W., & Wang, J. (2015, October). Location and time aware social collaborative retrieval for new successive point-of-interest recommendation. In *Proceedings of the 24th ACM international on conference on information and knowledge management* (pp. 1221-1230).
31. Zhang, J. D., & Chow, C. Y. (2015). Spatiotemporal sequential influence modeling for location recommendations: A gravity-based approach. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 7(1), 1-25.
32. Ying, J. J. C., Lu, E. H. C., & Tseng, V. S. (2012, September). Followee recommendation in asymmetrical location-based social networks. In *Proceedings of the 2012 ACM Conference on Ubiquitous Computing* (pp. 988-995).

-
33. Li, R., Wu, X., & Wang, W. (2020, January). Adversarial learning to compare: Self-attentive prospective customer recommendation in location based social networks. In *Proceedings of the 13th International Conference on Web Search and Data Mining* (pp. 349-357).
 34. Hsieh, H. P., Li, C. T., & Lin, S. D. (2014). Measuring and recommending time-sensitive routes from location-based data. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 5(3), 1-27.
 35. Tu, Z., Fan, Y., Li, Y., Chen, X., Su, L., & Jin, D. (2019). From fingerprint to footprint: Cold-start location recommendation by learning user interest from app data. *Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies*, 3(1), 1-22.
 36. Zheng, Y., Zhang, L., Ma, Z., Xie, X., & Ma, W. Y. (2011). Recommending friends and locations based on individual location history. *ACM Transactions on the Web (TWEB)*, 5(1), 1-44.
 37. Lian, D., Zheng, K., Ge, Y., Cao, L., Chen, E., & Xie, X. (2018). GeoMF++ scalable location recommendation via joint geographical modeling and matrix factorization. *ACM Transactions on Information Systems (TOIS)*, 36(3), 1-29.
 38. Liao, Y., Lam, W., Jameel, S., Schockaert, S., & Xie, X. (2016, September). Who wants to join me? Companion recommendation in location based social networks. In *Proceedings of the 2016 ACM International Conference on the Theory of Information Retrieval* (pp. 271-280).
 39. Ayala-Gómez, F., Daróczy, B. Z., Mathioudakis, M., Benczúr, A., & Gionis, A. (2017). Where could we go? Recommendations for groups in location-based social networks.
 40. Cheng, Z., & Shen, J. (2014, April). Just-for-me: an adaptive personalization system for location-aware social music recommendation. In *Proceedings of international conference on multimedia retrieval* (pp. 185-192).
 41. Ma, Y., Mao, J., Ba, Z., & Li, G. (2020). Location recommendation by combining geographical, categorical, and social preferences with location popularity. *Information Processing & Management*, 57(4), 102251.
 42. Yang, W. S., Cheng, H. C., & Dia, J. B. (2008). A location-aware recommender system for mobile shopping environments. *Expert Systems with Applications*, 34(1), 437-445.
 43. Sojahrood, Z. B., & Taleai, M. (2021). A POI group recommendation method in location-based social networks based on user influence. *Expert Systems with Applications*, 171, 114593.
 44. Seo, Y. D., & Cho, Y. S. (2021). Point of interest recommendations based on the anchoring effect in location-based social network services. *Expert Systems with Applications*, 164, 114018.

45. Chen, Z., Xia, J. C., Irawan, B., & Caulfied, C. (2014). Development of location-based services for recommending departure stations to park and ride users. *Transportation Research Part C: Emerging Technologies*, 48, 256-268.
46. Huang, L., Ma, Y., Liu, Y., & Sangaiah, A. K. (2020). Multi-modal Bayesian embedding for point-of-interest recommendation on location-based cyber-physical-social networks. *Future Generation Computer Systems*, 108, 1119-1128.
47. Tao, M., Wei, W., & Huang, S. (2019). Location-based trustworthy services recommendation in cooperative-communication-enabled internet of vehicles. *Journal of Network and Computer Applications*, 126, 1-11.
48. Zhang, J. D., & Chow, C. Y. (2015). CoRe: Exploiting the personalized influence of two-dimensional geographic coordinates for location recommendations. *Information Sciences*, 293, 163-181.
49. Ojagh, S., Malek, M. R., Saeedi, S., & Liang, S. (2020). A location-based orientation-aware recommender system using IoT smart devices and Social Networks. *Future Generation Computer Systems*, 108, 97-118.
50. Acharya, M., Yadav, S., & Mohbey, K. K. (2023). 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*, 3(1), 100161.
51. Xia, B., Ni, Z., Li, T., Li, Q., & Zhou, Q. (2017). Vrer: context-based venue recommendation using embedded space ranking SVM in location-based social network. *Expert Systems with Applications*, 83, 18-29.
52. Xin, M., & Wu, L. (2020). Using multi-features to partition users for friends recommendation in location based social network. *Information Processing & Management*, 57(1), 102125.
53. Al-Ghobari, M., Muneer, A., & Fati, S. M. (2021). Location-Aware Personalized Traveler Recommender System (LAPTA) Using Collaborative Filtering KNN. *Computers, Materials & Continua*, 69(2).
54. Qiao, Z., Zhang, P., Cao, Y., Zhou, C., & Guo, L. (2014). Improving collaborative recommendation via location-based user-item subgroup. *Procedia Computer Science*, 29, 400-409.
55. Shi, L. L., Liu, L., Jiang, L., Zhu, R., & Panneerselvam, J. (2022). QoS prediction for smart service management and recommendation based on the location of mobile users. *Neurocomputing*, 471, 12-20.
56. Geng, B., Jiao, L., Gong, M., Li, L., & Wu, Y. (2019). A two-step personalized location recommendation based on multi-objective immune algorithm. *Information Sciences*, 475, 161-181.

57. Gao, Q., Wang, W., Huang, L., Yang, X., Li, T., & Fujita, H. (2023). Dual-grained human mobility learning for location-aware trip recommendation with spatial-temporal graph knowledge fusion. *Information Fusion*, 92, 46-63.
58. Zhou, Y., Yang, G., Yan, B., Cai, Y., & Zhu, Z. (2022). Point-of-interest recommendation model considering strength of user relationship for location-based social networks. *Expert Systems with Applications*, 199, 117147.
59. Gao, R., Li, J., Li, X., Song, C., Chang, J., Liu, D., & Wang, C. (2018). STSCR: Exploring spatial-temporal sequential influence and social information for location recommendation. *Neurocomputing*, 319, 118-133.
60. Tsai, C. Y., & Lai, B. H. (2015). A location-item-time sequential pattern mining algorithm for route recommendation. *Knowledge-Based Systems*, 73, 97-110.
61. Ekaterina, G., Ivan, D., & Oksana, S. (2020). A trust and relevance-based Point-Of-Interest recommendations method with inaccessible user location. *Procedia Computer Science*, 178, 153-161.
62. Wang, S., Gong, M., Wu, Y., & Zhang, M. (2020). Multi-objective optimization for location-based and preferences-aware recommendation. *Information Sciences*, 513, 614-626.
63. Cai, W., Wang, Y., Lv, R., & Jin, Q. (2019). An efficient location recommendation scheme based on clustering and data fusion. *Computers & Electrical Engineering*, 77, 289-299.
64. BKuo, M. H., Chen, L. C., & Liang, C. W. (2009). Building and evaluating a location-based service recommendation system with a preference adjustment mechanism. *Expert Systems with Applications*, 36(2), 3543-3554.
65. Si, Y., Zhang, F., & Liu, W. (2019). An adaptive point-of-interest recommendation method for location-based social networks based on user activity and spatial features. *Knowledge-Based Systems*, 163, 267-282.
66. Acharya, M., & Mohbey, K. K. (2024). High-order spatial connectivity mining over neural graph collaborative filtering for POI recommendation in location-based social networks. *Evolving Systems*, 1-16.
67. Amirat, H., Lagraa, N., Fournier-Viger, P., Ouinen, Y., Kherfi, M. L., & Guellouma, Y. (2023). Incremental tree-based successive POI recommendation in location-based social networks. *Applied Intelligence*, 53(7), 7562-7598.
68. Liu, Z., Zhang, H., Ouyang, G., Chen, J., & Wu, K. (2022). Data-driven pick-up location recommendation for ride-hailing services. *IEEE Transactions on Mobile Computing*, 23(2), 1001-1015.
69. Bashir, S. R., Raza, S., & Misic, V. B. (2023). BERT4Loc: BERT for Location—POI recommender system. *Future Internet*, 15(6), 213.

70. Wang, Q., Zhang, M., Zhang, Y., Zhong, J., & Sheng, V. S. (2022). Location-based deep factorization machine model for service recommendation. *Applied Intelligence*, 1-20.
71. Han, S., Chen, L., Su, Z., Gupta, S., & Sivarajah, U. (2024). Identifying a good business location using prescriptive analytics: Restaurant location recommendation based on spatial data mining. *Journal of Business Research*, 179, 114691.
72. Liu, J., Yi, H., Gao, Y., & Jing, R. (2023). Personalized Point-of-Interest Recommendation Using Improved Graph Convolutional Network in Location-Based Social Network. *Electronics*, 12(16), 3495.
73. Zhu, R., Lv, D., Yu, Y., Zhu, R., Zheng, Z., Bu, K., ... & Wu, F. (2023, April). LINet: A Location and Intention-Aware Neural Network for Hotel Group Recommendation. In *Proceedings of the ACM Web Conference 2023* (pp. 779-789).
74. Xu, S., Huang, Q., & Zou, Z. (2023). Spatio-temporal transformer recommender: next location recommendation with attention mechanism by mining the spatio-temporal relationship between visited locations. *ISPRS International Journal of Geo-Information*, 12(2), 79.
75. Wei, X., Liu, C., Liu, Y., Li, Y., & Zhang, K. (2023). Next location recommendation: a multi-context features integration perspective. *World Wide Web*, 26(4), 2051-2074.
76. Chen, Y., Huang, G., Wang, Y., Huang, X., & Min, G. (2023). A graph neural network incorporating spatio-temporal information for location recommendation. *World wide web*, 26(5), 3633-3654.
77. Lai, Y., & Zeng, X. (2023). A POI recommendation model for intelligent systems using AT-LSTM in location-based social network big data. *International Journal on Semantic Web and Information Systems (IJSWIS)*, 19(1), 1-15.
78. Telonis, G., Panteli, A., & Boutsinas, B. (2023). A Point-of-Interest Recommender System for Tourist Groups Based on Cooperative Location Set Cover Problem. *Mathematics*, 11(17), 3646.
79. Acharya, M., & Mohbey, K. K. (2023). Trust-aware spatial-temporal feature estimation for next POI recommendation in location-based social networks. *Social Network Analysis and Mining*, 13(1), 102.
80. Panteli, A., & Boutsinas, B. (2023). Improvement of similarity-diversity trade-off in recommender systems based on a facility location model. *Neural Computing and Applications*, 35(1), 177-189.
81. Chen, X., Chen, J., Lian, X., & Mai, W. (2022). Resolving data sparsity via aggregating graph-based user-app-location association for location recommendations. *Applied Sciences*, 12(14), 6882.

82. Zhao, X., Zhang, Z., Bi, X., & Sun, Y. (2023). A new point-of-interest group recommendation method in location-based social networks. *Neural Computing and Applications*, 1-12.
83. Li, Z., Wu, J., Han, G., Ma, C., & Chen, Y. (2023). Multi-hypergraph Neural Network with Fusion of Location Information for Session-based Recommendation. *IAENG International Journal of Applied Mathematics*, 53(4).
84. Wang, B., Li, H., Tong, L., Zhang, Q., Zhu, S., & Yang, T. (2023). SanMove: next location recommendation via self-attention network. *Data Technologies and Applications*, 57(3), 330-343.
85. Chang, W., Sun, D., & Du, Q. (2023). Intelligent sensors for POI recommendation model using deep learning in location-based social network big data. *Sensors*, 23(2), 850.
86. Safavi, S., & Jalali, M. (2022). DeePOF: A hybrid approach of deep convolutional neural network and friendship to Point-of-Interest (POI) recommendation system in location-based social networks. *Concurrency and Computation: Practice and Experience*, 34(15), e6981.
87. Moayedikia, A., Jahani, H., Rahman, M. A., & Ong, K. L. (2024). Three-layered location recommendation algorithm using spectral clustering. *Social Network Analysis and Mining*, 14(1), 1-17.
88. Canturk, D., Karagoz, P., Kim, S. W., & Toroslu, I. H. (2023). Trust-aware location recommendation in location-based social networks: A graph-based approach. *Expert Systems with Applications*, 213, 119048.
89. Chen, Y. M., Chen, T. Y., & Chen, L. C. (2021). On a method for location and mobility analytics using location-based services: a case study of retail store recommendation. *Online Information Review*, 45(2), 297-315.
90. Wan, L., Wang, H., Hong, Y., Li, R., Chen, W., & Huang, Z. (2022). iTourS-POT: a context-aware framework for next POI recommendation in location-based social networks. *International Journal of Digital Earth*, 15(1), 1614-1636.
91. Zhong, T., Zhang, S., Zhou, F., Zhang, K., Trajcevski, G., & Wu, J. (2020). Hybrid graph convolutional networks with multi-head attention for location recommendation. *World Wide Web*, 23, 3125-3151.
92. Chen, Y. C., Huang, H. H., Chiu, S. M., & Lee, C. (2021). Joint promotion partner recommendation systems using data from location-based social networks. *ISPRS International Journal of Geo-Information*, 10(2), 57.
93. Vahidnia, M. H. (2022). Point-of-interest recommendation in location-based social networks based on collaborative filtering and spatial kernel weighting. *Geocarto international*, 37(26), 13949-13972.

94. Yu, M., Fan, G., Yu, H., & Chen, L. (2021). Location-based and time-aware service recommendation in mobile edge computing. *International Journal of Parallel Programming*, 49, 715-731.
95. Zhang, H., Gan, M., & Sun, X. (2021). Incorporating memory-based preferences and point-of-interest stickiness into recommendations in location-based social networks. *ISPRS International Journal of Geo-Information*, 10(1), 36.
96. Elangovan, R., Vairavasundaram, S., Varadarajan, V., & Ravi, L. (2021). Location-based social network recommendations with computational intelligence-based similarity computation and user check-in behavior. *Concurrency and computation: practice and experience*, 33(22), e6106.
97. Zhao, G., Liu, T., Qian, X., Hou, T., Wang, H., Hou, X., & Li, Z. (2017). Location recommendation for enterprises by multi-source urban big data analysis. *IEEE Transactions on Services Computing*, 13(6), 1115-1127.
98. Liu, B., Meng, Q., Zhang, H., Xu, K., & Cao, J. (2022). VGMF: visual contents and geographical influence enhanced point-of-interest recommendation in location-based social network. *Transactions on Emerging Telecommunications Technologies*, 33(6), e3889.
99. Chatzidimitris, T., Gavalas, D., Kasapakis, V., Konstantopoulos, C., Kypriadis, D., Pantziou, G., & Zaroliagis, C. (2020). A location history-aware recommender system for smart retail environments. *Personal and Ubiquitous Computing*, 24, 683-694.
100. Rahimi, S. M., Far, B., & Wang, X. (2022). Contextual location recommendation for location-based social networks by learning user intentions and contextual triggers. *GeoInformatica*, 26(1), 1-28.
101. Mohammadi, N., & Rasoolzadegan, A. (2022). A two-stage location-sensitive and user preference-aware recommendation system. *Expert Systems with Applications*, 191, 116188.
102. Liu, Y., & Wu, A. B. (2021). POI Recommendation Method Using Deep Learning in Location-Based Social Networks. *Wireless Communications and Mobile Computing*, 2021(1), 9120864.
103. Zhu, J., Han, L., Gou, Z., Yang, Y., Yuan, X., Li, J., & Li, S. (2021). A robust personalized location recommendation based on ensemble learning. *Expert Systems with Applications*, 167, 114065.
104. Gültekin, G., & Bayat, O. (2022). A Naïve Bayes prediction model on location-based recommendation by integrating multi-dimensional contextual information. *Multimedia Tools and Applications*, 81(5), 6957-6978.
105. Ravi, L., Devarajan, M., V, V., Sangaiah, A. K., Wang, L., & Subramaniaswamy, V. (2021). An intelligent location recommender system utilising

-
- multi-agent induced cognitive behavioural model. *Enterprise Information Systems*, 15(10), 1376-1394.
106. Kang, Y., Chen, J., Cao, Y., & Xu, Z. (2021). A higher-order graph convolutional network for location recommendation of an air-quality-monitoring station. *Remote Sensing*, 13(8), 1600.
 107. Nguyen, L. V., Jung, J. J., & Hwang, M. (2020). OurPlaces: cross-cultural crowdsourcing platform for location recommendation services. *ISPRS International Journal of Geo-Information*, 9(12), 711.
 108. Lyu, Z., Yang, M., & Li, H. (2021). Multi-view group representation learning for location-aware group recommendation. *Information Sciences*, 580, 495-509.
 109. Xia, B., Bai, Y., Yin, J., Li, Q., & Xu, L. (2020). MTPR: a multi-task learning based poi recommendation considering temporal check-ins and geographical locations. *Applied Sciences*, 10(19), 6664.
 110. Shahriari-Mehr, G., Delavar, M. R., Claramunt, C., Araabi, B. N., & Dehaqani, M. R. A. (2021). A store location-based recommender system using user's position and web searches. *Journal of Location Based Services*, 15(2), 118-141.
 111. Wei, Y., Zhao, X., Zou, J., & Herrera-Viedma, E. (2019). A complementing preference based method for location recommendation with cellular data. *Knowledge-Based Systems*, 183, 104889.
 112. Meng, S., Qi, L., Li, Q., Lin, W., Xu, X., & Wan, S. (2019). Privacy-preserving and sparsity-aware location-based prediction method for collaborative recommender systems. *Future Generation Computer Systems*, 96, 324-335.
 113. Ameen, T., Chen, L., Xu, Z., Lyu, D., & Shi, H. (2020). A convolutional neural network and matrix factorization-based travel location recommendation method using community-contributed geotagged photos. *ISPRS International Journal of Geo-Information*, 9(8), 464.
 114. Li, J., Wang, X., & Feng, W. (2020). A point-of-interest recommendation algorithm combining social influence and geographic location based on belief propagation. *IEEE Access*, 8, 165748-165756.
 115. Baral, R., Iyengar, S. S., Zhu, X., Li, T., & Sniatala, P. (2019). HiRecS: A hierarchical contextual location recommendation system. *IEEE Transactions on Computational Social Systems*, 6(5), 1020-1037.
 116. Zhu, J., Wang, C., Guo, X., Ming, Q., Li, J., & Liu, Y. (2019). Friend and POI recommendation based on social trust cluster in location-based social networks. *EURASIP Journal on Wireless Communications and Networking*, 2019, 1-12.

117. Shi, H., Chen, L., Xu, Z., & Lyu, D. (2019). Personalized location recommendation using mobile phone usage information. *Applied Intelligence*, 49, 3694-3707.
118. Chen, M., Li, W. Z., Qian, L., Lu, S. L., & Chen, D. X. (2020). Next POI recommendation based on location interest mining with recurrent neural networks. *Journal of Computer Science and Technology*, 35, 603-616.
119. Honarparvar, S., Forouzandeh Jonaghani, R., Alesheikh, A. A., & Atazadeh, B. (2019). Improvement of a location-aware recommender system using volunteered geographic information. *Geocarto International*, 34(13), 1496-1513.
120. Rahimi, S. M., Far, B., & Wang, X. (2020). Behavior-based location recommendation on location-based social networks. *GeoInformatica*, 24(3), 477-504.
121. Zhao, G., Lou, P., Qian, X., & Hou, X. (2020). Personalized location recommendation by fusing sentimental and spatial context. *Knowledge-Based Systems*, 196, 105849.
122. Guo, Q., Sun, Z., Zhang, J., & Theng, Y. L. (2020, April). An attentional recurrent neural network for personalized next location recommendation. In *Proceedings of the AAAI Conference on artificial intelligence* (Vol. 34, No. 01, pp. 83-90).
123. Álvarez, P., Zarazaga-Soria, F. J., & Baldassarri, S. (2020). Mobile music recommendations for runners based on location and emotions: The DJ-Running system. *Pervasive and Mobile Computing*, 67, 101242.
124. Kaya, B. (2020). A hotel recommendation system based on customer location: a link prediction approach. *Multimedia Tools and Applications*, 79(3), 1745-1758.
125. Li, W., Liu, X., Yan, C., Ding, G., Sun, Y., & Zhang, J. (2020). STS: spatial-temporal-semantic personalized location recommendation. *ISPRS International Journal of Geo-Information*, 9(9), 538.
126. Gao, K., Yang, X., Wu, C., Qiao, T., Chen, X., Yang, M., & Chen, L. (2020). Exploiting location-based context for poi recommendation when traveling to a new region. *IEEE Access*, 8, 52404-52412.
127. Ravi, L., Subramaniaswamy, V., Devarajan, M., Ravichandran, K. S., Arunkumar, S., Indragandhi, V., & Vijayakumar, V. (2019). SECRECSY: A secure framework for enhanced privacy-preserving location recommendations in cloud environment. *Wireless Personal Communications*, 108, 1869-1907.
128. Maddikunta, P. K. R., Gadekallu, T. R., Al-Ahmari, A., & Abidi, M. H. (2020). Location based business recommendation using spatial demand. *Sustainability*, 12(10), 4124.

129. Qi, Z., Wang, H., He, T., Wang, C., Li, J., & Gao, H. (2020). TAILOR: time-aware facility location recommendation based on massive trajectories. *Knowledge and Information Systems*, 62(9), 3783-3810.
130. Pan, Y., & Wu, D. (2020). A novel recommendation model for online-to-offline service based on the customer network and service location. *Journal of Management Information Systems*, 37(2), 563-593.
131. Ravi, L., Subramaniaswamy, V., Vijayakumar, V., Chen, S., Karmel, A., & Devarajan, M. (2019). Hybrid location-based recommender system for mobility and travel planning. *Mobile Networks and Applications*, 24, 1226-1239.
132. Lyu, D., Chen, L., Xu, Z., & Yu, S. (2020). Weighted multi-information constrained matrix factorization for personalized travel location recommendation based on geo-tagged photos. *Applied Intelligence*, 50, 924-938.
133. Guo, L., Wen, Y., & Liu, F. (2019). Location perspective-based neighborhood-aware POI recommendation in location-based social networks. *Soft Computing*, 23(22), 11935-11945.
134. Nie, W., Ding, H., Song, D., & Long, X. (2019). Location emotion recognition for travel recommendation based on social network. *Signal, Image and Video Processing*, 13, 1259-1266.
135. Shafqat, W., & Byun, Y. C. (2020). A context-aware location recommendation system for tourists using hierarchical LSTM model. *Sustainability*, 12(10), 4107.
136. Liu, J., Zhang, Z., Liu, C., Qiu, A., & Zhang, F. (2020). Exploiting two-dimensional geographical and synthetic social influences for location recommendation. *ISPRS International Journal of Geo-Information*, 9(4), 285.
137. Khazaei, E., & Alimohammadi, A. (2019). Context-aware group-oriented location recommendation in location-based social networks. *ISPRS International Journal of Geo-Information*, 8(9), 406.
138. Oner, S. C., Oztaysi, B., & Oner, M. (2020). Social platform based interval valued intuitionistic fuzzy location recommendation system. *Journal of Intelligent & Fuzzy Systems*, 38(1), 1027-1042.
139. Yin, C., Ding, S., & Wang, J. (2019). Mobile marketing recommendation method based on user location feedback. *Human-centric computing and information sciences*, 9(1), 14.
140. Roy, A. C., Arefin, M. S., Kayes, A. S. M., Hammoudeh, M., & Ahmed, K. (2020). An empirical recommendation framework to support location-based services. *Future Internet*, 12(9), 154.
141. Li, J., Wang, Y., Zhong, Y., Guo, D., & Zhu, S. (2018). Aggregate location recommendation in dynamic transportation networks. *World Wide Web*, 21, 1637-1653.

142. Guo, L., Jiang, H., Liu, X., & Xing, C. (2019). Network Embedding-Aware Point-of-Interest Recommendation in Location-Based Social Networks. *Complexity*, 2019(1), 3574194.
143. Yang, X., Zimba, B., Qiao, T., Gao, K., & Chen, X. (2019). Exploring IoT location information to perform point of interest recommendation engine: Traveling to a new geographical region. *Sensors*, 19(5), 992.
144. Kuang, L., Yu, L., Huang, L., Wang, Y., Ma, P., Li, C., & Zhu, Y. (2018). A personalized QoS prediction approach for CPS service recommendation based on reputation and location-aware collaborative filtering. *Sensors*, 18(5), 1556.
145. Zhao, W. X., Zhou, N., Sun, A., Wen, J. R., Han, J., & Chang, E. Y. (2018). A time-aware trajectory embedding model for next-location recommendation. *Knowledge and Information Systems*, 56, 559-579.
146. Zhao, X., Ma, Z., & Zhang, Z. (2018). A novel recommendation system in location-based social networks using distributed ELM. *Memetic computing*, 10, 321-331.
147. Hao, F., Park, D. S., Yin, X., Wang, X., & Phonexay, V. (2019). A location-sensitive over-the-counter medicines recommender based on tensor decomposition. *The Journal of Supercomputing*, 75, 1953-1970.
148. Zhu, L., Yu, L., Cai, Z., & Zhang, J. (2019). Toward Pattern and Preference-Aware Travel Route Recommendation over Location-Based Social Networks. *Journal of Information Science & Engineering*, 35(5).
149. Xie, X., Zhang, X., Fu, J., Jiang, D., Yu, C., & Jin, M. (2018). Location recommendation of digital signage based on multi-source information fusion. *Sustainability*, 10(7), 2357.
150. Gan, M., & Gao, L. (2019). Discovering memory-based preferences for POI recommendation in location-based social networks. *ISPRS International Journal of Geo-Information*, 8(6), 279.
151. Ding, R., & Chen, Z. (2018). RecNet: A deep neural network for personalized POI recommendation in location-based social networks. *International Journal of Geographical Information Science*, 32(8), 1631-1648.
152. Tal, O., & Liu, Y. (2019). A Joint Deep Recommendation Framework for Location-Based Social Networks. *Complexity*, 2019(1), 2926749.
153. Khazaei, E., & Alimohammadi, A. (2018). An automatic user grouping model for a group recommender system in location-based social networks. *ISPRS international journal of geo-information*, 7(2), 67.
154. Hosseini, S., Yin, H., Zhou, X., Sadiq, S., Kangavari, M. R., & Cheung, N. M. (2019). Leveraging multi-aspect time-related influence in location recommendation. *World Wide Web*, 22, 1001-1028.

155. Guo, L., Jiang, H., & Wang, X. (2018). Location regularization-based poi recommendation in location-based social networks. *Information*, 9(4), 85.
156. Qian, T. Y., Liu, B., Hong, L., & You, Z. N. (2018). Time and location aware points of interest recommendation in location-based social networks. *Journal of Computer Science and Technology*, 33, 1219-1230.
157. Tang, L., Cai, D., Duan, Z., Ma, J., Han, M., & Wang, H. (2019). Discovering Travel Community for POI Recommendation on Location-Based Social Networks. *Complexity*, 2019(1), 8503962.
158. Czioska, P., Trifunović, A., Dennisen, S., & Sester, M. (2017). Location-and time-dependent meeting point recommendations for shared interurban rides. *Journal of location based services*, 11(3-4), 181-203.
159. Huang, H. (2016). Context-aware location recommendation using geotagged photos in social media. *ISPRS International Journal of Geo-Information*, 5(11), 195.
160. Wang, S., Gong, M., Li, H., Yang, J., & Wu, Y. (2017). Memetic algorithm based location and topic aware recommender system. *Knowledge-Based Systems*, 131, 125-134.
161. AlBanna, B., Sakr, M., Moussa, S., & Moawad, I. (2016). Interest aware location-based recommender system using geo-tagged social media. *ISPRS International Journal of Geo-Information*, 5(12), 245.
162. Xia, B., Li, T., Li, Q., & Zhang, H. (2018). Noise-tolerance matrix completion for location recommendation. *Data Mining and Knowledge Discovery*, 32, 1-24.
163. Kong, X., Xia, F., Wang, J., Rahim, A., & Das, S. K. (2017). Time-location-relationship combined service recommendation based on taxi trajectory data. *IEEE Transactions on Industrial Informatics*, 13(3), 1202-1212.
164. Yin, Y., Yu, F., Xu, Y., Yu, L., & Mu, J. (2017). Network location-aware service recommendation with random walk in cyber-physical systems. *Sensors*, 17(9), 2059.
165. Logesh, R., & Subramaniaswamy, V. (2017). Learning recency and inferring associations in location based social network for emotion induced point-of-interest recommendation. *Journal of Information Science & Engineering*, 33(6).
166. Ozsoy, M. G., Polat, F., & Alhajj, R. (2016, August). Time preference aware dynamic recommendation enhanced with location, social network and temporal information. In *2016 IEEE/ACM International Conference on Advances in Social Networks Analysis and Mining (ASONAM)* (pp. 909-916). IEEE.
167. Nie, W., Liu, A., Zhu, X., & Su, Y. (2016). Quality models for venue recommendation in location-based social network. *Multimedia Tools and Applications*, 75, 12521-12534.

-
168. Pálovics, R., Szalai, P., Pap, J., Frigó, E., Kocsis, L., & Benczúr, A. A. (2017). Location-aware online learning for top-k recommendation. *Pervasive and mobile computing*, 38, 490-504.
 169. Tuan, C. C., Hung, C. F., & Wu, Z. H. (2017). Collaborative location recommendations with dynamic time periods. *Pervasive and Mobile Computing*, 35, 1-14.
 170. Celdrán, A. H., Pérez, M. G., Clemente, F. J. G., & Pérez, G. M. (2016). Design of a recommender system based on users' behavior and collaborative location and tracking. *Journal of Computational Science*, 12, 83-94.
 171. Gao, H., Tang, J., & Liu, H. (2015). Addressing the cold-start problem in location recommendation using geo-social correlations. *Data Mining and Knowledge Discovery*, 29, 299-323.
 172. Huang, L., Ma, Y., & Liu, Y. (2015). Point-of-interest recommendation in location-based social networks with personalized geo-social influence. *China Communications*, 12(12), 21-31.
 173. Kosmides, P., Demestichas, K., Adamopoulou, E., Remoundou, C., Loumiotis, I., Theologou, M., & Anagnostou, M. (2016). Providing recommendations on location-based social networks. *Journal of ambient intelligence and humanized computing*, 7, 567-578.
 174. Bagci, H., & Karagoz, P. (2016). Context-aware location recommendation by using a random walk-based approach. *Knowledge and Information Systems*, 47, 241-260.
 175. Ravi, L., & Vairavasundaram, S. (2016). A collaborative location based travel recommendation system through enhanced rating prediction for the group of users. *Computational intelligence and neuroscience*, 2016(1), 1291358.
 176. Sattari, M., Toroslu, I. H., Karagoz, P., Symeonidis, P., & Manolopoulos, Y. (2015). Extended feature combination model for recommendations in location-based mobile services. *Knowledge and Information Systems*, 44, 629-661.
 177. Chen, X., Zeng, Y., Cong, G., Qin, S., Xiang, Y., & Dai, Y. (2015, February). On information coverage for location category based point-of-interest recommendation. In *Proceedings of the AAAI Conference on Artificial Intelligence* (Vol. 29, No. 1).
 178. Gao, H., Tang, J., Hu, X., & Liu, H. (2015, February). Content-aware point of interest recommendation on location-based social networks. In *Proceedings of the AAAI conference on artificial intelligence* (Vol. 29, No. 1).
 179. Liu, X., Liu, Y., & Li, X. (2016, July). Exploring the context of locations for personalized location recommendations. In *IJCAI* (pp. 1188-1194).

180. Zhang, J. D., Chow, C. Y., & Li, Y. (2014). iGeoRec: A personalized and efficient geographical location recommendation framework. *IEEE Transactions on Services Computing*, 8(5), 701-714.
181. Shi, Z., Wang, H., Wei, W., Zheng, X., Zhao, M., Zhao, J., & Wang, Y. (2016). Novel individual location recommendation with mobile based on augmented reality. *International Journal of Distributed Sensor Networks*, 12(7), 1550147716657266.
182. Wang, P., Yang, J., & Zhang, J. P. (2016). Protection of location privacy based on distributed collaborative recommendations. *Plos one*, 11(9), e0163053.
183. Zhou, D., Rahimi, S. M., & Wang, X. (2016). Similarity-based probabilistic category-based location recommendation utilizing temporal and geographical influence. *International Journal of Data Science and Analytics*, 1, 111-121.
184. Bao, J., Zheng, Y., & Mokbel, M. F. (2012, November). Location-based and preference-aware recommendation using sparse geo-social networking data. In *Proceedings of the 20th international conference on advances in geographic information systems* (pp. 199-208).
185. Zhu, J. Q., Lu, L., & Ma, C. M. (2015). From interest to location: Neighbor-based friend recommendation in social media. *Journal of Computer Science and Technology*, 30(6), 1188-1200.
186. Li, Y. M., Chou, C. L., & Lin, L. F. (2014). A social recommender mechanism for location-based group commerce. *Information Sciences*, 274, 125-142.
187. Chang, A., Hwang, T. K., Li, Y. M., & Lin, L. F. (2015). A contextual group recommender mechanism for location-based service.
188. Liu, S., & Meng, X. (2015). A Location-Based Business Information Recommendation Algorithm. *Mathematical Problems in Engineering*, 2015(1), 345480.
189. Li, J., & Li, L. (2014). A location recommender based on a hidden Markov model: mobile social networks. *Journal of organizational computing and electronic commerce*, 24(2-3), 257-270.
190. Li, W., Yao, M., Zhou, X., Nishimura, S., & Jin, Q. (2014). Recommendation of location-based services based on composite measures of trust degree. *The Journal of Supercomputing*, 69, 1154-1165.
191. Yang, D., Zhang, D., Yu, Z., & Wang, Z. (2013, May). A sentiment-enhanced personalized location recommendation system. In *Proceedings of the 24th ACM conference on hypertext and social media* (pp. 119-128).
192. Kaminskas, M., Ricci, F., & Schedl, M. (2013, October). Location-aware music recommendation using auto-tagging and hybrid matching. In *Proceedings of the 7th ACM Conference on Recommender Systems* (pp. 17-24).

-
193. Leung, K. W. T., Lee, D. L., & Lee, W. C. (2011, July). CLR: a collaborative location recommendation framework based on co-clustering. In Proceedings of the 34th international ACM SIGIR conference on Research and development in Information Retrieval (pp. 305-314).
 194. Liu, B., & Xiong, H. (2013, May). Point-of-interest recommendation in location based social networks with topic and location awareness. In Proceedings of the 2013 SIAM international conference on data mining (pp. 396-404). Society for Industrial and Applied Mathematics.
 195. Yu, Y., Kim, J., Shin, K., & Jo, G. S. (2009). Recommendation system using location-based ontology on wireless internet: An example of collective intelligence by using ‘mashup’ applications. *Expert systems with applications*, 36(9), 11675-11681.
 196. Dao, T. H., Jeong, S. R., & Ahn, H. (2012). A novel recommendation model of location-based advertising: Context-Aware Collaborative Filtering using GA approach. *Expert Systems with Applications*, 39(3), 3731-3739.
 197. Zheng, V. W., Zheng, Y., Xie, X., & Yang, Q. (2010, April). Collaborative location and activity recommendations with gps history data. In Proceedings of the 19th international conference on World wide web (pp. 1029-1038).
 198. Balduini, M., Celino, I., Dell’Aglia, D., Della Valle, E., Huang, Y., Lee, T., ... & Tresp, V. (2012). BOTTARI: An augmented reality mobile application to deliver personalized and location-based recommendations by continuous analysis of social media streams. *Journal of Web Semantics*, 16, 33-41.
 199. Rodriguez-Carrion, A., Garcia-Rubio, C., Campo, C., Cortés-Martín, A., Garcia-Lozano, E., & Noriega-Vivas, P. (2012). Study of lz-based location prediction and its application to transportation recommender systems. *sensors*, 12(6), 7496-7517.

Apêndice B

Tabelas da análise dos dados

Tabela B.1: Técnicas identificadas.

Técnica Identificada	Identificadores dos Artigos (IDs)
Filtragem Colaborativa	2, 3, 5, 6, 10, 17, 21, 26, 30, 35, 36, 37, 39, 48, 50, 53, 54, 55, 56, 61, 63, 73, 78, 81, 87, 90, 93, 94, 95, 99, 100, 104, 105, 107, 111, 112, 115, 116, 120, 127, 130, 136, 138, 143, 144, 150, 156, 157, 159, 161, 164, 165, 166, 169, 170, 175, 181, 182, 183, 184, 186, 187, 193, 196, 197
Aprendizado Profundo	7, 14, 16, 18, 27, 32, 33, 67, 70, 74, 76, 85, 86, 98, 101, 102, 109, 135, 152
Aprendizado de Máquina	82, 103, 106, 124, 128, 134, 140, 146, 149, 168, 171, 172, 173, 179, 198, 199
Fatoração de Matriz	15, 25, 29, 43, 117, 132, 133, 178, 191, 194
Grafo	8, 12, 13, 19, 38, 88, 137, 158, 167, 174, 188
Híbrido	131, 41, 42, 49, 58, 69, 176, 192
Baseado em Conteúdo	64, 68, 77, 119
Mineração de Dados	60, 89, 121, 148
Baseado em Contexto	22, 40, 51
Filtragem Colaborativa em Grafo Profundo	66, 72, 75
Algoritmo Guloso	129, 177
Filtragem Colaborativa Neural Profunda	4, 79
Modelo Generativo Probabilístico	46, 154
Rede Neural	142, 163
Rede Neural Convolucional	113, 139
Rede Neural Recorrente	118, 122
Rede Neural em Grafo	23,57
Algoritmo Bayesiano	155
Algoritmo de Alocação Latente de Dirichlet	44
Algoritmo de Diagrama de Voronoi	110
Algoritmo de Estrutura de Recomendação de Localização	28
Algoritmo de Propagação de Crença	114
Algoritmo de Recomendação de Serviços Confiáveis com Base em Localização	47
Algoritmo Dijkstra	141
Algoritmo Evolutivo	62
Algoritmo Gaussiano	125
Algoritmo Gaussiano e Algoritmo Unidimensional	65
Algoritmo GFP-LORE	1
Algoritmo Heurístico Guidance Search	34
Algoritmo Joint-Promotion-Partner	92
Algoritmo Locality Sensitive Hashing (LSH)	9
Algoritmo Memético	160
Análise de Big Data	97
Aprendizado Profundo em Grafos	71
Aprendizado Profundo MultiCamada	24
Aprendizagem de representação	108
Aprendizagem de representação distribuída	145
Baseado em Casos	80
Clusters	153
Decomposição de Tensor	147
Estimativa de Densidade de Kernel	180
Fatoração Tensorial	59
Filtragem Colaborativa em Grafo	11
Grafo em Rede Convolucional	20
Hipercubo	185
Integração de Bregman	162
Inteligência Artificial	123
Inteligência Coletiva	195
inteligência Computacional	96
Lógica Fuzzy	45
Modelo de Fator Latente	126
Modelo de Gravidade	31
Modelo de Markov Oculto	189
Modelo Skyline (Horizontal)	190
Rede de Auto Atenção	84
Rede Neural Convolucional em Grafo	91
Rede Neural Multi-hipergrafo	83
Rede Neural Profunda	151
Vetor de Suporte de Máquinas Multi Recurso	52

Tabela B.2: Agrupamento das técnicas identificadas.

Agrupamento	Técnicas Identificadas
Outras Técnicas Baseadas em Modelos Matemáticos (OTMM)	Algoritmo Bayesiano Algoritmo de Alocação Latente de Dirichlet Algoritmo Gaussiano Algoritmo Gaussiano e Algoritmo Unidimensional Decomposição de Tensor Estimativa de Densidade de Kernel Fatoração de Matriz Fatoração Tensorial Integração de Bregman Modelo de Fator Latente Modelo de Gravidade Modelo de Markov Oculto Modelo Generativo Probabilístico Modelo Skyline (Horizontal)
Aprendizado de Máquina (AM)	Algoritmo Evolutivo Algoritmo Memético Aprendizado de Máquina Aprendizado Profundo Aprendizado Profundo Multi Camada Aprendizagem de representação Aprendizagem de representação distribuída Mineração de Dados Rede Neural Rede Neural Convolutacional Rede Neural Profunda Rede Neural Recorrente Vetor de Suporte de Máquinas Multi Recurso
Híbrido (H)	Aprendizado Profundo em Grafos Filtragem Colaborativa em Grafo Filtragem Colaborativa em Grafo Profundo Filtragem Colaborativa Neural Profunda Grafo em Rede Convolutacional Híbrido Rede Neural Convolutacional em Grafo Rede Neural em Grafo Rede Neural Multi-hipergrafo
Estruturas Gráficas ou Espaciais (EGE)	Grafo Hipercubo Algoritmo de Diagrama de Voronoi Algoritmo de Estrutura de Recomendação de Localização Algoritmo de Propagação de Crença Algoritmo de Recomendação de Serviços Confiáveis com Base em Localização Algoritmo Dijkstra
Outras Técnicas de IA (OIA)	Análise de Big Data Clusters Inteligência Artificial Inteligência Coletiva inteligência Computacional Lógica Fuzzy Rede de Auto Atenção
Outras Técnicas (OT)	Algoritmo GFP-LORE Algoritmo Guloso Algoritmo Heurístico Guidance Search Algoritmo Joint-Promotion-Partner Algoritmo Locality Sensitive Hashing (LSH)
Filtragem Colaborativa (FC)	Filtragem Colaborativa
Baseado em Conteúdo (BC)	Baseado em Conteúdo
Baseado em Contexto (BX)	Baseado em Contexto
Baseado em Casos (BCS)	Baseado em Casos

Tabela B.3: Fonte de origem dos dados.

Origem dos Dados	Identificação (ID)s	Quantitativo
Redes Sociais Baseadas em Localização	1, 2, 7, 11, 13, 14, 15, 16, 17, 18, 19, 20, 22, 23, 24, 25, 26, 28, 29, 30, 31, 33, 34, 37, 38, 39, 40, 41, 43, 44, 46, 48, 51, 52, 54, 56, 58, 59, 63, 65, 66, 67, 69, 72, 74, 75, 76, 77, 79, 82, 84, 85, 86, 88, 89, 91, 92, 93, 95, 96, 98, 100, 102, 103, 104, 105, 108, 109, 114, 115, 116, 118, 120, 121, 122, 125, 127, 133, 134, 136, 137, 138, 142, 145, 146, 149, 150, 151, 153, 154, 155, 156, 157, 159, 160, 161, 162, 166, 167, 168, 171, 172, 173, 174, 175, 176, 177, 178, 179, 180, 183, 184, 185, 186, 187, 189, 191, 194, 198	119
Plataforma de Avaliação de Restaurantes ou Turismo	15, 17, 23, 32, 33, 41, 61, 69, 71, 72, 73, 80, 86, 87, 91, 107, 124, 126, 128, 130, 131, 135, 136, 138, 143, 152, 165, 167, 188, 190	30
APPs e Ferramentas de Coleta de Dados	21, 35, 50, 53, 78, 81, 99, 117, 119, 135, 181, 199	12
Dataset de Serviços Web	3, 4, 5, 9, 12, 55, 70, 94, 101, 112, 144	11
Dados de Mapeamento ou Localização Geográfica	36, 45, 60, 97, 130, 140, 163, 193, 195, 197	10
Dados de Tráfego ou Mobilidade Urbana	22, 47, 129, 141, 148, 158, 164, 182	8
Plataforma de Recomendação de Filmes	2, 6, 54, 62, 130, 160, 170, 196	8
Plataforma de Armazenamento de Foto	57, 90, 113, 132, 159, 167	6
Site	10, 110, 123, 167, 169, 192	6
Dados para Análise de Compras ou Consumo	83, 141, 147, 149, 158	5
Plataforma de Criação de Grupo	17, 49, 108, 160	4
Dados Sintéticos	2, 128, 141	3
Usuários que Testaram o Sistema	42, 47, 64	3
Fontes de Dados de Clima ou Ambiente	90, 106	2
Plataforma de Stream de Música	27, 62	2
Rede de Internet (Wi-fi ou 3G)	8, 111	2
Aplicativo (APP) de Carona	68	1

Tabela B.4: Dados espaciais extraídos.

Dados Espaciais Extraídos	Identificadores (IDs)	Quantitativo
Localização do Usuário	1, 2, 3, 4, 5, 6, 7, 9, 10, 11, 12, 13, 15, 16, 17, 18, 19, 20, 21, 22, 25, 26, 27, 28, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 42, 43, 44, 45, 46, 47, 48, 49, 51, 52, 53, 54, 56, 58, 59, 61, 62, 64, 65, 67, 69, 70, 72, 74, 75, 76, 79, 81, 82, 83, 84, 85, 86, 87, 88, 89, 90, 91, 93, 94, 95, 96, 98, 99, 100, 101, 102, 103, 104, 105, 107, 108, 109, 110, 111, 112, 113, 114, 115, 116, 117, 118, 119, 120, 121, 122, 123, 124, 125, 126, 127, 128, 130, 131, 132, 133, 134, 135, 136, 137, 138, 139, 140, 142, 143, 144, 145, 146, 148, 150, 151, 152, 153, 154, 155, 156, 157, 158, 159, 160, 161, 162, 164, 165, 166, 167, 168, 169, 170, 171, 172, 173, 174, 175, 176, 177, 178, 179, 180, 183, 184, 185, 187, 188, 189, 190, 191, 194, 195, 196, 197, 198, 199	171
Localização do Negócio	8, 23, 61, 66, 71, 77, 78, 80, 92, 97, 106, 108, 110, 128, 147, 186, 190, 192	18
Trajetórias do Usuário	57, 60, 68, 73, 122, 129, 141, 145, 148, 157, 193	11
Localização do Serviço	9, 55, 70, 90, 101, 130, 144, 164	8
Localização do Sinal Digital	3, 4, 5, 149	4
Localização	14, 50, 192	3
Localização de Amigos	12, 44, 116	3
Local Visitado	63, 24	2
Rotas de Estradas e Ferrovias	158, 106	2
Localização do Táxi / veículo	163, 182	2
Localização das Fotos Capturadas	181	1
Região Geográfica	29	1
Trajetória de Taxi	163	1

Tabela B.5: Dados recomendados.

Categoria	Identificadores (IDs)	Quantitativo
Ponto de Interesse	1, 12, 15, 18, 19, 20, 21, 25, 26, 28, 30, 39, 44, 46, 50, 56, 57, 58, 61, 63, 65, 66, 67, 69, 74, 77, 79, 81, 82, 85, 86, 87, 88, 90, 91, 93, 95, 96, 98, 100, 102, 104, 109, 114, 115, 118, 120, 121, 122, 126, 127, 131, 133, 142, 143, 150, 151, 154, 155, 156, 157, 161, 166, 172, 177, 178, 180, 194, 116, 169	70
Localização	59, 105, 111, 125, 135, 136, 137, 152, 159, 162, 165, 167, 171, 173, 174, 175, 179, 181, 183, 184, 189, 191, 193, 197, 198	25
Serviço	3, 4, 5, 9, 47, 55, 70, 94, 101, 112, 130, 140, 144, 163, 164, 182, 190	17
Item	6, 10, 49, 53, 54, 62, 64, 83, 160, 168, 170, 176, 195	13
Local	11, 13, 17, 35, 37, 48, 51, 72, 75	9
Próximo Local	2, 22, 29, 31, 41, 76, 84, 145	8
Amigos	14, 36, 38, 52, 146, 185, 116	7
Música	27, 40, 123, 192	4
Local de Viagem	24, 113, 132, 134	4
Localização de Loja	8, 89, 92, 110	4
Grupo de Amigos	108, 153	2
Grupo de Ponto de Interesse	43, 78	2
Local de Coleta de Carona	68, 158	2
Localização de Hotel	73, 124	2
Localização de Restaurante	119, 138	2
Rota de Viagem	34, 148	2
Localização Personalizada	103, 117	2
Localização de Instalações	80, 129	2
Cliente	33	1
Compras Móveis	42	1
Conteúdos da Web	8	1
Cupom de Grupos para Produtos	186	1
Informações comerciais	188	1
Linha de ônibus	199	1
Marketing Móvel	139	1
Medicamentos de Livre Comércio	147	1
Notícias	7	1
Novos Usuários	23	1
Produtos e Serviços de Varejo	99	1
Publicidade	196	1
Seguidores	32	1
Estação de Trem	45	1
Local Candidato	16	1
Local para Grupo	187	1
Local Turístico	107	1
Localização de Empresas	97	1
Localização de Estação de Monitoramento de Qualidade do Ar	106	1
Localização de Instalação de Sinal Digital	149	1
Localização de um Ponto de Negócio	128	1
Localização em Redes de Transporte Dinâmica	141	1
Ponto para Instalar Restaurante	71	1
Rota	60	1

Tabela B.6: Abordagens de cálculo de distância por métricas espaciais.

Abordagem de Cálculo da Distância	Identificadores (IDs)	Quantitativo
Distância Euclidiana	11, 90, 100, 106, 116, 136, 138, 160, 164, 176, 188, 3, 10, 25, 43, 49, 53, 58, 64, 65, 66, 73, 74, 82, 85, 87, 88, 89, 91, 92, 93, 98, 99, 101, 110, 118, 119, 149, 181, 190, 2, 42, 71	43
Caminho mais Curto	34, 57, 60, 68, 72, 75, 76, 77, 86, 125, 1289, 140, 141, 143, 158, 171, 2, 42, 71	19
Distância de Haversine	14, 29, 31, 41, 79, 97, 121, 126, 130, 135, 155, 142	12
Método Gaussiano Multicêntrico	1, 44, 48, 56, 16, 180	6
Matriz de Proximidade Geográfica	22, 151	2
Equação Própria do Estudo	163	1
Cálculo do Centróides	197	1
Distância de Manhattan	170	1
Distância de Vincenty	39	1
Distância Ortodrômica	26	1

Tabela B.7: Abordagem de cálculo de distância por métricas não espaciais.

Abordagem de Cálculo da Distância	Identificadores (IDs)	Quantitativo
Por Similaridade	4, 5, 6, 7, 8, 9, 12, 15, 20, 23, 24, 28, 30, 32, 33, 36, 37, 38, 46, 47, 50, 52, 54, 55, 59, 61, 62, 63, 67, 69, 78, 80, 84, 94, 95, 96, 105, 107, 108, 111, 112, 113, 114, 123, 127, 131, 132, 137, 148, 150, 153, 156, 157, 169, 184, 186, 187, 191	58
Distância de Jaccard	21, 81, 124, 145, 192, 35, 154	7
Por Classificação do Usuário	13, 16, 19, 51, 120	5
Peso de Amostragem	102, 174	2
Distância de Bregman	162	1
Distância de Hamming	187	1
Distância de Kullback-Leibler	27	1
Distância de Leibler	194	1
Distorção Temporal Dinâmica	183	1
Função Vulcão	17	1
Lei de Potência Truncada	146	1
Limite de Hoeffding	193	1
Meta-caminho	122	1

Tabela B.8: Abordagens baseadas na interpretação de dados.

Abordagem Identificada	Identificadores (IDs)	Quantitativo
Análise ou Informação de Contexto	49, 99, 119, 126, 135, 174, 187, 192	8
Agregação Temporal	20, 22, 28, 59, 94, 169	6
Informações Multi-contexto	63, 132, 146, 153, 159	5
Preferência do Usuário	64, 95, 118, 144, 186	5
Otimização Multiobjetivo	62, 68, 166	3
Análise ou Informação de Emoções	123, 134	2
Comportamento do Usuário	120, 170	2
Não Identificado	92, 128	2
Propriedades Sociais	72, 143	2
Reconhecimento de Vizinhaça	29, 133	2
Reconhecimento Semântico	7, 125	2
Fator de Confiança	19, 61	2
Abordagem Multivisão	108	1
Acoplamento de Curva	183	1
Amostragem Negativa da Distância	102	1
Análise de Sentimentos	165	1
Categorização de POI	177	1
Comportamento Sequencial	139	1
Correlação Entre Redes Sociais	171	1
Corretor Adaptativo de Similaridade	4	1
Corretor de Localização	10	1
Credibilidade	190	1
Efeito de Ancoragem	44	1
Estruturas Hierárquicas	115	1
Força do Relacionamento do Usuário	58	1
Hierarquia Categórica	41	1
Hierarquia de Categoria Ponderada	184	1
Incorporação de Trajetória	145	1
Influência Mult-aspecto	154	1
Informação Multimodal	46	1
Interdependência Entre Grupos de Usuários	12	1
Matriz de Classificação	130	1
Modelagem de Tópicos	194	1
Modelo Tripartite de Localização-Consulta-Navegação	8	1
Multfatores	97	1
Ontologia	195	1
Otimização Multiobjetivo	56	1
Padrão de Movimento do Usuário	148	1
Particionamento de Usuário	2	1
Perfil do Usuário	182	1
Pontuação em Geo-tags	161	1
Preferência do Usuário e Uso de Texto	191	1
Previsão de Links	124	1
Processamento Paralelo de Trajetórias	84	1
Prompt Temporal e Geográfico	18	1
Reconhecimento de Localização	5	1
Relações de Amizade	189	1
Sensores Inteligentes	85	1
Similaridade Cognitiva	107	1
Subgrupo de itens	54	1

Tabela B.9: Abordagens baseadas em aprendizado e modelos avançados.

Abordagem Identificada	identificadores (IDs)	Quantitativo
Fatoração de Matriz	3, 25, 37, 70, 98, 111, 113, 117, 121, 150, 151, 155, 156, 168, 185, 197	16
Mineração de Dados	14, 16, 27, 32, 36, 40, 66, 71, 89	9
Clusters	47, 80, 116, 149, 160, 173, 175, 193	8
Grafo	21, 31, 81, 122, 129, 164, 172, 178	8
Filtragem Colaborativa	91, 105, 140, 142, 147, 188	6
Aprendizado de Máquina	53, 82, 103, 104, 167	5
Algoritmo Heurístico	34, 50, 78, 141	4
Estimativa de Densidade de Kernel	1, 48, 52, 136	4
Rede Neural	73, 79, 101	3
Método Fuzzy	43, 65, 138	3
Fatoração Tensorial	26, 112	2
Aprendizagem Contrastiva	57, 83	2
Aprendizado Profundo	74, 77	2
Kernel Gaussiano	39, 96	2
Modelo de Markov	114, 157	2
Modelo Generativo	35, 38	2
Passeio Aleatório	88, 137	2
Rede Neural Convolucional	86, 152	2
Realidade Aumentada	181, 198	2
Agrupamento k-Means	158	1
Algoritmo Genético	196	1
Algoritmo Spectral	87	1
Algoritmos Baseados em LZ	199	1
Algoritmos Inteligentes	131	1
Aprendizado de Métricas	23	1
Aprendizado Multitarefa	109	1
Árvores	42	1
Codificação de Grafos	11	1
Combinação de Grafos e Subgrafos	75	1
Combinação de Matrizes de Similaridade	6	1
Combinação Linear Ponderada	45	1
Conclusão de Matriz	162	1
Decomposição Tensor	15	1
Diagrama de Voronoi	110	1
Fatoração Tensorial e Passeio Aleatório	100	1
Função Vulcão	17	1
Fusão de Matriz	127	1
Híbrido (FC, BC, BCX e Rede Neural)	24	1
Mineração de Sequência	60	1
Mineração Incremental	67	1
Modelo de Máquina Vetorial e Árvore	163	1
Modelo de Recuperação Colaborativa	30	1
Modelo Híbrido	55	1
Modelo Skip-gram	179	1
Não Identificado	9	1
Ponderação Espacial do Kernel	93	1
Rede de Informação Heterogênea (HIN)	13	1
Rede Neural Convolucional e Grafos	106	1
Rede Neural Convolucional Profunda	90	1
Rede Neural e Grafos	76	1
Representações de Codificadores	69	1
Tensor	176	1
Transformadora Rápida de Gauss	180	1
Treinamento Adversário	33	1
Vetor de Suporte de Máquinas	51	1

Tabela B.10: Abordagens de avaliação utilizadas nos experimento

Técnica Identificada	Identificadores (IDs)	Quantitativo
Baseline	1, 2, 3, 4, 5, 6, 7, 8, 9, 11, 13, 15, 16, 17, 18, 19, 20, 21, 22, 23, 24, 25, 26, 27, 28, 29, 30, 31, 32, 33, 34, 35, 36, 37, 38, 39, 40, 41, 43, 44, 46, 48, 50, 51, 52, 53, 54, 55, 56, 57, 58, 59, 61, 62, 63, 65, 66, 67, 68, 69, 70, 72, 73, 74, 75, 76, 79, 81, 82, 83, 84, 85, 86, 87, 88, 90, 91, 93, 95, 96, 97, 98, 100, 102, 103, 105, 106, 108, 109, 111, 112, 113, 114, 115, 116, 117, 118, 120, 121, 122, 124, 125, 126, 127, 128, 130, 131, 132, 133, 135, 136, 137, 138, 139, 141, 142, 143, 144, 145, 146, 147, 148, 149, 150, 151, 152, 153, 154, 155, 156, 157, 159, 160, 162, 163, 164, 165, 166, 168, 171, 172, 173, 174, 175, 176, 177, 178, 179, 180, 182, 183, 184, 185, 186, 187, 188, 189, 191, 192, 193, 194, 196, 198	163
Simulação	10, 12, 42, 49, 60, 64, 77, 78, 92, 94, 104, 119, 134, 140, 158, 161, 169, 170, 190, 195, 199	21
Estudo de Caso	42, 45, 47, 71, 80, 89, 99, 101, 107, 110, 123, 129, 167, 181, 197	15
Teste A/B	14	1