UNIVERSIDADE DE SÃO PAULO

Instituto de Ciências Matemáticas e de Computação

Geração de recomendações interpretáveis em sistemas de recomendação utilizando contexto

Vítor Rodrigues Tonon

Dissertação de Mestrado do Programa de Pós-Graduação em Ciências de Computação e Matemática Computacional (PPG-C²MC)

SERVIÇO DE PÓS-GRADUAÇÃO DO ICMC-USP

Data de Depósito:

Assinatura: _____

Vítor Rodrigues Tonon

Geração de recomendações interpretáveis em sistemas de recomendação utilizando contexto

Dissertação apresentada ao Instituto de Ciências Matemáticas e de Computação – ICMC-USP, como parte dos requisitos para obtenção do título de Mestre em Ciências – Ciências de Computação e Matemática Computacional. *VERSÃO REVISADA*

Área de Concentração: Ciências de Computação e Matemática Computacional

Orientadora: Profa. Dra. Solange Oliveira Rezende

USP – São Carlos
Maio de 2021

Ficha catalográfica elaborada pela Biblioteca Prof. Achille Bassi
e Seção Técnica de Informática, ICMC/USP,
com os dados inseridos pelo(a) autor(a)

R696g Rodrigues Tonon, Vitor
 Geração de recomendações interpretáveis em
 sistemas de recomendação utilizando contexto / Vitor
 Rodrigues Tonon; orientadora Solange Oliveira
 Rezende. -- São Carlos, 2021.
 158 p.

 Dissertação (Mestrado - Programa de Pós-Graduação
 em Ciências de Computação e Matemática
 Computacional) -- Instituto de Ciências Matemáticas
 e de Computação, Universidade de São Paulo, 2021.

 1. Sistemas de Recomendação. 2. Redes
 Heterogêneas. 3. Interpretabilidade. 4. Informação
 Contextual. I. Oliveira Rezende, Solange, orient.
 II. Título.

Vítor Rodrigues Tonon

Generating interpretable recommendations in recommender systems using context.

Dissertation submitted to the Institute of Mathematics and Computer Sciences – ICMC-USP, in accordance with the requirements of the Computer and Mathematical Sciences Graduate Program, for the degree of Master in Science. *FINAL VERSION*

Concentration Area: Computer Science and Computational Mathematics

Advisor: Profa. Dra. Solange Oliveira Rezende

USP – São Carlos
May 2021

*Dedico este trabalho à Hope e ao Marvin,
meus filhos de quatro patas.*

Agradecimentos

Primeiramente, gostaria de agradecer aos meus pais, Sandra e Renato, por todo o amor, carinho, apoio e suporte prestados a mim, do momento em que eu nasci até este momento. Obrigado por entenderem todas as vezes que não estive disponível ou que não pude lhes a atenção que mereciam. Sei que vocês abdicaram muito para que eu pudesse me dedicar aos estudos, e agradeço por terem aberto todas as portas nesse sentido. Se hoje eu estou aqui, devo tudo a vocês.

Agradeço também à minha irmã, Carol, pelo apoio e companheirismo que sempre tivemos. Sempre fomos muito próximos um do outro, e acredito que isso contribuiu muito para que eu me tornasse quem eu sou hoje. Por mais que os compromissos e as correrias do dia-a-dia nos tenham afastado um pouco, conte comigo para o que for preciso. Sua enorme dedicação aos seus objetivos, serviram como inspiração para mim.

Estendo meus agradecimentos a todos os outros familiares que estiverem presentes durante o meu crescimento e formação. Em especial, gostaria de agradecer à minha tia Madalena, que com seu jeito único de ser, sempre me fez sentir muito amado. Os cafés da tarde e tantas conversas serviram como um refugio às preocupações da pós-graduação. Além disso, gostaria de agradecer ao meu tio Márcio e a sua esposa, Érika, que também sempre estiveram comigo, desde a minha infância até os dias de hoje.

Não poderia deixar de agradecer à Prof.^a Solange, que foi muito mais que uma orientadora. Desde o primeiro contato que tivemos, sempre buscou a minha evolução como pessoa, e não apenas a minha evolução acadêmica. Na minha opinião, isso é muito mais do que eu poderia desejar. Obrigado por toda a amizade, compreensão e por toda a mentoria que você me proporcionou. Não poderia ter escolhido alguém melhor para me ajudar a trilhar esse caminho.

Agradeço também a todos os amigos e colegas que me acompanharam nessa jornada. Em especial, gostaria de agradecer ao Pedro por toda amizade e por todas as vezes que me aconselhou e ajudou na escrita desta dissertação. Sua dedicação ao seu sonho, me serviu de inspiração e me deu forças para continuar quando certas coisas já não faziam mais sentido. À Camila, que desde o período da IC, me auxiliou no mundo acadêmico, bem como na área de sistemas de recomendação. À Cintia e Daniele por toda amizade e todas as vezes que estiveram disponíveis para me ouvir reclamar dos problemas. Enfim, agradeço a todos vocês, e também à Fran, Ricardo e Roberta, por terem tornado esse período mais leve e por todas as sugestões valiosas para o meu trabalho. Sem vocês,

provavelmente esse sonho não estaria se realizando.

Por fim, gostaria de agradecer ao CNPq (Processo nº 132754/2018-5) e à FAPESP e CAPES pelo apoio financeiro durante os dois primeiros anos deste mestrado (Processo FAPESP nº 2018/04651-0, Fundação de Amparo à Pesquisa do Estado de São Paulo). Por último, e não menos importante, gostaria de agradecer também a todas as pessoas que em algum momento acreditaram no meu potencial. Em especial, agradeço ao Junior, por ter me dado a oportunidade do meu primeiro emprego, e por todo o cuidado e ensinamentos no período em que estive sob sua mentoria.

*“Por vezes sentimos que aquilo que fazemos
não é senão uma gota de água no mar.
Mas o mar seria menor se lhe faltasse uma gota.”
(Madre Teresa de Calcuta)*

Resumo

TONON, V. R. **Geração de recomendações interpretáveis em sistemas de recomendação utilizando contexto**. 2021. 158 p. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2021.

Usuários enfrentam dificuldades em escolher produtos e serviços na Web devido a grande variedade de possibilidades de escolha. Nesse contexto, os sistemas de recomendação têm como objetivo auxiliar indivíduos a identificarem itens de interesse em um conjunto de opções. As abordagens tradicionais de sistemas de recomendação focam em recomendar itens mais relevantes para usuários individuais, não levando em consideração o contexto dos usuários. Porém, em muitas aplicações reais, é importante também considerar informações contextuais, por meio dos sistemas de recomendação sensíveis ao contexto, uma vez que estudos indicam que o uso de tais informações pode melhorar a acurácia das recomendações. Existem diversos tipos de sistemas de recomendação, como os baseados em conteúdo, na vizinhança de usuários e itens, baseados em fatoração de matrizes e em deep learning. No entanto, a maioria desses sistemas são considerados caixas-pretas, já que não oferecem transparência ao processo de recomendação, o que dificulta que usuários confiem nas recomendações apresentadas. Nesse sentido, fornecer recomendações interpretáveis tende a aumentar a confiança e a satisfação do usuário em relação ao sistema. O uso de explicações em sistemas de recomendação tem se mostrado uma área de pesquisa promissora, mas, ainda assim, poucos trabalhos exploraram a utilização de contexto como forma de gerar as explicações. Diante desse cenário, este projeto tem como objetivo propor o método **HINCARS** que gera recomendações interpretáveis utilizando informações contextuais. Os resultados obtidos mostraram que o método obteve resultados equiparáveis a um algoritmo estado-da-arte.

Palavras-chave: Sistemas de Recomendação, Redes Heterogêneas, Interpretabilidade, Informação Contextual.

Abstract

TONON, V. R. **Generating interpretable recommendations in recommender systems using context..** 2021. 158 p. Dissertação (Mestrado em Ciências – Ciências de Computação e Matemática Computacional) – Instituto de Ciências Matemáticas e de Computação, Universidade de São Paulo, São Carlos – SP, 2021.

Users face difficulties in choosing products and services on the Web because of the wide range of options. In this context, recommendation systems aim to assist users in identifying items of interest within a set of options. Traditional approaches to recommender systems focus on recommending more relevant items to individual users, not taking into account users' context. However, in many real-world applications, it is also important to consider contextual information through the use of context-aware recommender systems. Several studies have indicated that using such information can improve the accuracy of recommendations. There are various types of recommendation systems, such as content-based, neighborhood-based, matrix factorization and deep-learning-based systems. However, most of these systems are considered black boxes, since they do not offer transparency to the recommendation process, which makes it difficult for users to trust the recommendations that are presented to them. In this sense, providing interpretable recommendations tends to increase user confidence and satisfaction with the system. The use of explanations in recommendation systems has shown to be a promising area of research, but only a few works have explored the use of context as a way of generating explanations. Given this scenario, this project aims to propose a method that generates interpretable recommendations using contextual information. The obtained results showed that ***HINCARS*** had similar performance than a state-of-the-art recommendation method.

Keywords: Recommender Systems, Heterogeneous Network, Interpretability, Contextual Information.

Lista de ilustrações

Figura 1 – Exemplo de uma rede heterogênea de recomendação, utilizando dados de um serviço de <i>streaming</i> de filmes	10
Figura 2 – Categorias dos sistemas de recomendação tradicionais	12
Figura 3 – Exemplo de rede heterogênea com três tipos de nós (U, I e C). Inicialmente, há dois nós rotulados: U_3 , que possui a classe vermelha; e C_1 , que possui a classe amarela. O algoritmo <i>GNetMine</i> faz a propagação dos rótulos para todos os outros nós da rede.	19
Figura 4 – Exemplo de como o processo de recomendação é feito a partir da rede parcialmente rotulada e de uma abordagem baseada em propagação de rótulos.	20
Figura 5 – Categorias dos sistemas de recomendação sensíveis ao contexto.	24
Figura 6 – O tipo de explicação que gerou as melhores avaliações no trabalho de Herlocker <i>et al.</i> (2000)	27
Figura 7 – Grafo de relacionamentos entre os trabalhos identificados na literatura e a sua organização em grupos de tópicos. Cada trabalho é representado por um nó e o número de cada nó corresponde ao <i>ID</i> do trabalho na Tabela 5. Dois trabalhos similares estão conectados por uma aresta. As cores definem grupos de trabalhos.	35
Figura 8 – Visão geral da proposta deste mestrado: um método para geração de recomendações interpretáveis utilizando informações contextuais e redes heterogêneas	46
Figura 9 – Esquemático da rede heterogênea proposta para a Abordagem N-Partida . Ligações entre entidades de diferentes tipos: usuário-item (preto), usuário-contexto C_i (vermelho), usuário-contexto C_j (verde), item-contexto C_i (amarelo) e item-context C_j (azul).	50
Figura 10 – Esquemático da rede heterogênea proposta para a Abordagem Heterogênea Usuários . Além das ligações entre entidades de diferentes tipos, existem ligações entre usuários similares (em roxo).	51
Figura 11 – Esquemático da rede heterogênea proposta para a Abordagem Heterogênea Itens . Além das ligações entre entidades de diferentes tipos, existem ligações entre itens similares (em vermelho).	52

Figura 12 – Esquemático da rede heterogênea proposta para a Abordagem Completa . Além das ligações entre entidades de diferentes tipos, existem ligações entre usuários e itens similares (em roxo e vermelho, respectivamente) e também entre diferentes dimensões contextuais (em verde).	53
Figura 13 – Matrizes de informação prévia para os dados de exemplo considerando cada uma das abordagens. Só são exibidas as matrizes de informação prévia dos tipos definidas na abordagem. As matrizes para os outros tipos são todas zero.	56
Figura 14 – Exemplo de matrizes de confianças estimadas pelo algoritmo <i>GNetMine</i>	58
Figura 15 – Esquemático do processo de avaliação experimental realizado neste trabalho de mestrado	68
Figura 16 – Frequência com que cada configuração experimental gerou resultados estatisticamente equivalentes ou superiores ao <i>baseline</i>	70
Figura 17 – Frequência com que cada abordagem utilizada para construção da rede heterogênea gerou resultados estaticamente iguais ou superiores ao <i>baseline</i>	71
Figura 18 – Para cada configuração experimental, é apresentada a frequência com que as abordagens utilizadas para construção da rede heterogênea geraram resultados estaticamente iguais ou superiores ao <i>baseline</i>	72
Figura 19 – Frequência com que cada vetor de pesos considerado gerou resultados estatisticamente iguais ou superiores ao <i>baseline</i>	73
Figura 20 – Frequência com que as diferentes taxas de usuários similares consideradas geraram resultados estatisticamente iguais ou superiores ao <i>baseline</i> .	74

Lista de tabelas

Tabela 1 – Exemplo de dados de recomendação modelados na representação Espaço-Vetorial	8
Tabela 2 – Exemplo de dados de recomendação bidimensionais modelados na representação Espaço-Vetorial como uma matriz de avaliações	9
Tabela 3 – Exemplo de atributos para os itens da Tabela 2	13
Tabela 4 – Matriz de similaridades para os atributos dos itens apresentados na Tabela 2	14
Tabela 5 – Síntese de trabalhos relacionados e algumas características	34
Tabela 6 – Dados-exemplo de interação de usuários para recomendações de carros em serviços de aluguel de automóveis	53
Tabela 7 – Dados-exemplo de interação de usuários para recomendações em serviços de <i>streaming</i> de filmes	55
Tabela 8 – Resultados da métrica MAP para a base de dados <i>DePaul Movie</i> utilizando o <i>baseline</i> (<i>TriRank</i>)	65
Tabela 9 – Descrição das configurações experimentais realizadas, considerando a importância atribuída à premissa de consistência e de informação prévia.	66
Tabela 10 – Resultados obtidos pelo método HINCARS que foram estatisticamente iguais ou superiores ao <i>baseline</i>	69
Tabela 11 – Resultados de todos os experimentos realizados	91

1	Introdução	1
1.1	Contextualização e Motivação	1
1.2	Questões de Pesquisa e Objetivos	3
1.3	Principais Resultados	4
1.4	Organização	5
2	Fundamentação Téorica	7
2.1	Modelos de Representação dos Dados de Recomendação	8
2.1.1	Modelo Espaço-Vetorial	8
2.1.2	Redes Heterogêneas	9
2.2	Sistemas de Recomendação Tradicionais	11
2.2.1	Filtragem baseada em conteúdo	12
2.2.1.1	Abordagem baseada nos K-vizinhos mais próximos	13
2.2.1.2	Outras Abordagens	15
2.2.2	Filtragem colaborativa	15
2.2.2.1	Abordagens baseadas em vizinhança	16
2.2.2.1.1	Abordagem baseada em usuários/itens similares	16
2.2.2.1.2	Abordagem baseada em propagação de rótulos	17
2.2.2.2	Abordagens baseadas em modelo	21
2.2.2.2.1	Abordagem baseada em fatoração de matrizes	21
2.2.2.2.2	Outras Abordagens	23
2.3	Sistemas de Recomendação Sensíveis ao Contexto	24
2.4	Explicações em Sistemas de Recomendação	25
2.5	Métodos de Avaliação dos Sistemas de Recomendação	28
2.5.1	Métricas de acurácia para predição de avaliações	29
2.5.2	Métricas de acurácia para ranqueamento de itens	29
2.6	Considerações Finais	30
3	Trabalhos Relacionados	33
3.1	Utilização de contexto para geração de explicações	36
3.2	Utilização de redes heterogêneas para modelagem do problema de recomendação	37
3.3	Utilização de outras técnicas para geração e visualização de explicações	40
3.4	Considerações Finais	43
4	HINCARS: Um Método para Geração de Recomendações Interpretáveis Utilizando Contexto e Redes Heterogêneas	45

4.1	Cálculo de Similaridade	47
4.1.1	Similaridade entre usuários	48
4.1.2	Similaridade entre itens	48
4.2	Construção da Rede Heterogênea	49
4.2.1	Abordagem N-Partida	49
4.2.2	Abordagem Heterogênea Usuários	51
4.2.3	Abordagem Heterogênea Itens	52
4.2.4	Abordagem Completa	52
4.3	Geração das Recomendações	54
4.3.1	Abordagens para definição das matrizes de informação prévia	55
4.3.2	Propagação dos rótulos pelo <i>GNetMine</i>	57
4.3.3	Abordagens para o ranqueamento dos itens	57
4.4	Interpretabilidade das recomendações e possíveis explicações	59
4.5	Considerações Finais	60
5	Avaliação Experimental	61
5.1	Escopo da avaliação	61
5.2	Configuração Experimental	62
5.2.1	Bases de dados utilizadas	62
5.2.2	Protocolo de avaliação	63
5.3	Resultados do <i>Baseline</i> (<i>TriRank</i>)	63
5.4	Descrição dos Experimentos Realizados	65
5.5	Resultados e Discussão	67
5.6	Considerações Finais	73
6	Conclusões	77
6.1	Contribuições Científicas	77
6.2	Publicações	79
6.2.1	Artigos publicados em periódicos	79
6.2.2	Capítulos de livro publicados	79
6.2.3	Artigos publicados em conferências	80
6.3	Limitações e Trabalhos Futuros	81
	Referências	83
	APÊNDICE A Resultados do método <i>HINCARS</i>	91

Introdução

1.1 Contextualização e Motivação

A quantidade de dados e informações disponíveis na Web é abundante e consumidores encontram grande variedade de produtos, serviços, notícias e filmes disponíveis. Essa situação faz com que eles encontrem dificuldade em identificar e escolher os itens que melhor satisfazem ao que estão buscando. Uma pesquisa de mercado, realizada pela *Netflix*¹, sugere que um membro usual perde interesse no serviço após ter analisado de 10 a 20 títulos do seu catálogo de filmes e séries (GOMEZ-URIBE; HUNT, 2015). Buscando amenizar ou até mesmo eliminar essa dificuldade, existem os sistemas de recomendação, que são uma tecnologia de filtragem de informação que busca prover sugestões de itens a seus usuários, considerando tanto o histórico de interações do usuário com o sistema como também outras informações que possam estar disponíveis, como as fichas técnicas dos itens e/ou o perfil demográfico do usuário (AGGARWAL, 2016).

As vantagens em se utilizar um sistema de recomendação são inúmeras, e podem ser vistas tanto sob a perspectiva do usuário quanto a do vendedor/provedor de conteúdo. Para o usuário, boas recomendações permitem que itens de interesse sejam encontrados com maior facilidade. Para o vendedor/provedor de conteúdo, por sua vez, boas recomendações possibilitam o aumento do volume de vendas e do lucro obtido, uma vez que elas trazem itens relevantes à atenção dos usuários. Dessa forma, esses sistemas têm se tornado partes intrínsecas das empresas, como *Netflix*, *Amazon*², *Google*³. Muito mais do que a simples recomendação dos itens a serem consumidos, vários aspectos da experiência do usuário são considerados pelos sistemas de recomendação dessas empresas. No caso da *Netflix*, por exemplo, até mesmo as imagens das séries e filmes que são exibidas são

¹ www.netflix.com

² www.amazon.com

³ www.google.com

personalizadas de acordo com as preferências dos usuários (NELSON, 2016).

Outros aspectos que também influenciam a preferência de um usuário e, portanto, podem ser considerados pelos sistemas de recomendação são as informações contextuais (ADOMAVICIUS; TUZHILIN, 2011; RAZA; DING, 2019; RENJITH *et al.*, 2020; YUAN *et al.*, 2020; ALI *et al.*, 2020). Segundo Dey (2001), “*contexto é qualquer informação que pode ser usada para caracterizar a situação de uma entidade*”, sendo esta entidade qualquer pessoa, local ou objeto relevantes para interação entre um usuário e uma aplicação. Assim, em muitas aplicações é importante incorporar informação contextual dentro do processo de recomendação. Por exemplo, em recomendações de restaurantes, o usuário pode preferir churrascarias no almoço e pizzarias no jantar; ou ainda, preferir sorveterias no verão e restaurantes com comidas quentes no inverno.

Pesquisadores começaram a perceber que é possível aumentar a qualidade das recomendações quando essas informações adicionais, como tempo, local e outros, são utilizadas (ADOMAVICIUS *et al.*, 2005; LI *et al.*, 2010; ADOMAVICIUS; TUZHILIN, 2011; HARIRI *et al.*, 2011). Pesquisas recentes indicaram que o uso do contexto em sistemas de recomendação pode aumentar a confiança do usuário (GORGOGNONE *et al.*, 2011) e fornecer recomendações mais precisas, superando as abordagens tradicionais (KARATZOGLOU *et al.*, 2010; DOMINGUES *et al.*, 2014; SUNDERMANN *et al.*, 2019), que utilizam apenas as informações de usuários e itens. Nesse cenário, um sistema de recomendação sensível ao contexto é uma tecnologia de filtragem de informação que, além do comportamento e do interesse do usuário, utiliza também informação contextual para recomendar itens que lhe são de interesse.

Como as recomendações geradas pelos sistemas tradicionais e sensíveis ao contexto podem ter grande impacto na satisfação do usuário e no volume de vendas ou de utilização dos produtos e serviços (AGGARWAL, 2016), o processo de avaliação dessas recomendações é crucial na tarefa de recomendação. No entanto, nesse processo, a maioria dos trabalhos (KOREN *et al.*, 2009; KARATZOGLOU *et al.*, 2010; SUNDERMANN *et al.*, 2016; YUAN *et al.*, 2020) utiliza apenas métricas como acurácia, precisão e revocação, de tal forma que algoritmos de recomendação considerados hoje estado-da-arte, muitas vezes, funcionam como caixas-pretas, não justificando os motivos pelos quais as recomendações foram geradas.

Mesmo assim, um grande número de trabalhos da área de Aprendizado de Máquina (HOLZINGER, 2018; SAMEK, 2019; BERTOSSI; GEERTS, 2020) e da área de Sistemas de Recomendação (TINTAREV; MASTHOFF, 2007; ZANKER; NINAUS, 2010; LAMCHE *et al.*, 2014; BARAL *et al.*, 2018), já demonstraram a importância de agregar interpretabilidade aos modelos aprendidos. Segundo esses pesquisadores, no caso dos sistemas de recomendação, quando o usuário entende por que um dado item está sendo recomendado, ele se torna mais receptivo às recomendações que lhe são apresentadas.

Isso, portanto, aumenta a probabilidade dele consumir o item recomendado, o que vai ao encontro dos objetivos dos sistemas de recomendação. Nesse sentido, sistemas como a *Netflix*, por exemplo, exibem informações adicionais junto com os itens recomendados, como “*Porque você viu o filme X, pode se interessar também pelos filmes a seguir*”, que explicitam, pelo menos em parte, o raciocínio por trás do processo de recomendação.

Porém, todos os trabalhos identificados na literatura que agregam interpretabilidade aos seus modelos ou que geram explicações para as recomendações produzidas ou não consideram a informação contextual (ZHANG *et al.*, 2014; WANG *et al.*, 2016; CHEN *et al.*, 2016; ABDOLLAHI; NASRAOUI, 2017), ou não apresentaram bons resultados em razão de limitações no método adotado (SATO *et al.*, 2018). Explicações que utilizam informações contextuais podem sugerir contextos aos itens recomendados, como no seguinte exemplo: “*O filme Harry Potter é adequado para ser visto **com a família***”, em que a informação contextual nesse caso indica a companhia adequada com quem o usuário deve ver o filme em questão. Dessa forma, é de extrema relevância explorar a utilização da informação contextual nesse processo, pois ao considerar a situação atual do usuário ao gerar as recomendações, é possível que recomendações e explicações ainda mais personalizadas sejam geradas.

Nesse cenário, existem diferentes entidades (usuários, itens e contextos) que se relacionam entre si, o que torna necessário entender a influência que cada uma delas exerce sobre as outras e sobre o processo de recomendação como um todo. Diante disso, escolher um modelo de representação de dados para o sistema que considere explicitamente todas as interações existentes entre essas entidades pode possibilitar que melhores recomendações sejam geradas e, além disso, pode agregar semântica ao processo, que é de extrema importância para a interpretabilidade do modelo aprendido. Dessa forma, a escolha adequada desse modelo de representação tem grande impacto na performance final dos sistemas de recomendação, porque pode influenciar a qualidade das recomendações e explicações produzidas (PHAM *et al.*, 2016). Na seção seguinte são apresentadas as questões de pesquisa e os objetivos deste trabalho de mestrado.

1.2 Questões de Pesquisa e Objetivos

Diante deste cenário, este mestrado foi guiado a fim de desenvolver um método para geração de recomendações interpretáveis utilizando contexto. Para isso, foram definidas as seguinte questões de pesquisa responder questões de pesquisa.

- Q1** É possível agregar em uma única representação de dados as diferentes entidades envolvidas na tarefa de recomendação (usuários, itens e contextos), de tal forma que o modelo de recomendação produzido seja interpretável?

- Q2** A agregação dessas diferentes entidades em uma única representação de dados leva a recomendações com acurácia igual ou superior a de outros métodos de recomendação considerados estado-da-arte?

De acordo com as questões de pesquisa estabelecidas, foram definidos os seguintes objetivos para o desenvolvimento deste trabalho.

- O1** Pesquisar e explorar modelos de representação que possibilitem agregar diferentes entidades no processo de recomendação (usuários, itens e informações contextuais). Esse objetivo está relacionado à questão de pesquisa **Q1**.
- O2** Pesquisar e explorar métodos que geram recomendações interpretáveis, utilizando algoritmos tradicionais e sensíveis ao contexto. Esse objetivo está relacionado a questão de pesquisa **Q1**.
- O3** Propor e desenvolver um método que, utilizando dados de usuários, itens e informações contextuais, gere recomendações de uma maneira transparente, possibilitando a interpretabilidade do processo de recomendação. Esse objetivo está relacionado às questões de pesquisa **Q1** e **Q2**.
- O4** Avaliar o método proposto, utilizando bases de dados reais, para verificar se houve melhoria na acurácia das recomendações. Esse objetivo está relacionado à questão de pesquisa **Q2**.

1.3 Principais Resultados

Os principais resultados obtidos com o desenvolvimento deste trabalho de mestrado são apresentados a seguir:

- R1** Exploração e análise dos principais trabalhos que buscam gerar recomendações interpretáveis. Este resultado atende aos objetivos **O1** e **O2**.
- R2** Proposta, desenvolvimento e avaliação do método **HINCARS** (*Heterogeneous Information Network for Context-Aware Recommender Systems*), que gera recomendações interpretáveis utilizando não só informações de usuários e itens, como também de quaisquer outras informações disponíveis no processo de recomendação (como contextos, aspectos, etc). Este resultado atende ao objetivo **O3**.
- R3** Avaliação experimental do método proposto, que foi instanciado para três diferentes tipos de entidades: usuários, itens e contextos. Foi considerada uma base de dados real nesse processo: *Depaul Movie* (ZHENG *et al.*, 2015). Este resultado atende ao objetivo **O4**.

1.4 Organização

O restante desta dissertação está organizado da seguinte maneira. No Capítulo 2, serão apresentados os conceitos essenciais para o entendimento deste trabalho, como sistemas de recomendação, tradicionais e sensíveis ao contexto, bem como os modelos de representação de dados utilizados nesse processo. No Capítulo 3, serão apresentados os principais trabalhos que buscam gerar modelos de recomendação interpretáveis, utilizando, para isso, não só informações de usuários, itens e contextos, mas também de outros aspectos/entidades envolvidos no processo de recomendação. No Capítulo 4, por sua vez, será apresentado o método proposto neste trabalho, **HINCARS**, que gera recomendações interpretáveis, utilizando informações de usuários, itens e contextos. No Capítulo 5, será apresentada a avaliação experimental realizada para validar o método proposto, bem como os principais resultados obtidos. Por fim, no Capítulo 6, serão apresentadas as principais contribuições deste trabalho, bem como as publicações originadas dele. Finalmente, serão sintetizadas algumas limitações e direções para trabalhos futuros.

Fundamentação Téorica

Como mencionado anteriormente, nos últimos anos, houve um desenvolvimento massivo dos serviços e tecnologias de informação, que geram uma quantidade abundante de dados. Diante disso, consumidores encontram dificuldade em identificar os produtos e serviços que melhor atendem às suas necessidades. Os sistemas de recomendação surgem com o propósito de mitigar esse problema, e consistem em um conjunto de técnicas cujo objetivo é prever e recomendar itens que os usuários podem gostar.

Ao utilizar um sistema de informação, mesmo sem perceber, os usuários estão fornecendo ao provedor de conteúdo/serviço diversos tipos de dados que podem posteriormente ser utilizados em sistemas de recomendação. Ao navegar em um site buscando um determinado calçado, por exemplo, o usuário passa o *mouse* sobre itens, clica em diferentes produtos e adiciona alguns deles ao seu carrinho. Todas essas informações podem ser utilizadas para prever a sua preferência pelos itens que lhe foram apresentados. Passar o mouse sobre um produto e ficar um tempo sobre ele, por exemplo, pode indicar que o usuário está analisando as suas diferentes características, ao passo que, em muitos outros itens, ele sequer parou de rolar a página. De maneira similar, adicionar um item ao seu carrinho pode significar que o usuário está realmente considerando comprar aquele produto, ao invés de estar somente analisando suas especificações técnicas, como quando clica em um determinado item.

Nesses casos apresentados, o sistema coleta implicitamente dados que podem ser usados como indicativos da preferência do usuário. Em outros casos, por sua vez, o usuário fornece diretamente as informações de preferência, atribuindo uma nota aos itens já consumidos. Todas essas informações podem ser denominadas avaliações (ou *ratings*), e são a fonte primária de informação dos sistemas de recomendação (AGGARWAL, 2016). No entanto, a maioria dos sistemas de recomendação recentes já utiliza também outras fontes de informação externa, como revisões de usuários na forma de textos, informação contextual e imagens (BARAL *et al.*, 2018; SATO *et al.*, 2018; ABBAS; ALAM, 2019; CHENG

et al., 2019; TONON *et al.*, 2019; BLANCO-MALLO *et al.*, 2020; SUNDERMANN *et al.*, 2020). Na seção seguinte, serão apresentados como todos esses dados/informações podem ser modelados nos sistemas de recomendação.

2.1 Modelos de Representação dos Dados de Recomendação

Os sistemas de recomendação podem ser modelados de duas formas principais (SHI *et al.*, 2017; PHAM *et al.*, 2016): **Modelo Espaço-Vetorial** e **Redes Heterogêneas**. No Modelo Espaço-Vetorial, os dados de recomendação são representados por meio do conceito de instâncias e atributos do aprendizado de máquina; isto é, cada usuário é visto como uma instância do problema de recomendação, e os itens são os seus atributos. Por sua vez, no Modelo de Redes Heterogêneas, os usuários e itens são objetos de uma rede, cujo relacionamento é dado pela avaliação desse usuário ao item em questão. Cada um desses modelos de representação dos dados serão descritos detalhadamente nas seções seguintes.

2.1.1 Modelo Espaço-Vetorial

No Modelo Espaço-Vetorial, os dados de preferência do usuário são modelados como uma tabela, com instâncias e atributos. Mais especificamente, cada instância representa uma avaliação para um dado usuário e item. Caso existam informações adicionais, como contexto ou características extraídas dos textos e imagens, elas são modeladas como atributos adicionais. Na Tabela 1, é apresentado um exemplo esquematizando esse tipo de modelagem.

Tabela 1 – Exemplo de dados de recomendação modelados na representação Espaço-Vetorial

Usuário	Item	Local	...	Sentimento	...	Categoria	...	Avaliação
João	Homem de Ferro	Em casa		Neutro		Super-Herói		3
Camila	Harry Potter	Cinema		Positivo		Bruxo		5
...	...	...	...	...	...	...	...	...

Fonte: Elaborada pelo autor.

No exemplo apresentado, além das informações de usuário e item, há também algumas informações adicionais, como o contexto no qual o item foi consumido (*Local*), o sentimento geral inferido a partir do texto opinativo que o usuário escreveu (*Sentimento*), e a categoria inferida a partir da imagem do filme (*Categoria*). Além disso, há um valor numérico (*Avaliação*), que indica o grau de preferência do usuário pelo item em questão. Informações adicionais que existam no processo de recomendação estão representadas pelo símbolo de reticências.

A tarefa de recomendação, quando vista sob a perspectiva dessa representação de dados, pode ser considerada como um problema de classificação/regressão. Se o atributo *Avaliação* for categórico, como *Recomendar/Não-Recomendar* ou *Péssimo/Ruim/Neutro/Bom/Muito Bom*, recomendar itens resume-se à predição desses rótulos, seguida da identificação dos itens classificados de forma positiva (*Recomendar* ou *Bom/Muito Bom*). Por outro lado, se o atributo *Avaliação* for numérico, como no caso do exemplo da Tabela 1, a tarefa de recomendação consiste em prever um valor numérico de preferência, seguida da identificação das instâncias com maior valor.

Quando os dados são bidimensionais, ou seja, existem apenas as informações de usuários e itens, eles podem ser modelados como uma matriz de avaliações (SHAPIRA *et al.*, 2011; AGGARWAL, 2016). Na Tabela 2, é apresentado um exemplo dessa representação. Nesse caso, cada entrada $R_{i,j}$ da matriz de avaliações representa a preferência do usuário i pelo item j . No exemplo, *João* tem preferência cinco por *Homem de Ferro*, e preferência um por *Harry Potter*, o que indica que ele gostou mais do primeiro filme do que do segundo.

Tabela 2 – Exemplo de dados de recomendação bidimensionais modelados na representação Espaço-Vetorial como uma matriz de avaliações

	Homem de Ferro	Harry Potter	Rei Leão	Vingadores
João	5	1		
Marcos	1		4	2

Fonte: Elaborada pelo autor.

Nesse caso, a tarefa de recomendação consiste em prever o valor das entradas desconhecidas da matriz de avaliações. Subsequentemente, pode-se identificar os itens com maior valor predito, para recomendá-los. No caso do exemplo apresentado na Tabela 2, para recomendar itens para *João*, seria preciso prever o valor da sua preferência para os filmes *Rei Leão* e *Vingadores*. Então, o item com maior valor seria recomendado.

2.1.2 Redes Heterogêneas

De acordo com Newman (2010), “uma rede, em sua forma mais simples, é uma coleção de pontos, que estão conectados em pares por linhas”. Na computação, esses pontos são denominados **nós** ou **vértices** e as linhas são denominadas **arestas** ou **links**. As redes podem ser utilizadas para representar uma grande variedade de sistemas, tais como (NEWMAN, 2010): a Internet, que consiste em um conjunto de computadores interligados (**rede tecnológica**); a sociedade, que consiste em uma coleção de pessoas interligadas por interações sociais (**rede social**); elementos biológicos que interagem entre si (**redes biológicas**); ou dados que de alguma forma se relacionam ou que permitem a troca de informações entre si (**redes de informação**).

Formalmente, segundo Newman (2010), uma rede pode ser definida como uma tripla $N = \langle \mathcal{O}, \mathcal{R}, \mathcal{W} \rangle$, tal que $\mathcal{O}$ representa o conjunto de objetos (ou nós) da rede, $\mathcal{R}$ representa o conjunto de relações (ou arestas) e $\mathcal{W}$ representa o conjunto de pesos das relações entre os objetos. A relação entre dois pares de objetos $o_i, o_j \in \mathcal{O}$, caso exista, é dada por r_{o_i, o_j} e w_{o_i, o_j} é o peso dessa relação. Quando $\mathcal{O}$ possui apenas um tipo de objeto, a rede é denominada **homogênea**. Porém, se $\mathcal{O}$ é composto por objetos de diferentes tipos, a rede é denominada **heterogênea** (SHI *et al.*, 2017).

De acordo com Shi *et al.* (2017), a maioria dos sistemas reais é composta por objetos de diferentes tipos que interagem entre si: websites de mídia social (como Facebook¹) contêm usuários, postagens, fotos, vídeos e *tags*; sistemas de saúde contêm médicos, pacientes e doenças; e sistemas de distribuição elétrica possuem estações de distribuições, transformadores e clientes finais, por exemplo.

Diante disso, as redes heterogêneas são adequadas para modelar uma grande variedade de sistemas, como os sistemas de recomendação, que também são formados por objetos de diferentes tipos (usuários, itens e contextos). Na Figura 1, é apresentado um exemplo de rede heterogênea de recomendação, utilizando os dados de usuários e itens apresentados na Tabela 2. Nessa rede há dois tipos de nós, que representam usuários (nós superiores) e itens (nós inferiores). Os pesos nas arestas indicam a nota que o usuário atribuiu ao item em questão.

Figura 1 – Exemplo de uma rede heterogênea de recomendação, utilizando dados de um serviço de *streaming* de filmes

Fonte: Elaborada pelo autor.

De maneira geral, por meio das representações em rede, é possível explorar a estrutura dos nós e arestas, buscando padrões que possam indicar características dos objetos (como grau de importância e categoria), subestruturas existentes (como grupos e comunidades), e até fornecer *insights* sobre como os objetos se conectam, ajudando a prever *links* futuros (GETOOR; DIEHL, 2005). Os algoritmos de mineração de dados podem ser utilizados para esse fim e permitem realizar uma grande variedade de tarefas,

¹ www.facebook.com

como classificação, agrupamento, propagação de rótulos, predição de *links* e ranqueamento, que possibilitam resolver diversos problemas do mundo real.

Em especial, a tarefa de recomendar itens utilizando representações em rede pode ser vista como um caso especial de aprendizado semissupervisionado (HE *et al.*, 2015), que utiliza dados rotulados e não-rotulados para fazer a classificação/regressão. No caso da recomendação, os rótulos podem consistir nas notas que os usuários atribuíram a cada item. Caso seja um valor inteiro em um dado intervalo (por exemplo, de 1 a 5), trata-se de um problema de classificação. Caso contrário, trata-se de um problema de regressão. O objetivo do processo consistiria em determinar os rótulos dos dados ainda não-rotulados.

Para exemplificar, considere novamente a rede do serviço de *streaming* de filmes, apresentada na Figura 1. Os dados rotulados poderiam ser triplas na forma $\langle \text{usuário}, \text{item}, \text{rótulo} \rangle$, ou seja, para o exemplo apresentado, tem-se $\langle \text{Harry Potter}, \text{João}, 1 \rangle$, $\langle \text{Homem de Ferro}, \text{João}, 5 \rangle$, $\langle \text{Rei Leão}, \text{Marcos}, 4 \rangle$, $\langle \text{Homem de Ferro}, \text{Marcos}, 1 \rangle$. A recomendação consistiria em determinar os rótulos para os dados não rotulados, que são: $\langle \text{Rei Leão}, \text{João}, ? \rangle$ e $\langle \text{Harry Potter}, \text{Marcos}, ? \rangle$. No entanto, outras abordagens também podem ser consideradas para modelar a tarefa de recomendação (PHAM *et al.*, 2016), como a utilização de vetores de características como rótulos e as notas dos usuários como pesos das arestas, por exemplo.

De acordo com Shi *et al.* (2017), redes heterogêneas são promissoras para sistemas de recomendação, pois permitem representar semanticamente e visualmente as interações entre usuários, itens e contextos, bem como explorar padrões nas interações da rede para recomendar itens aos usuários. Os relacionamentos na rede, por exemplo, podem ser utilizados como fonte para explicação das recomendações geradas.

Na seção seguinte, serão apresentados as principais técnicas e algoritmos utilizados para geração de recomendações, tanto na modelagem de Espaço-Vetorial quanto na de Redes Heterogêneas.

2.2 Sistemas de Recomendação Tradicionais

Tradicionalmente, o problema de recomendação consiste em prever a avaliação de um usuário para um dado item, considerando apenas o conjunto de usuários e itens presentes no sistema (ADOMAVICIUS; TUZHILIN, 2011). Para isso, o sistema de recomendação busca estimar uma função de utilidade, r , que mapeia um par item-usuário a um conjunto ordenado de avaliações, indicando o quão útil um item i é para um usuário u .

$$r : \text{Usuário} \times \text{Item} \rightarrow \text{Avaliação} \quad (2.1)$$

Nesse caso, *Usuário* e *Item* representam o conjunto de usuários e itens presentes no sistema, respectivamente, e *Avaliação* representa o domínio de avaliações.

De acordo com Ricci *et al.* (2015), existem diferentes técnicas e algoritmos que são utilizados para a predição dos valores de avaliação, a partir dos quais a recomendação é feita. Em geral, essas técnicas diferem na forma como trabalham com os dados de interação do usuário. Se os algoritmos buscam identificar padrões na forma como diferentes usuários avaliam os itens do sistema, tratam-se de algoritmos baseados na **filtragem colaborativa**. Por sua vez, se os algoritmos consideram o conteúdo e os atributos dos itens consumidos por um dado usuário para gerar as recomendações, trata-se da **filtragem baseada em conteúdo**. Na Figura 2, são apresentadas as principais categorias dos sistemas de recomendação tradicionais, que serão detalhadas nas seções seguintes.

Figura 2 – Categorias dos sistemas de recomendação tradicionais

Fonte: Elaborada pelo autor.

2.2.1 Filtragem baseada em conteúdo

Segundo Aggarwal (2016), a filtragem baseada em conteúdo é adequada principalmente nos cenários em que os itens podem ser descritos por um conjunto de atributos. Nesses casos, os dados de interação do **próprio usuário** alvo da recomendação são utilizados para gerar as recomendações, em conjunto com os outros atributos que descrevem os itens.

Para exemplificar, considere os dados de interação apresentados na Tabela 1, bem como os atributos dos itens mostrados na Tabela 3. O domínio é o de recomendação de filmes, há quatro itens (*Homem de Ferro*, *Harry Potter*, *Rei Leão* e *Vingadores*) com três atributos que os descrevem (*Gênero*, *Público-Alvo* e *Década de Lançamento*).

Tabela 3 – Exemplo de atributos para os itens da Tabela 2

	Gênero	Público-Alvo	Década de Lançamento
Homem de Ferro	Super-Herói	Jovem-Adulto	2000-2009
Harry Potter	Fantasia	Infanto-Juvenil	2000-2009
Rei Leão	Fantasia	Infantil	1990-1999
Vingadores	Super-Herói	Jovem-Adulto	2010-2019

Fonte: Elaborada pelo autor.

A ideia principal das técnicas baseadas em conteúdo é considerar tanto os dados de interação, apresentados na Tabela 1, quanto os atributos dos itens, apresentados na Tabela 3. A abordagem mais comumente utilizada é a dos K-vizinhos mais próximos, que será descrita na Seção 2.2.1.1; no entanto, existem outros tipos de algoritmos que também podem ser considerados, que serão descritos brevemente na Seção 2.2.1.2.

2.2.1.1 Abordagem baseada nos K-vizinhos mais próximos

Nessa abordagem, o primeiro passo é definir uma matriz de similaridades $S_{m \times m}^{item}$, tal que m é o número de itens, e o elemento $S_{k,j}^{item}$ indica a similaridade entre o item i_k e o item i_j , calculada a partir da matriz de atributos dos itens. Para isso, devem ser utilizadas métricas de similaridades adequadas aos dados dos itens em questão. A seguir, são apresentadas duas possibilidades, tal que a Equação 2.2 é adequada para dados numéricos, e a Equação 2.3 para dados categóricos.

$$\cos(X_k, X_j) = \frac{X_k \cdot X_j}{||X_k|| ||X_j||} \quad (2.2) \quad \text{sim}(X_k, X_j) = \sum_{t=1}^f \text{iguais}(x_{k,t}, x_{j,t}) \quad (2.3)$$

tal que X_k é o vetor de atributos do item i_k , X_j é o vetor de atributos do item i_j , f é o número de atributos que cada item possui, e $\text{iguais}(x_{k,t}, x_{j,t}) = 1$, se X_k e X_j possuem o mesmo valor para o atributo t , e $\text{iguais}(x_{k,t}, x_{j,t}) = 0$, caso contrário.

Para exemplificar, considere os dados da Tabela 3, que contém os atributos dos itens. Como os atributos são todos categóricos, a métrica de similaridade mais adequada é a apresentada na Equação 2.3. Dessa forma, a matriz de similaridades S^{item} para o exemplo em questão é apresentada na Tabela 4. A similaridade entre *Homem de Ferro* e *Vingadores*, por exemplo, foi dois, porque eles possuem dois atributos com valores iguais (*Gênero* e *Público-Alvo*). Por outro lado, a similaridade entre *Homem de Ferro* e *Rei Leão* foi zero, porque eles não possuem nenhum atributo em comum.

Subsequentemente, prossegue-se para a geração das recomendações para um usuário alvo, u . Para predizer um valor de avaliação ao item i ($r_{u,i}$), considera-se os K itens mais similares a i , definido pelo conjunto τ_i . Dessa forma, a avaliação predita do usuário u para o item i é dada pela média das suas avaliações aos itens em τ_i (outras funções de

Tabela 4 – Matriz de similaridades para os atributos dos itens apresentados na Tabela 2

	Homem de Ferro	Harry Potter	Rei Leão	Vingadores
Homem de Ferro				
Harry Potter	1			
Rei Leão	0	1		
Vingadores	2	0	0	

Fonte: Elaborada pelo autor.

agregações podem ser utilizadas, como a média ponderada):

$$\hat{r}_{u,i} = \frac{1}{|\tau_i|} \sum_{t \in \tau_i} r_{u,t} \quad (2.4)$$

No caso do exemplo apresentado na Tabela 2, suponha que se deseja prever a avaliação do usuário *Marcos* ao filme *Harry Potter* ($\hat{r}_{marcos,HP}$). O primeiro passo é obter o conjunto τ_{HP} , que consiste nos K itens mais similares já vistos por *Marcos*. Por simplicidade, suponha que $K = 2$. Nesse caso, $\tau_{HP} = \{ \text{Rei Leão, Homem de Ferro} \}$, uma vez que a similaridade entre *Harry Potter* e *Rei Leão* ($S_{HP,RL}^{item} = 1$), e entre *Harry Potter* e *Homem de Ferro* ($S_{HP,HF}^{item} = 1$) são maiores que a similaridade entre *Harry Potter* e *Vingadores* ($S_{HP,Ving}^{item} = 0$). Portanto, o valor de avaliação predito a *Marcos* e *Harry Potter* é dado por: $\hat{r}_{marcos,HP} = \frac{1}{2} \cdot (r_{marcos,RL} + r_{marcos,HF}) = \frac{1}{2} \cdot (4 + 1) = 2,5$.

Uma das principais vantagens em se utilizar a filtragem baseada em conteúdo considerando os K -Vizinhos mais próximos é que as recomendações geradas são **interpretáveis** (AGGARWAL, 2016). Essa é uma característica que tem sido considerada de extrema importância nos algoritmos de aprendizado de máquina atuais (BARAL *et al.*, 2018; HOLZINGER, 2018; SAMEK, 2019; BERTOSSI; GEERTS, 2020). Para isso, uma possibilidade é determinar quais atributos dos itens mais impactaram à recomendação, gerando explicações com base nessa informação. No caso do exemplo apresentado anteriormente, *Homem de Ferro* foi considerado similar a *Harry Potter*, uma vez que ambos foram produzidos na década de 2000-2009. De maneira análoga, *Harry Potter* foi considerado similar à *Rei Leão*, porque ambos são do gênero fantasia. Diante disso, uma possível explicação para recomendar *Harry Potter* poderia ser: “*Esses itens são adequados porque possuem o mesmo gênero e/ou década de lançamento*”.

No entanto, apesar dessa abordagem ser uma das técnicas pioneiras de recomendação baseada em conteúdo, ela apresenta várias limitações. Assim como a maioria dos algoritmos baseados em conteúdo, não há diversidade e/ou serendipidade² nas recomendações geradas, uma vez que apenas são recomendados itens similares em conteúdo a outros que o usuário já viu (PAZZANI; BILLSUS, 2007; RICCI *et al.*, 2015; AGGARWAL, 2016).

² Esse conceito indica quando o usuário é surpreendido com uma recomendação que, em geral, ele não esperava.

Além disso, os atributos considerados dos itens e as técnicas utilizadas são bastante simples, e não escalam para cenários reais (AGGARWAL, 2016). Em razão disso, outras abordagens têm sido propostas a fim de mitigar tais problemas (SHU *et al.*, 2018; BELEVESLIS; TJORTJIS, 2020); no entanto, descrever tais abordagens em detalhes foge do escopo deste trabalho de mestrado. Dessa forma, na seção seguinte, serão apenas citadas algumas delas.

2.2.1.2 Outras Abordagens

Segundo Aggarwal (2016), vários outros tipos de algoritmos podem ser utilizados para gerar recomendações baseadas em conteúdo, tais como regras de associação, classificadores bayesianos, e outros modelos de aprendizado de classificação e regressão. Independente do algoritmo utilizado, é importante possuir os dados de interações do usuário, como os apresentados na Tabela 2, e dados de descrição dos itens, como os apresentados na Tabela 3.

De acordo com Lops *et al.* (2019), uma das tendências atuais na área é explorar novas abordagens para a definição dos dados descritivos dos itens. Em especial, têm sido buscadas novas fontes de dados/informações que contenham informação relevante sobre características dos itens, como revisões de usuários, imagens e outros tipos de dados multimedia. Além disso, novos algoritmos e técnicas têm sido utilizados, como modelagem por redes heterogêneas, uso de *embeddings* e algoritmos de *Deep Learning*.

Na seção seguinte, será apresentada a filtragem colaborativa, que superam algumas das limitações dos métodos baseados em conteúdo (DESROSIERS; KARYPIS, 2011).

2.2.2 Filtragem colaborativa

A filtragem colaborativa tem como princípio que a recomendação de itens é um processo colaborativo. Informalmente, ela se inspira nas recomendações boca-a-boca, quando pessoas sugerem itens que eles próprios gostaram à conhecidos, amigos ou familiares. Formamente, a filtragem colaborativa prediz valores de avaliação antes desconhecidos, considerando a existência de padrões de interação e relacionamento entre diferentes usuários e itens (AGGARWAL, 2016). Ou seja, existem conjuntos de usuários que avaliam itens de maneira similar, e conjuntos de itens que são avaliados de forma similar por diferentes usuários. Portanto, são essas informações que os sistemas colaborativos buscam explorar.

Além de utilizar as avaliações do próprio usuário alvo da recomendação, a filtragem colaborativa considera também as avaliações de outros usuários. Por causa disso, ela supera a principal limitação dos métodos baseados em conteúdo, que é a falta de novidade e serendipidade nas recomendações (DESROSIERS; KARYPIS, 2011), pois itens

que outros usuários gostaram também serão recomendados.

Existem dois tipos principais de métodos colaborativos (AGGARWAL, 2016): os que são baseados em vizinhança (ou métodos baseados em memória), e os baseados em modelo. De maneira geral, os métodos baseados em vizinhança consideram a vizinhança dos usuários e/ou itens para gerar as recomendações, como apresentado nos parágrafos anteriores. Outra possibilidade consiste em utilizar modelos de aprendizado de máquina e mineração de dados para gerar as recomendações, que são os métodos baseados em modelo. Nas seções seguintes, serão descritas diferentes abordagens colaborativas baseadas em vizinhança e em modelo.

2.2.2.1 Abordagens baseadas em vizinhança

Esse tipo de abordagem considera a vizinhança dos usuários/itens alvo da recomendação para gerar as recomendações, e é reconhecido pela sua simplicidade e bons resultados (AGGARWAL, 2016). Por ser uma das abordagens mais comumente utilizadas, existem uma variedade de métodos disponíveis na literatura. Em razão disso, serão descritos a seguir quatro desses métodos: dois que utilizam a representação de dados no modelo Espaço-Vetorial, e um método que utiliza Redes Heterogêneas.

2.2.2.1.1 Abordagem baseada em usuários/itens similares

A abordagem baseada em usuários similares busca identificar usuários com padrões de avaliação similares ao usuário-alvo da recomendação. Com isso, os itens recomendados tendem a ser os itens que os usuários similares já consumiram e gostaram (AGGARWAL, 2016). Mais especificamente, dada a matriz de avaliações, R , como a apresentada na Tabela 2, o primeiro passo é definir uma matriz de similaridade entre usuários, considerando as suas avaliações já feitas.

A similaridade entre os usuários u e v é dada por $S_{u,v}^{user}$, e pode ser calculada a partir do Coeficiente de Correlação de Pearson:

$$S_{u,v}^{user} = \text{Pearson}(u, v) = \frac{\sum_{k \in I_u \cap I_v} (r_{u,k} - \mu_u) \cdot (r_{v,k} - \mu_v)}{\sqrt{\sum_{k \in I_u \cap I_v} (r_{u,k} - \mu_u)^2} \cdot \sqrt{\sum_{k \in I_u \cap I_v} (r_{v,k} - \mu_v)^2}} \quad (2.5)$$

tal que $I_u \cap I_v$ é o conjunto dos itens que foram avaliados mutuamente pelo usuário u e pelo usuário v ; μ_u e μ_v são a média das avaliações feitas pelo usuário u e v , respectivamente; e, por fim, $r_{u,k}$ é a avaliação feita pelo usuário u ao item k .

Um dos problemas que surge nessa abordagem é o fato de que diferentes usuários podem fornecer avaliações em diferentes escalas, isto é, um usuário pode ter uma tendência de avaliar todos os itens positivamente, enquanto um outro usuário pode avaliar os itens

negativamente. Para mitigar esse problema, define-se $\bar{r}_{u,j}$, que é a avaliação centrada na média do usuário u ao item j :

$$\bar{r}_{u,j} = r_{u,j} - \mu_u, \quad \forall u \in \{1, \dots, m\} \quad (2.6)$$

Dessa forma, a função que prediz a avaliação de um usuário u a um item j é dada por:

$$\hat{r}_{u,j} = \mu_u + \frac{\sum_{v \in P_u(j)} S_{u,v}^{user} \cdot \bar{r}_{v,j}}{\sum_{v \in P_u(j)} |S_{u,v}^{user}|} \quad (2.7)$$

tal que $P_u(v)$ representa o conjunto dos k usuários mais similares a u que avaliaram o item v .

Por outro lado, a abordagem baseada em itens similares, para prever a avaliação feita por um usuário a um dado item, busca identificar outros itens que tenham sido avaliados de maneira similar. Com isso, são consideradas as avaliações feitas pelo próprio usuário alvo nesses outros itens para prever a avaliação final ao item em questão. Para uma descrição mais detalhada dessa abordagem, consulte o livro de Ricci *et al.* (2015) e Aggarwal (2016).

De maneira geral, independente de se estar considerando a abordagem baseada em usuários ou a abordagem baseada em itens similares, é importante destacar que ambas produzem recomendações **interpretáveis**, que é uma característica essencial dos sistemas de recomendação recentes (TINTAREV; MASTHOFF, 2007; BARAL *et al.*, 2018; SATO *et al.*, 2018). Em especial, podem ser consideradas as informações de vizinhança para gerar explicações. No caso da abordagem baseada em usuários similares, uma possível explicação seria: “*Estamos recomendando o item X, porque ele foi visto por usuários com preferências similares às suas*”. No caso da abordagem baseada em itens similares, por sua vez, uma possível explicação seria: “*Estamos recomendando o item X porque ele tem avaliações similares a de outros itens que você já gostou, como o item Y e o item Z*”. No entanto, essas abordagens foram uma das primeiras abordagens colaborativas a serem utilizadas na prática; portanto, podem não ser consideradas adequadas para os problemas atuais, tanto em termos de acurácia quanto de escalabilidade (AGGARWAL, 2016).

2.2.2.1.2 Abordagem baseada em propagação de rótulos

Essa abordagem trabalha com a representação de dados no Modelo de Redes Heterogêneas. Como mencionado na Seção 2.1.2, as entidades da tarefa de recomendação são tratadas como diferentes objetos de uma rede complexa (objetos do tipo usuário, item, contexto, e outras entidades relevantes). Além disso, os relacionamentos entre os objetos dessa rede definem as interações entre as suas diferentes entidades (usuário avaliou item em determinado contexto, usuários similares, itens similares, entre outros).

Uma das possíveis abordagens para geração de recomendações nesse tipo de apresentação de dados é fazer a propagação de rótulos entre os nós da rede. Mais especificamente, as avaliações feitas pelos usuários aos itens já consumidos, como *Gostei/Não Gostei* ou *Péssimo/Ruim/Neutro/Bom/Muito Bom*, podem ser consideradas os rótulos desses itens. O objetivo dessa abordagem, então, seria propagar os rótulos para os objetos ainda não-rotulados. Dessa forma, ao final, seria possível identificar os itens que o usuário gostou e os que ele não gostou, e a partir dessa informação gerar as recomendações.

Nesse contexto, um algoritmo de propagação de rótulos geralmente utilizado é o *GNetMine* (JI *et al.*, 2010), que é um algoritmo semi-supervisionado transdutivo. Isso significa que, a partir de dados previamente rotulados e da estrutura de uma rede (dos objetos e seus relacionamentos), ele busca aprender um rótulo para os objetos ainda não rotulados. A sua principal característica é a possibilidade de fazer a classificação dos nós a partir de uma rede com **topologia arbitrária**, ou seja, com qualquer número de tipos de objetos e de relacionamentos. Além disso, é um algoritmo considerado computacionalmente eficiente, o que é de extrema importância em problemas que envolvem redes heterogêneas, que, em geral, possuem grande número de nós e arestas.

Intuitivamente, por se basear no *framework* de regularização de redes (ZHOU; SCHÖLKOPF, 2004), o *GNetMine* busca satisfazer as premissas de consistência e de informação prévia. De maneira geral, essas premissas preconizam que vértices vizinhos devem possuir classes semelhantes (consistência) e que as informações de classe preditas devem ser próximas às informações de rótulo reais já fornecidas (informação prévia).

Na Figura 3 é ilustrado o funcionamento do *GNetMine*, com especial destaque a como o algoritmo satisfaz às premissas mencionadas anteriormente. Uma rede heterogênea é dada como exemplo na Figura 3a: são três tipos diferentes de nós, U, I e C, sendo dois nós previamente rotulados, que são o nó U_3 , que pertence à classe vermelha, e o nó C_1 , que pertence à classe amarela. A ideia geral do algoritmo é propagar esses rótulos para todos os outros nós da rede, considerando os relacionamentos existentes, bem como os diferentes tipos dos objetos.

Ao se observar o resultado final do algoritmo para o exemplo em questão, apresentado na Figura 3b, nota-se que os nós U_1 e U_2 foram rotulados como da classe vermelha, uma vez que são do mesmo tipo que U_3 , previamente rotulado como vermelho, e também por estarem conectados a ele. Além disso, o nó I_1 também é classificado como vermelho, porque está próximo a U_2 (está conectado a ele). Os nós C_2 e I_2 , por sua vez, são rotulados como da classe amarela por serem vizinhos à C_1 , previamente rotulado. Portanto, a premissa de consistência foi satisfeita. Apesar do objeto C_1 sofrer influência de U_3 (vermelha) no processo de propagação dos rótulos, por estarem conectados entre si, a premissa da informação prévia mantém a classe inicial de C_1 como sendo amarela.

Formalmente, suponha que o número de rótulos (ou classes) seja K e suponha que

Figura 3 – Exemplo de rede heterogênea com três tipos de nós (U, I e C). Inicialmente, há dois nós rotulados: U_3 , que possui a classe vermelha; e C_1 , que possui a classe amarela. O algoritmo *GNetMine* faz a propagação dos rótulos para todos os outros nós da rede.

Fonte: Elaborada pelo autor.

haja m tipos de objetos. Para cada conjunto de objetos $\mathcal{X}_i$ (objetos do tipo i), $i \in \{1, \dots, m\}$, é definida uma matriz indicadora de classe $F_i = [f_i^{(1)}, \dots, f_i^{(K)}] \in \mathbb{R}^{n_i \times K}$, tal que n_i é o número de objetos do tipo i . Cada $f_i^{(k)} = [f_{i1}^{(k)}, \dots, f_{in_i}^{(k)}]^T$ indica a confiança de que o objeto $x_{ip} \in \mathcal{X}_i$ pertence à classe k .

Para os objetos dos tipos $\mathcal{X}_i$ e $\mathcal{X}_j$ é definida uma matriz de adjacências, R_{ij} entre os objetos dos tipos i e j , de tal forma que $R_{ij,pq}$ indica o peso da relação entre os objetos p do tipo i e q do tipo j . Além disso, a informação de rótulos inicial é definida pelo vetor $y_i^{(k)} = [y_{i1}^{(k)}, \dots, y_{in_i}^{(k)}]^T \in \mathbb{R}^{n_i}$ para cada tipo de objetos $\mathcal{X}_i$, de tal forma que:

$$y_{ip}^{(k)} = \begin{cases} 1 & \text{se } x_{ip} \text{ pertence à classe } k \\ 0 & \text{caso contrário} \end{cases} \quad (2.8)$$

O objetivo do *GNetMine*, portanto, é inferir as matrizes de confiança F_i a partir das matrizes de relação R_{ij} e das matrizes de informação prévia Y_i , $i, j \in \{1, \dots, m\}$. Para isso, o algoritmo busca minimizar a seguinte função objetivo:

$$J(f_1^{(k)}, \dots, f_m^{(k)}) = \sum_{i,j=1}^m \lambda_{i,j} \sum_{p=1}^{n_i} \sum_{q=1}^{n_j} R_{ij,pq} \left(\frac{1}{\sqrt{D_{ij,pp}}} f_{ip}^{(k)} - \frac{1}{\sqrt{D_{ji,qq}}} f_{jq}^{(k)} \right) + \sum_{i=1}^m \alpha_i (f_i^{(k)} - y_i^{(k)})^T (f_i^{(k)} - y_i^{(k)}). \quad (2.9)$$

tal que D_{ij} , de tamanho $n_i \times n_i$ é uma matriz diagonal, em que o elemento $D_{ij,pp}$ é a soma da linha p de R_{ij} . Além disso, $\lambda_{i,j}$ e α_i são parâmetros que determinam o peso das relações entre os tipos i e j , e o peso da informação prévia dos objetos do tipo i , respectivamente. A primeira parte da função busca satisfazer a premissa de consistência, e a segunda parte, a premissa de informação prévia. A partir das matrizes de confiança $F_i, i \in \{1, \dots, m\}$, estimadas pelo algoritmo, é possível prever a classe de cada um dos objetos da rede,

selecionando a classe de maior confiança dentre os elementos $f_{ip} = [f_{ip}^{(1)}, \dots, f_{ip}^{(K)}]$, $p \in \{1, \dots, n_i\}$.

Em resumo, o algoritmo parte de uma rede parcialmente rotulada, como no caso da Figura 3a, e, considerando os relacionamentos entre os objetos, a topologia da rede e os rótulos iniciais, obtém uma rede completamente rotulada ao final, como no caso da Figura 3b. Para exemplificar o processo de propagação de rótulos no contexto de recomendação, considere a Figura 4. No exemplo, há três usuários (U_1 , U_2 e U_3), dois itens (I_1 e I_2) e dois contextos (C_1 e C_2). Além disso, há duas possibilidades de rótulos: avaliação positiva, representada em verde, e avaliação negativa, representada em vermelho. O objetivo seria obter as recomendações para o usuário U_3 , que está em destaque nas figuras.

Figura 4 – Exemplo de como o processo de recomendação é feito a partir da rede parcialmente rotulada e de uma abordagem baseada em propagação de rótulos.

Fonte: Elaborada pelo autor.

Inicialmente, sabe-se que o usuário U_3 já avaliou o item I_2 positivamente, e que ele não gosta de consumir itens no contexto C_1 . Além disso, sabe-se que ele tem gostos similares ao usuário U_2 . Com base nessas informações, é construída a rede heterogênea com os rótulos apropriados (item I_2 é rotulado como verde, contexto C_1 como vermelho e usuário U_2 como verde), que é apresentada na Figura 4a. Com isso, é executado o algoritmo *GNetMine*, que faz a propagação dos rótulos para o restante da rede.

A rede resultante é apresentada na Figura 4b, em que os rótulos finais foram: usuários U_2 e U_3 foram rotulados como positivo, bem como os itens I_1 e I_2 . Por outro lado, o usuário U_1 foi rotulado como negativo, bem como os contextos C_1 e C_2 . Com base nessas informações, é possível identificar que o usuário U_3 , alvo da recomendação nesse exemplo, tem grande probabilidade de gostar do item I_1 , uma vez que esse item foi rotulado como positivo. Dessa forma, a recomendação de I_1 é feita.

Essa abordagem de propagação de rótulos no contexto da tarefa de recomendação tem inúmeras vantagens (PHAM *et al.*, 2016; SHI *et al.*, 2017), em especial a alta acurácia e a **interpretabilidade** das recomendações geradas (HE *et al.*, 2015). Existem

várias possibilidades de explicar as recomendações, tais como apresentar os usuários/itens similares e contextos preferidos, uma vez que todos os nós da rede foram rotulados. No caso do exemplo da Figura 4, uma explicação seria: “*Estamos recomendando o item I_1 porque ele foi consumido por um usuário similar a você (usuário U_2)*”. Diante disso, essa abordagem e algoritmo foram escolhidos para a geração das recomendações neste trabalho de mestrado, como será apresentado no Capítulo 4.

2.2.2.2 Abordagens baseadas em modelo

Além das abordagens colaborativas baseadas em vizinhança, apresentadas nas seções anteriores, existem também as abordagens baseadas em modelo. Esse tipo de abordagem busca criar um modelo sumário dos dados da tarefa de recomendação, como acontece no aprendizado supervisionado. Por simplicidade, serão apresentadas apenas duas abordagens colaborativas baseadas em modelo, que serão descritas nas seções seguintes: a fatoração de matrizes, que é amplamente utilizada e reconhecida por gerar resultados muito bons (KOREN *et al.*, 2009; FRIEDMAN *et al.*, 2016; XUE *et al.*, 2017; GUAN *et al.*, 2017; WU *et al.*, 2018), e outras abordagens, baseadas em algoritmos aprendizados supervisionados.

2.2.2.2.1 Abordagem baseada em fatoração de matrizes

De maneira geral, essa abordagem tem como propósito identificar os fatores latentes nos dados de recomendação, que são padrões e características ocultas nos dados, descrevendo as características dos usuários e dos itens do sistema (KOREN *et al.*, 2009; KOREN; BELL, 2011). Por exemplo, quando os itens são filmes, os fatores descobertos podem indicar dimensões óbvias como comédia versus drama, quantidade de ação ou orientação para crianças, mas também dimensões de difícil interpretação. A partir desses fatores, é possível identificar a preferência do usuário por cada uma dessas dimensões, e então gerar as recomendações com base nessa informação (KOREN *et al.*, 2009).

Alguns dos algoritmos mais bem sucedidos que implementam o método dos fatores latentes são baseados em técnicas de fatoração de matrizes, que têm se tornado populares por combinarem boa escalabilidade e acurácia (KOREN *et al.*, 2009). A ideia por trás das técnicas de fatoração de matrizes em sistemas de recomendações tradicionais é, considerando m usuários e n itens, decompor a matriz de avaliações, R , em duas outras matrizes, X e Y , cada qual com k fatores, que são características inferidas dos dados de avaliação

existentes:

$$\hat{R} = XY^T = \begin{pmatrix} x_{11} & x_{12} & x_{13} & \cdots & x_{1k} \\ x_{21} & x_{22} & x_{23} & \cdots & x_{2k} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ x_{m1} & x_{m2} & x_{m3} & \cdots & x_{mk} \end{pmatrix} \times \begin{pmatrix} y_{11} & y_{12} & \cdots & y_{1n} \\ y_{21} & y_{22} & \cdots & y_{2n} \\ y_{31} & y_{32} & \cdots & y_{3n} \\ \vdots & \vdots & \ddots & \vdots \\ y_{k1} & y_{k2} & \cdots & y_{kn} \end{pmatrix} \quad (2.10)$$

Os algoritmos de recomendação têm como propósito prever a preferência do usuário pelos itens ainda não avaliados. Dessa forma, na abordagem baseada em fatoração de matrizes, a avaliação de um usuário u para um item i pode ser aproximada por:

$$\hat{r}_{u,i} = \vec{x}_u \cdot (\vec{y}_i)^T \quad (2.11)$$

tal que $\vec{x}_u$ corresponde ao vetor de fatores do usuário u e $\vec{y}_i$, ao vetor de fatores do item i . Essas informações podem ser obtidas, respectivamente, das matrizes X e Y .

Para obter os vetores de fatores ($\vec{x}_u$ e $\vec{y}_i$), o sistema deve minimizar a raiz quadrada do erro quadrático médio (RMSE) no conjunto de avaliações conhecidas:

$$\min_{x,y} \sum_{(u,i) \in K} (r_{u,i} - \vec{x}_u \cdot (\vec{y}_i)^T)^2 + \lambda (\|\vec{x}_u\|^2 + \|\vec{y}_i\|^2) \quad (2.12)$$

tal que K é o conjunto dos pares (u,i) para os quais $r_{u,i}$ é conhecido. A constante λ é utilizada para a regularização dos parâmetros aprendidos, de forma a evitar a superespecialização do modelo.

Para isso, podem ser utilizados diferentes algoritmos de otimização, como o *Stochastic Gradient Descent* (SGD) (BOTTOU, 2012) e o *Alternating Least Squares* (ALS) (LAWSON; HANSON, 1995). Em razão de sua maior simplicidade, será descrito o processo de otimização considerando o algoritmo SGD. De maneira geral, deve-se iterar sobre todos os dados de avaliação no conjunto de treinamento. Para cada par (u,i) do conjunto de treinamento, o algoritmo computa o valor de $r_{u,i}$ e calcula o erro associado a essa predição:

$$e_{u,i} = r_{u,i} - \vec{x}_u \cdot (\vec{y}_i)^T \quad (2.13)$$

A fim de reduzir esse erro, os parâmetros são ajustados em uma magnitude proporcional a η na direção oposta ao gradiente, produzindo:

$$\vec{x}_u = \vec{x}_u - \eta \cdot (e_{u,i} \cdot \vec{y}_i + \lambda \vec{x}_u) \quad (2.14) \quad \vec{y}_i = \vec{y}_i - \eta \cdot (e_{u,i} \cdot \vec{x}_u + \lambda \vec{y}_i) \quad (2.15)$$

O algoritmo itera repetidamente sobre todos os dados de treinamento até que a raiz quadrada do erro quadrático médio (RMSE) atinja um patamar inferior a um erro desejado ou até que um número pré-determinado de iterações seja atingido.

A principal vantagem em se utilizar essa abordagem é o seu alto desempenho, tanto em termos de acurácia quanto de escalabilidade. No entanto, ela **não é interpretável**, uma vez que se baseia nos fatores latentes para gerar as recomendações. De maneira geral, não é possível identificar quais características foram consideradas como os fatores mais importantes dos dados e quais deles mais influenciaram às recomendações. Isso atrapalha a interpretabilidade do processo, e pode tornar a utilização dessa abordagem inviável nos cenários onde a interpretabilidade dos resultados é essencial.

2.2.2.2.2 Outras Abordagens

De acordo com [Aggarwal \(2016\)](#), existem uma variedade de abordagens colaborativas baseadas em modelo, como árvores de decisão, métodos baseados em regras, classificadores bayesianos, modelos de regressão e máquinas de vetores de suportes. De maneira geral, como mencionado na Seção 2.1.1, a tarefa de recomendação pode ser vista como um problema de classificação ou regressão, que são instâncias do aprendizado supervisionado. Dessa forma, quaisquer algoritmos tradicionais de aprendizado de máquina supervisionado podem ser adaptados para o contexto da recomendação.

Mais especificamente, considere os dados apresentados na Tabela 1, que contêm um conjunto de atributos descritivos, bem como um rótulo, que representa a avaliação do usuário para um dado item (categórico ou numérico). Esses dados podem ser utilizados como entrada de um algoritmo de aprendizado supervisionado, que irá então definir um modelo de aprendizado, que será utilizado para rotular novas instâncias.

Com isso, é feita a recomendação dos itens, considerando os rótulos atribuídos. Quando eles são categóricos, basta identificar os itens que foram rotulados positivamente (como *Recomendar*, *Muito Bom* / *Bom* e *Gosta*), e recomendá-los. Quando os rótulos são numéricos, basta ranquear os itens em ordem decrescente considerando o valor predito e, então, recomendar os top-K itens.

A interpretabilidade das recomendações nesse caso vai depender da interpretabilidade do algoritmo de aprendizado supervisionado utilizado. Ou seja, se forem utilizados algoritmos simbólicos, por exemplo, será possível interpretar as recomendações geradas. Por outro lado, se forem utilizadas redes neurais, cujo modelo de aprendizado consiste em um conjunto de pesos numéricos estimados, as recomendações não serão interpretáveis. Dessa forma, em um cenário de recomendação real, a escolha do algoritmo de aprendizado mais adequado deve considerar tanto o seu desempenho, quanto a necessidade ou não em se explicar os resultados obtidos.

Na próxima seção, serão apresentados os sistemas de recomendação sensíveis ao contexto, que constituem uma extensão dos algoritmos tradicionais apresentados até agora.

2.3 Sistemas de Recomendação Sensíveis ao Contexto

Os sistemas de recomendação sensíveis ao contexto utilizam, além das informações tradicionais de usuários e itens, informações adicionais que representam o contexto dos usuários e/ou itens. Essas informações, como, por exemplo, horário, dia da semana, clima e localidade, podem influenciar significativamente a preferência de um usuário. Afinal, um usuário pode preferir viajar à praia no verão e a cidades históricas no inverno, por exemplo. Dessa forma, a função de utilidade pode ser modificada para incorporar a informação contextual no processo de recomendação (ADOMAVICIUS; TUZHILIN, 2011):

$$r : \text{Usuário} \times \text{Item} \times \text{Contexto} \rightarrow \text{Avaliação} \quad (2.16)$$

tal que *Contexto* representa um conjunto de dimensões contextuais associadas à aplicação.

Nos sistemas de recomendação sensíveis ao contexto, a informação contextual pode ser utilizada em vários estágios do processo de recomendação (ADOMAVICIUS; TUZHILIN, 2011). Considerando o estágio no qual a informação contextual é utilizada, os sistemas de recomendação podem ser divididos em três categorias, como observado na Figura 5: (i) **pré-filtragem contextual**, (ii) **pós-filtragem contextual** e (iii) **modelagem contextual**.

Figura 5 – Categorias dos sistemas de recomendação sensíveis ao contexto.

Fonte: Adaptada de Panniello e Gorgoglione (2012).

Na **pré-filtragem contextual**, a informação de contexto é usada para selecionar apenas o conjunto dos dados mais relevantes para o contexto considerado. Os dados selecionados são então utilizados nos sistemas de recomendação tradicionais a fim de obter as recomendações desejadas. A principal vantagem dessa categoria é que ela permite o uso

das técnicas de recomendação tradicionais, ao mesmo tempo em que permite a utilização da informação contextual. Nesse âmbito, [Adomavicius et al. \(2005\)](#) propuseram uma abordagem que reduz o espaço multidimensional dos sistemas de recomendação sensíveis ao contexto a um espaço bidimensional. Além disso, propuseram uma abordagem, conhecida como *cReduction*, que combina a abordagem baseada em redução com algoritmos de filtragem colaborativa tradicionais.

Na **pós-filtragem contextual**, a informação de contexto é inicialmente ignorada, permitindo a utilização de qualquer sistema de recomendação tradicional para a geração das recomendações. Em seguida, o conjunto de recomendações produzido é ajustado considerando a informação contextual. Esses ajustes podem ocorrer de duas formas: filtrando as recomendações irrelevantes para um dado contexto; ou ajustando o *ranking* das recomendações na lista baseando-se em um determinado contexto. [Panniello e Gorgoglione \(2012\)](#) propuseram as abordagens conhecidas como *weightPoF* e *filterPoF*, que analisam os dados para um usuário específico em um contexto específico, calculando a probabilidade do usuário escolher algum item nesse contexto. As recomendações obtidas por meio de um sistema de recomendação tradicional são então ajustadas utilizando as probabilidades calculadas.

Na **modelagem contextual**, o contexto é usado diretamente nos modelos de recomendação, juntamente com os dados de usuários e itens. Na modelagem contextual a função de recomendação é verdadeiramente multidimensional. [Domingues et al. \(2013\)](#) propuseram a abordagem *daviBEST*, que trata o atributo de contexto como um item virtual para a construção do modelo de recomendação, permitindo também a utilização dos sistemas de recomendação tradicionais.

No entanto, independente da abordagem utilizada para gerar as recomendações, tradicional ou sensível ao contexto, muitos trabalhos têm identificado a necessidade em se explicar os resultados obtidos ([TINTAREV; MASTHOFF, 2007](#); [ZANKER; NINAUS, 2010](#); [LAMCHE et al., 2014](#); [BARAL et al., 2018](#)). Dessa forma, na próxima seção, serão apresentados os principais aspectos de explicações em sistemas de recomendação.

2.4 Explicações em Sistemas de Recomendação

Nos últimos anos, em razão do crescente interesse que grandes empresas têm demonstrado pelos sistemas de recomendação, inúmeras técnicas foram desenvolvidas, como métodos baseados em conteúdo ([LOPS et al., 2011](#)), em vizinhança ([DESHPANDE; KARYPIS, 2004](#)), em *deep learning* ([ZHANG et al., 2017](#)) e em fatoração de matrizes ([KOREN et al., 2009](#)). No entanto, muitos desses métodos funcionam como caixas-pretas, tal que não há transparência no processo da recomendação e nem informações adicionais, como explicações, que

acompanhem as recomendações (HERLOCKER *et al.*, 2000). Fornecer explicações que justifiquem as recomendações geradas pode aumentar a confiança e satisfação do usuário em relação ao sistema. Além disso, as explicações também podem auxiliar o usuário a entender quando/por que o sistema erra e, com isso, permitir a realimentação do sistema com novas informações, o que pode resultar em melhores recomendações (TINTAREV; MASTHOFF, 2007; ZANKER; NINAUS, 2010; LAMCHE *et al.*, 2014).

De maneira geral, Tintarev e Masthoff (2007) identificaram sete características ao usar explicações em sistemas de recomendação, que são:

- **Transparência** - auxiliar o usuário a entender como as recomendações foram geradas e de que maneira elas se encaixam em suas necessidades;
- **Escrutabilidade** - como o sistema coleta dados implicitamente, podem ser feitas suposições que não condizem com a realidade. Ao saber como o sistema funciona, o usuário pode corrigir essas suposições incorretas;
- **Confiança** - se o usuário entende por que as recomendações foram geradas, ele passa a confiar mais no sistema, tornando-se mais tolerante quando não são feitas boas recomendações;
- **Persuasão** - interfaces explicativas podem ser utilizadas para convencer usuários a testar ou comprar produtos;
- **Efetividade** - auxiliar o usuário a tomar boas decisões, escolhendo itens que de fato ele possa gostar;
- **Eficiência** - auxiliar o usuário a tomar decisões mais rapidamente, ajudando-o a decidir quais itens são melhores para ele;
- **Satisfação** - a presença de explicações para as recomendações pode facilitar a usabilidade do sistema, o que aumenta a satisfação do usuário.

O uso de explicações como mecanismo para aumentar a confiança do usuário em relação ao sistema remonta à época dos sistemas especialistas. Nesses sistemas, as explicações eram limitadas à exibição da sequência de regras aplicadas para atingir uma dada decisão, o que dificultava o seu entendimento por não-especialistas (NUNES; JANNACH, 2017). Desde então, muitas pesquisas têm sido feitas a fim de explorar o uso de explicações em outros tipos de sistemas, inclusive nos sistemas de recomendação.

Em especial, Herlocker *et al.* (2000) avaliaram diferentes tipos de explicação e interfaces de visualização nos sistemas de recomendação baseados em filtragem colaborativa. De maneira geral, foi realizado um estudo com usuários, onde lhes foi apresentada a recomendação de um filme junto com uma possível explicação, e lhes foi pedido que

atribuísem uma nota (na escala de um a sete) indicando a probabilidade de assistirem esse filme após terem visto a recomendação/explicação.

Nos seus resultados obtidos, [Herlocker et al. \(2000\)](#) identificaram que o tipo de explicação que levou a uma maior probabilidade do item ser de fato consumido foi um histograma com as avaliações feitas pelos usuários similares. Na Figura 6, é apresentado um exemplo de tal histograma. No caso desse exemplo, é possível observar que três vizinhos avaliaram o filme com as notas mais baixas (um e dois), sete vizinhos avaliaram o filme de maneira neutra (nota três), e 23 vizinhos avaliaram o filme positivamente (notas quatro e cinco). Ao receber essa explicação, um usuário poderia se sentir atraído a assistir ao filme, dado que ele consegue saber que usuários similares a ele gostaram do filme.

Figura 6 – O tipo de explicação que gerou as melhores avaliações no trabalho de [Herlocker et al. \(2000\)](#)

Fonte: [Herlocker et al. \(2000\)](#).

Outros experimentos também foram realizados por [Herlocker et al. \(2000\)](#), como por exemplo avaliar se as explicações aumentam a aceitação das recomendações. Em seus resultados, [Herlocker et al. \(2000\)](#) demonstraram que a maioria dos usuários de fato dão valor às explicações apresentadas (86% dos respondentes). Apesar de ser um trabalho antigo, os experimentos realizados por [Herlocker et al. \(2000\)](#) ainda são relevantes nos dias de hoje, principalmente por terem explorado diversos aspectos das explicações em sistemas de recomendação, como tipos, interfaces e aceitação das explicações.

No entanto, apesar de serem muito importantes nos sistemas de recomendação, as explicações não são o único aspecto que devem ser considerados ao desenvolver um sistema de recomendação. De nada adianta apresentar ótimas explicações, se as recomendações geradas não são corretas ou relevantes para o usuário em questão. Diante disso, é fundamental avaliar também a qualidade das recomendações geradas. Dessa forma, na seção seguinte, serão apresentados os principais métodos para avaliação dos sistemas de

recomendação.

2.5 Métodos de Avaliação dos Sistemas de Recomendação

Uma das principais etapas na construção de um sistema de recomendação é a definição do método de avaliação a ser utilizado. Em especial, existem três principais pontos que devem ser considerados: (i) os objetivos da avaliação, (ii) o tipo da avaliação ser realizado, e (iii) as métricas a serem consideradas.

O primeiro ponto a considerar são os objetivos do processo de avaliação (AGGARWAL, 2016). Na maioria das vezes se busca avaliar a acurácia das recomendações geradas, isto é, o quanto o sistema acerta ao gerar recomendações. No entanto, outros aspectos também podem ser avaliados, como a cobertura, a novidade, a serendipidade e a diversidade das recomendações. Em especial, um sistema possui alta cobertura quando ele recomenda uma alta proporção dos número total de itens existentes. A novidade consiste em recomendar itens que o usuário ainda não conhece. A serendipidade, por sua vez, ocorre quando o sistema traz um determinado nível de surpresa às recomendações; ou seja, quando o sistema recomenda um item relevante que o usuário não espera. Por fim, as recomendações devem ser diversas, isto é, os itens recomendados devem ser os mais diferentes possíveis entre si.

Outro ponto a se considerar na definição do processo de avaliação é o tipo de avaliação a ser realizado. De acordo com Ricci *et al.* (2015) e com Aggarwal (2016), existem três possibilidades: (i) estudo com usuários, (ii) avaliação *online*, e (iii) avaliação *offline*. No **estudo com usuários**, um determinado número de pessoas é recrutado, a fim de realizar tarefas específicas num sistema de recomendação. Por exemplo, aos usuários pode ser solicitado que assistam a um determinado filme, e atribuam uma nota indicando se gostaram ou não do filme. Na **avaliação *online***, por sua vez, a avaliação é realizada em um sistema real já em funcionamento. Nesse tipo de avaliação, por exemplo, os usuários poderiam ser amostrados aleatoriamente, e diversos algoritmos de recomendação poderiam ser testados em cada amostra de usuários. Por fim, na **avaliação *offline***, são utilizados dados históricos do sistema, como os dados de interações passadas dos usuários, como itens visualizados e avaliações feitas. Nesses casos, são utilizadas métricas de acurácia para avaliar a performance do sistema.

O terceiro ponto do processo de avaliação é a definição das métricas de performance a serem utilizadas. Essas métricas diferem de acordo com a forma como as recomendações são geradas. Se o sistema simplesmente prediz as avaliações que os usuários dariam aos itens ainda não consumidos, são utilizadas métricas de acurácia para predição de avalia-

ções. No entanto, se o sistema gera listas de itens recomendados, as métricas de acurácia utilizadas são para medir a qualidade do ranqueamento. Nas seções seguintes, esses dois tipos de métricas serão descritas.

2.5.1 Métricas de acurácia para predição de avaliações

Essas métricas geralmente são utilizadas nos sistemas que trabalham com avaliações numéricas. Elas buscam avaliar quanto o valor da avaliação predita pelo sistema difere da avaliação real presente nos dados de teste. Seja E o conjunto das avaliações especificados nos dados de teste, $r_{u,j}$ a avaliação real feita pelo usuário u ao item j , presente em E , e seja $\hat{r}_{u,j}$ a avaliação predita pelo sistema. O erro quadrático médio (*Mean Squared Error* - *MSE*) é dado por:

$$MSE = \frac{1}{|E|} \cdot \sum_{(u,j) \in E} (r_{u,j} - \hat{r}_{u,j})^2 \quad (2.17)$$

Quanto menores os valores de MSE, maior é a performance do sistema de recomendação avaliado.

Outra métrica utilizada é a raiz do erro quadrático médio (*Root Mean Squared Error* - *RMSE*), que tende a penalizar desproporcionalmente erros altos:

$$RMSE = \sqrt{\frac{1}{|E|} \cdot \sum_{(u,j) \in E} (r_{u,j} - \hat{r}_{u,j})^2} \quad (2.18)$$

Existem uma variedade de outras métricas para esse tipo de avaliação. A escolha da métrica mais apropriada deve considerar o que se deseja penalizar mais, como por exemplo a quantidade de avaliações preditas erroneamente ou o tamanho desses erros (avaliação predita mais distante da avaliação real). Para uma leitura mais aprofundada sobre diferentes métricas, consulte o livro de [Aggarwal \(2016\)](#).

2.5.2 Métricas de acurácia para ranqueamento de itens

As métricas de acurácia para ranqueamento são utilizadas quando o sistema recomenda listas de itens, ao invés de apenas predizer o valor da avaliação para os itens ainda não consumidos. A ideia por trás dessas métricas é avaliar quantos dos itens presentes nas listas de fato são relevantes. Nesse sentido, as métricas mais comumente utilizadas são: Precisão, *Recall*, e *Mean Average Precision* (*MAP*).

Seja N o número de itens na lista de recomendações, R . Além disso, seja H o conjunto de itens relevantes (*ground-truth*). A precisão é definida como a porcentagem dos itens recomendados que de fato são relevantes:

$$Precision(R) = 100 \cdot \frac{|R \cap H|}{|R|} \quad (2.19)$$

O *Recall*, por sua vez, é definido como a porcentagem dos itens relevantes que são recomendados:

$$\text{Recall}(R) = 100 \cdot \frac{|R \cap H|}{|H|} \quad (2.20)$$

Apesar de serem métricas muito utilizadas para avaliar a acurácia dos algoritmos de aprendizado de máquina tradicionais, existe uma desvantagem em utilizá-las no contexto dos sistemas de recomendação. Isso acontece porque essas métricas não consideram a ordenação inerente das listas de recomendações, onde o primeiro item tem maior probabilidade de ser consumido pelo usuário do que os itens subsequentes. De maneira geral, é interessante que os acertos (item recomendado de fato é relevante) que aconteçam no início da lista tenham um maior peso que os acertos que aconteçam em posições subsequentes. Nesse contexto, a métrica *Mean Average Precision (MAP)* surge como alternativa, e é definida por:

$$\text{MAP}(T_u) = \frac{1}{|T_u|} \cdot \sum_{j=1}^{|T_u|} \text{AP}(R_j, H_j) \quad (2.21)$$

tal que T_u são os usuários presentes no conjunto de teste, R_j é a lista de itens recomendados para o usuário j , e H_j é a lista de itens relevantes para o usuário j . Além disso, $\text{AP}(R_j, H_j)$ é definido por:

$$\text{AP}(R_j, H_j) = \frac{1}{|H_j|} \cdot \sum_{r=1}^{|H_j|} [\text{Precision}(R_j, r) \cdot \delta(R_j(r), H_j)] \quad (2.22)$$

tal que $\text{Precision}(R_j, r)$ é a precisão de todos os itens recomendados até a posição r e $\delta(R_j(r), H_j)$ é 1 se o item na posição r é um item relevante (ou seja, se $R_j(r) \subset H_j$), ou 0, caso contrário. Como a MAP é uma métrica de precisão, quanto maior o seu valor, melhores são listas de recomendações geradas para cada usuário.

2.6 Considerações Finais

Neste capítulo, foram apresentados os fundamentos principais sobre sistemas de recomendações, necessários para o entendimento deste trabalho de mestrado. Inicialmente, foram apresentados os modelos de representação dos dados de recomendação geralmente utilizados, que são: (i) Modelo Espaço-Vetorial, onde os dados são estruturados como uma matriz atributo-valor; e (ii) Modelo de Redes Heterogêneas, onde os dados são utilizados para definir os objetos e relações de uma rede complexa. Para problemas mais simples, como no caso dos sistemas de recomendação de duas dimensões (usuários e itens), a primeira abordagem pode gerar melhores resultados, em razão de sua simplicidade (AGGARWAL, 2016). No entanto, quando se deseja representar mais de duas dimensões, como nos sistemas de recomendação sensíveis ao contexto ou nos sistemas que utilizam outros tipos de informações (como aquelas extraídas das revisões textuais de usuários), pode não ser a

melhor estratégia. Nesses casos, o Modelo de Redes Heterogêneas surge como uma possibilidade, que permite explorar os relacionamentos entre as diferentes entidades e a influência que elas exercem sobre o processo como um todo, o que traz semântica ao processo de recomendação (PHAM *et al.*, 2016; SHI *et al.*, 2017).

Em seguida, foram apresentados os sistemas de recomendação tradicionais, que se caracterizam por considerar apenas as informações relativas a usuários e itens. Em especial, foram apresentados alguns dos algoritmos clássicos da área, bem como algoritmos considerados estado-da-arte, como os baseados em fatoração de matrizes. Em especial, nessa seção, buscou-se mostrar como os algoritmos funcionam para trazer clareza quanto à interpretabilidade das recomendações geradas por cada algoritmo.

Foram apresentados também os sistemas de recomendação sensíveis ao contexto, que além de utilizarem as informações de usuários e itens, consideram as informações contextuais presentes no processo de recomendação, como tempo, localização, companhia, dentre outros. Vários trabalhos já mostraram que o uso combinado dessas informações tende a gerar melhores recomendações.

Subsequentemente, foram mostrados os principais aspectos da geração de explicações em sistemas de recomendação, que buscam trazer, dentre outras coisas, maior transparência, scrutabilidade e confiança ao processo como um todo. Por fim, foi apresentado como é feita a avaliação dos sistemas de recomendação desenvolvidos, com enfoque nos objetivos da avaliação, nos seus tipos, e nas métricas de acurácia geralmente utilizadas.

Trabalhos Relacionados

Como apresentado anteriormente, este trabalho de mestrado teve como foco a geração de recomendações interpretáveis, utilizando para tanto as informações de usuários, itens e contextos. A fim de identificar a lacuna que este trabalho se propôs a resolver, foi realizada uma revisão da literatura nos principais portais bibliográficos da área de computação, como *ACM Digital Library*¹, *IEEE Xplore Digital*², *Scopus*³ e *Web of Science*⁴. Foi utilizada a seguinte *string* de busca:

(“*recommendation system*” OR “*recommender system*”)
AND
(“*explanation*” OR “*explainable*” OR “*interpretable*” OR “*interpretability*”)

Considerando as questões de pesquisa e os objetivos deste projeto, foram selecionados 17 trabalhos que consideram a geração de recomendações interpretáveis, bem como trabalhos que, além das recomendações, produzem explicações no processo. Esses trabalhos são apresentados na Tabela 5, juntamente com algumas informações consideradas importantes que foram extraídas de cada trabalho, como: (i) geração ou não de explicações utilizando contexto; (ii) dados utilizados para geração das explicações; (iii) modelo de representação de dados utilizado; e (iv) técnica utilizada.

Além disso, buscando identificar relacionamentos e tópicos em comum entre os trabalhos apresentados na Tabela 5, foi realizada uma análise de similaridade entre eles. Para isso, foram utilizadas a distância cosseno e a medida *Term Frequency–Inverse Document Frequency* (TF-IDF), que são adequadas para a análise de dados textuais. Para viabilizar a análise, foram extraídas as seguintes informações de cada artigo para o cálculo da simila-

¹ <http://dl.acm.org>

² <https://ieeexplore.ieee.org/Xplore/home.jsp>

³ <https://www.scopus.com>

⁴ <https://www.webofknowledge.com/>

Tabela 5 – Síntese de trabalhos relacionados e algumas características

ID	Trabalho	Contexto	Dados utilizados	Representação	Técnica Utilizada
1	Herlocker et al. (2000)	Não	Usuários e Itens	Espaço-Vetorial	Diferentes visualizações
2	Chen et al. (2013)	Não	<i>Tags</i>	Espaço-Vetorial	Nuvem de Palavras
3	Zhang et al. (2014)	Não	<i>Reviews</i>	Espaço-Vetorial	Extração de <i>features</i> e fatoração de matrizes
4	He et al. (2015)	Não	<i>Reviews</i>	Rede	Regularização em Redes
5	Chang et al. (2016)	Não	Itens	Espaço-Vetorial	<i>Template</i> elaborado por colaboradores
6	Pham et al. (2016)	Não	Usuários, Itens e Outros	Rede	Cadeias de Markov Multivariadas
7	Zheng et al. (2016)	Sim	Usuários, Itens e Contextos	Espaço-Vetorial	Sugestão de Contextos
8	Abdollahi e Nasraoui (2017)	Não	Usuários e Itens	Espaço-Vetorial	Termo de Explicabilidade
9	Chen e Wang (2017)	Não	Itens	Espaço-Vetorial	Prós e Contras
10	Guo et al. (2017)	Não	<i>Reviews</i>	Rede	Meta-Caminhos e PPR
11	Baral et al. (2018)	Não	<i>Reviews</i>	Rede	Mineração em Redes
12	Jiang et al. (2018)	Não	Usuários, Itens e Outros	Rede	Modelo de Caminhadas Aleatórias Generalizado
13	Sato et al. (2018)	Sim	Usuários, Itens e Contextos	Espaço-Vetorial	<i>FFM</i>
14	Kouki et al. (2019)	Não	Usuários, Itens e <i>Tags</i>	Espaço-Vetorial	Baseada em regras
15	Musto et al. (2019)	Não	Usuários e Itens	Rede	<i>Template</i> baseado em NLP
16	Donkers et al. (2020)	Não	Usuários, Itens e <i>Reviews</i>	Espaço-Vetorial	Mecanismos de Atenção (Deep Learning)
17	Ghazimatin et al. (2020)	Não	Usuários e Itens	Rede	Caminhadas Aleatórias em Grafos Dinâmicos

ridade: título, conferência à qual pertence, palavras-chave e outras palavras consideradas importantes para o trabalho em questão. Os trabalhos mais similares foram conectados em um grafo de relacionamento e, então, foi aplicado um algoritmo de agrupamento a fim de identificar grupos de trabalhos relacionados. As características mais importantes de cada grupo foram usadas para rotular tópicos em comum entre os trabalhos.

Na Figura 7, é apresentado o resultado dessa análise, que permite visualizar e entender, sob uma perspectiva estatística, como os trabalhos identificados se relacionam e quais são as suas características em comum. De maneira geral, é possível identificar a formação de três grupos de trabalhos. O primeiro grupo, formado pelos trabalhos de [Zheng et al. \(2016\)](#) e [Sato et al. \(2018\)](#), tem como característica principal a **utilização do contexto** para a geração das explicações. O segundo grupo, por sua vez, é formado pelos trabalhos de [He et al. \(2015\)](#), [Pham et al. \(2016\)](#), [Guo et al. \(2017\)](#), [Baral et al. \(2018\)](#), [Jiang et al. \(2018\)](#) e [Ghazimatin et al. \(2020\)](#), e tem como característica principal a representação do problema de recomendação como uma **rede heterogênea**. Por fim, o terceiro grupo é formado pelos demais trabalhos, que utilizam **diferentes técnicas** para geração e visualização das explicações. Esses trabalhos serão descritos nas Seções 3.1, 3.2 e 3.3, de acordo com os grupos gerados. Entre parênteses, ao lado de cada referência citada, será apresentada a numeração correspondente de acordo com a Tabela 5.

Figura 7 – Grafo de relacionamentos entre os trabalhos identificados na literatura e a sua organização em grupos de tópicos. Cada trabalho é representado por um nó e o número de cada nó corresponde ao *ID* do trabalho na Tabela 5. Dois trabalhos similares estão conectados por uma aresta. As cores definem grupos de trabalhos.

Fonte: Elaborada pelo autor.

3.1 Utilização de contexto para geração de explicações

[Zheng et al. \(2016\)](#) (Ref. #7) propuseram um método cujo objetivo é recomendar contextos nos quais os itens podem ser considerados adequados. Essa tarefa foi denominada por eles como *sugestão de contextos*. Diante disso, por exemplo, a seguinte mensagem poderia ser exibida ao usuário: “Quando estiver **treinando**, ouça as seguintes músicas”, quando as músicas apresentadas forem adequadas ao contexto **treinando**. Apesar dos autores do trabalho terem sugerido a utilização dos contextos recomendados como explicações, as explicações não foram criadas, uma vez que o foco do trabalho foi a geração de recomendações.

[Sato et al. \(2018\)](#) (Ref. #13), seguindo a mesma linha, utilizaram contextos para, num processo conjunto, gerar recomendações e explicações. Nesse sentido, em recomendações de restaurante, por exemplo, as explicações poderiam sugerir contextos apropriados para cada tipo de restaurante, tais como: “Esse restaurante é adequado para reuniões de negócio ou a lazer” ou “O restaurante a seguir é ótimo quando em companhia do(a) namorado(a)”.

De maneira geral, o método proposto por [Sato et al. \(2018\)](#) buscou associar aos itens do sistema contextos que o usuário pode encontrar no futuro. Nessa abordagem, no momento da recomendação, tanto o item quanto o contexto são desconhecidos e devem, portanto, ser estimados pelo sistema de recomendação. Diante disso, os autores do trabalho considerado utilizaram o método *Field-Aware Factorization Machine - FFM* ([JUAN et al., 2016](#)) buscando identificar interações par-a-par entre usuários, itens e contextos, de forma a encontrar correspondências entre usuários e itens, itens e contextos, e usuários e contextos.

Para gerar as recomendações e explicações, foram consideradas as interações dos itens e contextos identificadas que possuem maior relevância. Dessa forma, se existe um par item-contexto, com alta relevância, com item i e contexto c , o item i é recomendado para o usuário e o contexto c é utilizado para produzir a explicação. As explicações são geradas por meio do *template*: “Item i é recomendado a você porque é adequado ao contexto c ”.

Os experimentos realizados por [Sato et al. \(2018\)](#) foram baseados na coleta de *logs* de visitas de usuários a restaurantes por meio de uma plataforma de *crowdsourcing*. Os *logs* obtidos foram compilados e, então, utilizados para o treinamento da FFM. As recomendações e explicações geradas foram apresentadas aos mesmos usuários que participaram da coleta dos dados. Os resultados indicaram que as explicações baseadas em contexto produzidas pelo método apresentado não obtiveram melhores resultados que os outros tipos de explicações considerados. No entanto, a avaliação experimental utilizou apenas uma base de dados de um único domínio; novos experimentos, que considerem ba-

ses de dados de diferentes domínios, podem trazer resultados mais promissores ao método apresentado.

3.2 Utilização de redes heterogêneas para modelagem do problema de recomendação

He et al. (2015) (Ref. #4) propuseram um método de regularização em redes, denominado *TriRank*, a partir do qual é possível gerar recomendações e explicações, utilizando dados de usuários, itens e de aspectos extraídos de *reviews* de usuários, que correspondem às características dos itens que foram avaliadas na *review*.

A primeira etapa do processo proposto por **He et al. (2015)** consiste em construir uma rede tripartida com três tipos de nós (usuários, itens e aspectos), utilizando os dados de treinamento, que consistem em triplas na forma $\langle \text{usuário}, \text{item}, \text{aspecto} \rangle$. De maneira geral, são criados nós na rede para todos os usuários, itens e aspectos que aparecem nos dados. As arestas são definidas par-a-par entre todos os nós que aparecem em uma determinada tripla. Para exemplificar, considere a tripla $\langle \text{Marcos}, \text{Iron Man}, \text{Herói} \rangle$. Serão definidos os nós *Marcos*, *Iron Man* e *Herói*, e as arestas $r_{\text{Marcos}, \text{IronMan}}$, $r_{\text{Marcos}, \text{Herói}}$ e $r_{\text{IronMan}, \text{Herói}}$.

O método *TriRank* considera três matrizes, extraídas a partir das arestas da rede construída: matriz R , que representa a conexão entre usuários e itens; matriz Y , a conexão entre usuários e aspectos; e matriz X , a conexão entre itens e aspectos. O objetivo do *TriRank* consiste em estimar, iterativamente para cada usuário, valores numéricos para três vetores, $f(u)$, $f(p)$ e $f(g)$, que indicam, respectivamente, o grau de preferência do usuário-alvo em relação aos outros usuários, itens e aspectos do sistema. Para isso, além de considerar a estrutura da rede, o método *TriRank* também utiliza dados prévios do usuário-alvo: u^0 , que são os usuários similares a ele; p^0 , os itens que ele já avaliou anteriormente; e g^0 , os aspectos que ele já preferiu no passado.

O processo proposto por **He et al. (2015)** consiste em efetuar uma regularização na rede, por meio da minimização da Equação 5.1:

$$\begin{aligned} Q(f) = & \alpha \sum_{i,j} r_{ij} \left(\frac{f(u_i)}{\sqrt{d_i^u}} - \frac{f(p_j)}{\sqrt{d_j^p}} \right)^2 + \beta \sum_{j,k} x_{jk} \left(\frac{f(p_j)}{\sqrt{d_j^p}} - \frac{f(g_k)}{\sqrt{d_k^g}} \right)^2 + \gamma \sum_{i,k} y_{ik} \left(\frac{f(u_i)}{\sqrt{d_i^u}} - \frac{f(g_k)}{\sqrt{d_k^g}} \right)^2 + \\ & \eta_U \sum_i (f(u_i) - u_i^0)^2 + \eta_P \sum_j (f(p_j) - p_j^0)^2 + \eta_G \sum_k (f(g_k) - g_k^0)^2 \quad (3.1) \end{aligned}$$

em que $f(u_i)$ representa o grau de similaridade a ser encontrado do usuário-alvo em relação ao usuário i (de maneira similar, $f(p_j)$ e $f(g_k)$ foram definidos); $\sqrt{d_i^u}$ representa a soma

ponderada do grau de u_i ; α , β e γ representam os pesos das matrizes de usuário-item, item-grupo e usuário-grupo na regularização; e os parâmetros n_U , n_P e n_G representam os pesos dos dados prévios de usuários, itens e grupos de aspectos (u^0 , p^0 e q^0).

Por meio da minimização da Equação 5.1, são encontrados os valores estimados para os três vetores, $f(u)$, $f(p)$ e $f(g)$. Assim, para gerar as recomendações para um dado usuário, utiliza-se o vetor $f(p)$, que indica o grau de preferência do usuário em relação aos itens do sistema (são selecionados para recomendação os K itens com maior valor de $f(p)$). No processo proposto por He et al. (2015), as explicações são geradas utilizando os aspectos extraídos das *reviews*. Dessa forma, é utilizado o vetor $f(g)$, a partir do qual é possível obter os aspectos mais preferidos pelo usuário.

He et al. (2015) utilizaram duas bases de dados em seus experimentos: *Yelp*⁵, cujo domínio é o de recomendação de pontos de interesse, e *Amazon Eletronics* (MCAULEY; LESKOVEC, 2013), que considera as avaliações e *reviews* de usuários sobre produtos da *Amazon*⁶, em especial da categoria de eletrônicos. Os resultados mostraram que o desempenho obtido pelo *TriRank* superou o de todos os *baselines* considerados com significância estatística. No entanto, não foram avaliadas a qualidade das explicações geradas; os autores apenas mostraram, por meio de um estudo de caso, que os itens recomendados estão relacionados com os aspectos melhor ranqueados em $f(g)$ e que por isso podem ser usados como explicações.

Pham et al. (2016) (Ref. #6) propuseram um modelo genérico de recomendação utilizando redes heterogêneas, cuja característica principal é permitir a recomendação em diferentes domínios de aplicação. Para isso, como primeira etapa do processo, é necessário definir uma rede heterogênea considerando os dados de usuários, itens e de quaisquer outras entidades relevantes para o problema. Com a rede construída, a tarefa de recomendação foi tratada como um problema de identificação de proximidade entre nós considerando um nó alvo. Ou seja, a ideia consistiu em determinar os nós-item mais próximos em relação a um dado nó-usuário e, com base nisso, gerar as recomendações para esse usuário. Para isso, foram utilizadas as Cadeias de Markov Multivariadas. Foram realizados experimentos em bases de dados de diferentes domínios, como eventos, filmes e músicas, e os resultados obtidos superaram o desempenho de todos os *baselines* considerados.

Guo et al. (2017) (Ref. #10) propuseram uma rede heterogênea, denominada *Aspect-Aware Geo-Social Influence Graph* (AGSG), que combina em uma única representação informações de usuários, pontos de interesse e aspectos, extraídos de *reviews* de usuários. Como o processo de recomendação consiste em determinar os itens com maior relevância para um dado usuário, os autores do trabalho apresentado consideraram-no

⁵ http://www.yelp.com/dataset_challenge

⁶ www.amazon.com

como um problema de ranqueamento dos nós da rede. Para isso, propuseram uma abordagem que combina meta caminhos (SUN *et al.*, 2011) com *PageRank* personalizado (PPR) (HAVELIWALA, 2002) para gerar as recomendações, que obteve bons resultados. Apesar dessa abordagem não gerar explicações, esse trabalho é relevante para este mestrado por duas razões: (i) por apresentar uma modelagem da tarefa de recomendação utilizando redes heterogêneas; e (ii) por apresentar uma abordagem que realiza o ranqueamento dos nós considerando a estrutura heterogênea da rede, já que essa tarefa pode ser utilizada para a seleção dos nós mais relevantes no processo de geração das recomendações e explicações.

Baral *et al.* (2018) (Ref. 11) trabalharam no domínio de recomendações de pontos de interesse, utilizando *reviews* de usuários para extrair, categorizar e classificar termos que representam aspectos dos pontos de interesse. A partir das informações de usuários, pontos de interesse, aspectos e opiniões, foram geradas recomendações de pontos de interesse, que foram usadas para a geração das explicações.

De maneira geral, o processo proposto por Baral *et al.* (2018) é constituído de duas etapas principais: classificação das *reviews* e recomendação. Na etapa de classificação das *reviews*, os textos são inicialmente pré-processados para a remoção das *stop words* e, então, são utilizados em um módulo que realiza a extração dos termos que representam aspectos. Esses termos são categorizados em cinco classes de aspectos, relevantes para o domínio de recomendações de ponto de interesse: *Preço*, *Comida*, *Serviço*, *Facilidades* e *Outros*. A partir disso, é feita a classificação das sentenças das *reviews* de acordo com os aspectos relevantes em cada uma delas. Ou seja, para cada usuário, são identificados os aspectos preferidos em cada sentença. Esse processo também é utilizado para identificar os pontos de interesse especificados nas sentenças das *reviews*.

Na etapa de recomendação, as informações extraídas anteriormente são utilizadas como entrada de uma *Factorization Machine* - (FM) (RENDLE, 2010), que é um algoritmo baseado em fatoração de matrizes, para a geração das recomendações. Além disso, para a criação das explicações, é gerado um grafo bipartido de pontos de interesse e aspectos. Por meio de algoritmos de mineração em redes, são identificados, dentre os aspectos *Preço*, *Comida*, *Serviço*, *Facilidades* e *Outros*, aqueles que são mais relevantes para cada ponto de interesse recomendado. Os aspectos identificados são então utilizados para explicar as recomendações.

Baral *et al.* (2018) realizaram experimentos considerando três bases de dados: *Yelp*, *TripAdvisor*⁷ e *AirBnB*⁸. Os resultados obtidos indicaram que, para as três bases de dados, o processo proposto melhorou o desempenho das recomendações. Para avaliar o adequabilidade das explicações produzidas, foi feito um estudo de caso, comparando

⁷ <https://www.tripadvisor.com/>

⁸ <https://www.airbnb.com.br/>

os aspectos identificados nas explicações com os aspectos reais pelos quais os pontos de interesse são conhecidos. Em geral, as explicações se mostraram adequadas, apesar do método utilizado para a avaliação ser bastante limitado, uma vez que foram selecionadas apenas algumas explicações nesse processo.

Jiang et al. (2018) (Ref. #12) representaram o problema de recomendação por meio de uma rede heterogênea de usuários, itens e de outras entidades consideradas relevantes. A proposta principal desse trabalho foi a de utilizar o Modelo de Caminhadas Aleatórias Generalizado para gerar as recomendações. De maneira geral, a contribuição principal dos autores foi a de propor um método para aprender, a partir dos dados de treinamento, a matriz de probabilidades de transições utilizada no Modelo de Caminhadas Aleatórias. Foram realizados experimentos no domínio de restaurantes e filmes, e os resultados foram superiores aos do algoritmo *HeteRS* (**PHAM et al., 2016**), considerado estado-da-arte em recomendação em redes heterogêneas.

Ghazimatin et al. (2020) (Ref. #17) propuseram um método para geração de explicações utilizando redes heterogêneas e algoritmos de ranqueamento de nós, como o *Personalized PageRank*. O método proposto pelos autores tem como princípio remover cada uma das ações do usuário do seu histórico de interações, uma por vez, e verificar em que situações o conjunto de recomendações geradas se altera. Quando isso acontece, considera-se que a ação em questão é relevante para o processo de recomendação. Dessa forma, ao final do processo, o sistema apresenta como explicações ao usuário o conjunto dessas ações que mais impactaram às recomendações. No entanto, a principal limitação desse método é o fato de que as explicações geradas não condizem necessariamente com o algoritmo de recomendação adotado, mas sim com as fontes de dados utilizadas. Dessa forma, o método proposto por **Ghazimatin et al. (2020)** falha em trazer transparência total ao processo de recomendação.

3.3 Utilização de outras técnicas para geração e visualização de explicações

Herlocker et al. (2000) (Ref. #1) exploraram o impacto que diferentes estilos de explicação e interfaces de visualização, como histogramas e descrições detalhadas, exercem sobre a aceitação das recomendações. Em geral, os autores identificaram que histogramas contendo as avaliações dos usuários mais similares foram o estilo de explicação que mais contribuiu para a aceitação das recomendações. Além disso, foram realizados experimentos que verificaram que a maior parte dos usuários participantes considera as explicações fundamentais aos sistemas de recomendação.

Chen et al. (2013) (Ref. #2) criaram explicações na forma de uma nuvem de

palavras, utilizando *tags* associadas aos itens recomendados. O processo proposto pelos autores considerou as relações quartenárias entre usuários, *tags*, avaliações e itens para a geração das recomendações e explicações. Foi utilizado um algoritmo de decomposição de tensores para mapear as quatro entidades em um único espaço e então foram computadas distâncias entre essas entidades. A partir disso, dado um usuário alvo, os itens mais próximos foram recomendados e as *tags*, utilizadas como explicações em uma nuvem de palavras.

Zhang et al. (2014) (Ref. #3), por sua vez, utilizando de *reviews* de usuários, extraíram os aspectos pelos quais os itens são conhecidos (positiva e negativamente). Na *review* “A câmera possui ótima **resolução**, mas o **preço** é alto demais”, por exemplo, pode-se identificar que a câmera em questão é conhecida positivamente pela sua resolução e negativamente pelo seu preço. A partir dessas informações, os autores do trabalho utilizaram técnicas de fatoração de matrizes para gerar as recomendações e explicações, que então foram apresentadas ao usuário por meio de um *template*. Por exemplo: “Você pode estar interessado em câmeras com resolução alta, portanto os seguintes produtos são adequados”.

Chang et al. (2016) (Ref. #5) utilizaram *reviews* de usuários e um conjunto de *tags* para geração das recomendações e explicações. De maneira geral, o processo proposto pelos autores consistiu em identificar as *tags* mais relevantes associadas a cada item, por meio das suas *reviews*. Para cada *tag* identificada, com o auxílio de *crowdworkers*, foram gerados *templates* em língua natural descrevendo como ela é relevante para o item em questão. No processo de recomendação, foi considerada a *tag* mais importante associada ao item recomendado, considerando as preferências do usuário alvo, e o *template* correspondente foi utilizado como explicação.

Abdollahi e Nasraoui (2017) (Ref. #8) adaptaram o modelo de fatoração de matrizes tradicional (KOREN et al., 2009), para incluir um termo referente à explicabilidade dos itens na equação objetivo que é minimizada. O objetivo de Abdollahi e Nasraoui (2017) foi priorizar itens que tivessem um certo grau de explicabilidade no processo de recomendação, para propiciar maior transparência ao processo. Os resultados obtidos mostraram que o método é bastante adequado para a geração das recomendações. As principais vantagens desse método são a utilização apenas dos dados de usuários e itens, sem a necessidade de utilização de dados oriundos de fontes externas, como *reviews* de usuários; e integração da explicabilidade diretamente no módulo de recomendação. Porém, apesar de considerar a explicabilidade dos itens no processo de recomendação, Abdollahi e Nasraoui (2017) não propuseram explicações para as recomendações geradas, focando-se apenas na recomendação de itens explicáveis.

Chen e Wang (2017) (Ref. #9), utilizando técnicas de Mineração de Opiniões, extraíram aspectos e os sentimentos associados a partir de *reviews* de usuários. Essas in-

formações foram combinadas com as especificações dos itens para criar perfis dos usuários e dos itens. A proposta principal desse trabalho consistiu em gerar recomendações baseadas nos sentimentos extraídos e então agrupar os itens recomendados com base nas suas características em comum. As explicações geradas buscaram exibir os prós e contras das características dos itens recomendados, considerando as opiniões dos usuários que foram extraídas das *reviews*.

Kouki et al. (2019) (Ref. #14) exploraram o uso de diversas fontes de dados no processo de geração de explicações, visto que a maior parte dos trabalhos até o momento considerava apenas uma fonte de dados. Dessa forma, **Kouki et al. (2019)** incorporaram uma variedade de abordagens de recomendação (colaborativa e baseada em conteúdo) para geração de diferentes estilos de explicação. No entanto, a maior limitação desse método é que as recomendações são geradas por meio de um algoritmo baseado em regras previamente definidas, o que pode impedir o sistema de capturar todos os relacionamentos e interações existentes nos dados.

Musto et al. (2019) (Ref. #15) desenvolveram uma abordagem cujo objetivo principal é gerar explicações que sejam independentes do algoritmo utilizado. De maneira geral, o método proposto por **Musto et al. (2019)** busca criar uma representação em rede de forma a mapear os itens e o conjunto de recomendações gerado, por meio dos atributos/características desses itens (no caso dos itens serem filmes, seriam consideradas informações dos seus diretores e atores, por exemplo). Com base nos relacionamentos identificados entre as entidades dessa representação em rede, são extraídos os padrões de relacionamentos considerados mais relevantes. Tendo como base esse padrões identificados, o método gera, por fim, *templates* em linguagem natural, que são as explicações finais apresentadas ao usuário.

Uma característica interessante desse trabalho é observar como ele foi classificado pelo algoritmo de agrupamento apresentado na Figura 7. Em especial, observa-se que ele foi classificado como um trabalho do grupo em vermelho, cujo propósito é gerar explicações, interfaces e visualizações. De fato, o objetivo do trabalho de **Musto et al. (2019)** é apresentar um novo método/estilo para gerar explicações baseados em *templates* em linguagem natural, o que condiz com a sua classificação feita pelo algoritmo de agrupamento. Simultaneamente a isso, é possível identificar também que existe uma relação de similaridade entre ele (trabalho de número 15) e o trabalho de número 4, pertencente ao grupo de trabalhos cujo foco é a representação em redes heterogêneas. Isso provavelmente ocorre porque o método proposto por **Musto et al. (2019)** é construído utilizando uma rede heterogênea. Dessa forma, é um trabalho que exerce papel fundamental na análise apresentada na Figura 7, visto que interliga dois dos principais grupos.

Donkers et al. (2020) (Ref. #16) propuseram uma abordagem cujo propósito principal é gerar recomendações e explicações a partir de dados textuais de revisões de

usuários. Para isso, os autores utilizaram algoritmos estado-da-arte em processamento de linguagem natural, como os Mecanismos de Atenção (VASWANI *et al.*, 2017). Apesar do método proposto por Donkers *et al.* (2020) aparentar ser muito promissor, neste trabalho de mestrado buscou-se não utilizar algoritmos baseados em *deep learning*: na maioria das vezes, não é possível atribuir um significado claro a como o aprendizado desses algoritmos ocorre, uma vez que eles se baseiam no ajuste consecutivo dos pesos dos neurônios. Dessa forma, a capacidade de apresentar explicações que realmente mostrem como o algoritmo funciona pode ser prejudicada.

3.4 Considerações Finais

Como foi apresentado neste capítulo, os sistemas de recomendação tradicionais, como filtragem colaborativa e baseada em conteúdo, utilizam apenas os dados de usuários e itens para gerar as recomendações. No entanto, existem informações adicionais, como o contexto, que podem enriquecer esse processo e, com isso, aumentar a qualidade das recomendações geradas (ADOMAVICIUS; TUZHILIN, 2011; DOMINGUES *et al.*, 2014; SUNDERMANN *et al.*, 2016). Os sistemas de recomendação que utilizam informações contextuais são denominados sistemas de recomendação sensíveis ao contexto.

Existem inúmeras técnicas que foram desenvolvidas para ambos os sistemas, como métodos baseados em conteúdo (LOPS *et al.*, 2011), em vizinhança (DESHPANDE; KARYPIS, 2004), em fatoração de matrizes (KOREN *et al.*, 2009; KARATZOGLOU *et al.*, 2010) e em *deep learning* (ZHANG *et al.*, 2017). Porém, a maioria dos trabalhos que utilizam essas técnicas buscam primariamente aumentar o desempenho desses sistemas, considerando apenas métricas de acurácia, como precisão e *recall*, nesse processo. No entanto, vários outros trabalhos já demonstraram (TINTAREV; MASTHOFF, 2007; LAMCHE *et al.*, 2014; CHANG *et al.*, 2016; GUO *et al.*, 2017; BARAL *et al.*, 2018) que a transparência no processo de geração das recomendações exerce papel fundamental na satisfação final do usuário em relação ao sistema. Diante disso, é de extrema relevância apresentar explicações para as recomendações geradas pelos sistemas de recomendação.

Como mostrado na Tabela 5, os trabalhos identificados na literatura que exploram a geração de explicações em sistemas de recomendação são muitos e utilizam diferentes técnicas no processo. Apesar de várias pesquisas recentes utilizarem a informação contextual para gerar recomendações, como apresentado na Seção 2.3, ainda são poucos os trabalhos que usam esse tipo de informação para gerar explicações (somente foram identificados os trabalhos de Zheng *et al.* (2016) e Sato *et al.* (2018)). No entanto, nesses trabalhos foram utilizadas representações no modelo espaço-vetorial, que muitas vezes falham em capturar os relacionamentos e interações existentes entre as diferentes entidades envolvidas no processo (SHI *et al.*, 2017).

Além disso, como mostrado na Seção 3.2, as redes heterogêneas vêm sendo utilizadas para gerar recomendações e explicações, porque conseguem representar explicitamente em um único modelo todos os relacionamentos existentes entre as entidades consideradas, o que agrega semântica ao processo de recomendação. Ainda assim, nenhum trabalho identificado explorou a utilização conjunta de informações contextuais e representações em redes heterogêneas para geração de recomendações e explicações. Isso indica que este tópico, apesar de possuir grande potencial, ainda é pouco explorado na área de recomendação. Diante disso, este trabalho de mestrado busca produzir resultados nessa linha e, com base nisso, no Capítulo 4 é apresentada a proposta deste trabalho.

***HINCARS*: Um Método para Geração de Recomendações Interpretáveis Utilizando Contexto e Redes Heterogêneas**

Como foi apresentado na Seção 2.4, várias informações podem ser utilizadas no processo de geração das recomendações, como *tags* (CHEN *et al.*, 2013), aspectos e características principais dos itens (HERLOCKER *et al.*, 2000; CHANG *et al.*, 2016; CHEN; WANG, 2017), bem como *reviews* de usuários (ZHANG *et al.*, 2014; HE *et al.*, 2015; BARAL *et al.*, 2018). Além de possibilitarem recomendações mais precisas, essas informações, quando usadas em modelos caixa-branca, podem também trazer interpretabilidade ao processo de recomendação. Em especial, considerando a boa acurácia obtida pelos sistemas que utilizam informações contextuais, agregar o contexto nesse processo torna-se uma possibilidade com grande potencial, fato que pode ser evidenciado pelos trabalhos recentes que estão utilizando esse tipo de informação para criação de modelos interpretáveis (ZHENG *et al.*, 2016; SATO *et al.*, 2018).

No entanto, o modelo de representação de dados utilizado no processo de geração das recomendações exerce papel fundamental na qualidade do resultado final obtido. Em geral, representações de dados em rede conseguem capturar melhor os relacionamentos e interações existentes entre as diferentes entidades do processo de recomendação (como usuários, itens e contextos), possibilitando que recomendações com maior acurácia sejam geradas (PHAM *et al.*, 2016; SHI *et al.*, 2017; JIANG *et al.*, 2018). Além disso, algoritmos de mineração em redes, em geral, permitem entender como o aprendizado ocorre, que é uma característica importante no processo de geração de recomendações interpretáveis (PHAM *et al.*, 2016; HE *et al.*, 2015; GUO *et al.*, 2017; BARAL *et al.*, 2018; SATO *et al.*, 2018; JIANG *et al.*, 2018).

Diante disso, neste trabalho de mestrado é proposto o método ***HINCARS*** (*Hete-*

rogeous Information Network for Context-Aware Recommender Systems) para geração de recomendações interpretáveis, que é baseado em redes heterogêneas e que utiliza, além das informações de usuários e itens, quaisquer outras informações adicionais que sejam relevantes ao processo de recomendação (como contextos, aspectos e *tags*). Em especial, neste trabalho o método proposto foi instanciado para o uso de informações contextuais, mas o processo pode ser adaptado para quaisquer outros tipos informações. Na Figura 8, é apresentada uma visão geral do método proposto, que é composto por três etapas principais: (i) **cálculo de similaridades** entre as entidades de um mesmo tipo envolvidas no processo; (ii) **construção da rede heterogênea**, estabelecendo as relações existentes entre os nós da rede; e (iii) **geração das recomendações**, utilizando a rede construída e o algoritmo *GNetMine*, descrito na Seção 2.2.2.1.2.

Figura 8 – Visão geral da proposta deste mestrado: um método para geração de recomendações interpretáveis utilizando informações contextuais e redes heterogêneas

Fonte: Elaborada pelo autor.

O fluxo de execução do método **HINCARS** pode ser dividido em duas fases: uma fase de preparação, que abrange a 1ª e 2ª etapas, e uma fase em que o aprendizado realmente ocorre, que abrange a 3ª etapa. De maneira geral, na fase de preparação, os dados são utilizados para a criação dos artefatos necessários para que o aprendizado

ocorra, que são as matrizes de similaridades entre usuários e itens, bem como a rede heterogênea relacionando as entidades envolvidas no processo (usuários, itens e contextos). Na etapa do aprendizado, por sua vez, esses artefatos são utilizados para a geração das recomendações. Como será apresentado na Seção 4.3, o algoritmo utilizado para isso é um tipo de aprendizado semi-supervisionado transdutivo, então não há a necessidade de criação de um modelo de recomendação propriamente dito, uma vez que a preferência do usuário pode ser estimada diretamente. Dessa forma, a 3ª etapa do método proposto (que é a etapa de geração de recomendações) é executada diversas vezes, uma para cada usuário de que se deseja recomendações. Com isso, podem ser geradas listas de recomendações para cada um dos usuários do sistema. Nas seções seguintes, as três etapas da proposta deste mestrado serão apresentadas em detalhes.

4.1 Cálculo de Similaridade

Como mencionado na Seção 2.2, muitos métodos de recomendação consideram informações de similaridade entre as entidades para gerar as recomendações. Na filtragem baseada em conteúdo, por exemplo, as informações de itens similares são usadas para recomendar itens com perfis similares à outros que o usuário já consumiu no passado. Na filtragem colaborativa, por sua vez, as avaliações de usuários (ou itens) similares são combinadas para prever os itens de interesse a um dado usuário-alvo. Dessa forma, observa-se que essas informações de similaridade constituem fonte de informação valiosa no processo de geração das recomendações (AGGARWAL, 2016).

Com isso, no processo definido neste mestrado, esta etapa tem como objetivo realizar o cálculo de similaridades entre os nós de um mesmo tipo na rede, uma vez que essas informações serão utilizadas para a definição das relações da rede heterogênea e também serão utilizadas no processo de geração das recomendações. Para cada tipo diferente de entidade (como usuários e itens), deve-se obter uma matriz de similaridades, S , entre os nós daquele tipo:

$$S_t = \begin{pmatrix} s_{t1,1} & s_{t1,2} & s_{t1,3} & \cdots & s_{t1,n} \\ s_{t2,1} & s_{t2,2} & s_{t2,3} & \cdots & s_{t2,n} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ s_{tm,1} & s_{tm,2} & s_{tm,3} & \cdots & s_{tm,n} \end{pmatrix} \quad (4.1)$$

tal que $s_{ti,j}$ representa a similaridade entre os nós i e j do tipo t . No caso deste trabalho de mestrado, foram consideradas apenas as informações tradicionais de usuários e itens nesta etapa. Como em geral há poucos valores possíveis para cada variável contextual (e.g. há quatro possíveis valores para *estações do ano* e alguns poucos valores para *companhia*) quando comparado ao número de usuários e itens, escolheu-se por não calcular

a similaridade entre os nós das variáveis contextuais. Portanto, esta etapa gera como saída 2 matrizes de similaridades, que são: S_{user} e S_{item} . Nas Seções 4.1.1 e 4.1.2, serão apresentados, respectivamente, os processos para o cálculo das matrizes de similaridade de usuário e item.

4.1.1 Similaridade entre usuários

Para o cálculo das similaridades entre usuários, são consideradas as interações que eles tiveram com os itens do sistema. Intuitivamente, os usuários u_f e u_k são considerados similares se eles avaliaram similarmente o mesmo conjunto de itens. Formalmente, seja I_c o conjunto de itens avaliados tanto pelo usuário u_f como pelo usuário u_k . A similaridade s_{u_f, u_k} é dada pela similaridade cosseno, ou seja:

$$s_{u_f, u_k} = \cos(u_f, u_k) = \frac{\sum_{i \in I_c} r_{u_f, i} \cdot r_{u_k, i}}{\sqrt{\sum_{i \in I_c} (r_{u_f, i})^2} \sqrt{\sum_{i \in I_c} (r_{u_k, i})^2}} \quad (4.2)$$

tal que $r_{u_f, i}$ e $r_{u_k, i}$ são as avaliações dadas ao item i pelos usuários u_f e u_k respectivamente.

Em alguns casos, o usuário u_f pode ter avaliado o mesmo item em diferentes contextos. Por exemplo, quando os itens recomendados são **pacotes de viagem**, o usuário pode avaliar uma viagem para o litoral como 1 (muito ruim) no **inverno**, e como 5 (muito boa) no **verão**. Nesses casos, é considerada a média das avaliações nos diferentes contextos como o valor da avaliação do usuário para o item em questão. No caso do exemplo, $r_{u_f, \text{litoral}} = \frac{1+5}{2} = 3$

4.1.2 Similaridade entre itens

Para o cálculo das similaridades entre itens, é considerada a maneira como os itens foram avaliados pelos usuários do sistema. Intuitivamente, os itens i_p e i_q são considerados similares se foram avaliados similarmente pelo mesmo conjunto de usuários. Formalmente, seja U_c o conjunto de usuários que avaliaram tanto o item i_p e i_q . A similaridade s_{i_p, i_q} também é dada pela similaridade cosseno, ou seja:

$$s_{i_p, i_q} = \cos(i_p, i_q) = \frac{\sum_{u \in U_c} r_{u, i_p} \cdot r_{u, i_q}}{\sqrt{\sum_{u \in U_c} (r_{u, i_p})^2} \sqrt{\sum_{u \in U_c} (r_{u, i_q})^2}} \quad (4.3)$$

tal que r_{u, i_p} e r_{u, i_q} são as avaliações dadas aos itens i_p e i_q pelo usuário u . De maneira análoga, se houver avaliações para um mesmo usuário e item em diferentes contextos, é considerada a média das avaliações.

Na próxima seção, será apresentado o processo pelo qual a rede heterogênea proposta é construída, a partir dos dados de usuários, itens e contextos, bem como das matrizes de similaridades calculadas.

4.2 Construção da Rede Heterogênea

Em sistemas de recomendação, um dos modelos de representação de dados geralmente utilizados são as redes heterogêneas, que permitem relacionar todas as diferentes entidades envolvidas na tarefa de recomendação (usuários, itens, contextos, entre outros). Esse modelo foi adotado neste trabalho de mestrado por permitir explorar todas as interações e relacionamentos existentes entre as entidades, o que traz semântica ao processo de recomendação, permitindo que recomendações interpretáveis sejam geradas.

Como mencionado na Seção 2.1.2, uma rede é definida por uma tripla $N = \langle \mathcal{O}, \mathcal{R}, \mathcal{W} \rangle$, tal que: $\mathcal{O}$, é o conjunto de objetos da rede; $\mathcal{R}$, é o conjunto de relações; e $\mathcal{W}$ é o conjunto de pesos das relações entre os objetos. Uma rede é dita heterogênea se o conjunto $\mathcal{O}$ possui mais de um tipo de objeto. Além disso, como também já mencionado, algoritmos de mineração em redes são fortemente impactados pela estrutura da rede construída (SHI *et al.*, 2017). Portanto, o principal objetivo desta etapa foi definir esses três conjuntos da maneira mais adequada possível.

No caso deste trabalho de mestrado, o conjunto de objetos, $\mathcal{O}$, possui nós de diferentes tipos: m nós do tipo usuário, n nós do tipo item, e nós referentes a cada uma das K variáveis contextuais consideradas. O conjunto de relações $\mathcal{R}$ e o de pesos $\mathcal{W}$ foram definidos por quatro abordagens distintas, que são: **N-Partida**, **Heterogênea Usuários**, **Heterogênea Itens** e **Completa**, que serão descritas, respectivamente, nas Seções 4.2.1, 4.2.2, 4.2.3 e 4.2.4. O objetivo em adotar essas quatro abordagens foi explorar como a qualidade das recomendações é afetada em termos de acurácia pela estrutura da rede gerada. Nas seções seguintes, portanto, essas abordagens serão apresentadas em detalhes.

4.2.1 Abordagem N-Partida

Segundo Newman (2010), uma rede é dita n-partida quando os nós da rede se relacionam apenas com nós que sejam de tipos diferentes, e ainda existam n tipos de nós. Dessa forma, nessa abordagem foram definidas relações apenas entre as entidades de tipos diferentes da tarefa de recomendação; isto é, foram definidas relações entre usuários e itens, usuários e as dimensões contextuais, e entre os itens e as dimensões contextuais. Um esquemático de uma rede com quatro tipos de nós (usuários, itens, contextos C_i e contextos C_j), construída por meio dessa abordagem, é apresentado na Figura 9. Nesta figura, a aresta em preto ilustra as relações entre usuários e itens; as arestas em vermelho e verde, as relações

entre usuários e as duas dimensões contextuais (C_i e C_j , respectivamente); e as arestas em amarelo e azul, as relações entre itens e as dimensões contextuais.

Figura 9 – Esquemático da rede heterogênea proposta para a **Abordagem N-Partida**. Ligações entre entidades de diferentes tipos: usuário-item (preto), usuário-contexto C_i (vermelho), usuário-contexto C_j (verde), item-contexto C_i (amarelo) e item-contexto C_j (azul).

Fonte: Elaborada pelo autor.

Para a definição das arestas relacionando as entidades, foram utilizados dados de interação do usuário com o sistema, como informações de visualização e avaliação dos itens, e os cenários (contextos) nos quais essa interação aconteceu. A seguir, será descrito como cada tipo de relação foi criada.

1. **Relação usuário-item (em preto):** um usuário u está conectado a um item i se ele interagiu com esse item. O peso da relação é dado pela média das avaliações que esse usuário fez ao item em questão. Por exemplo, em recomendações de restaurantes, se o usuário avaliou uma **churrascaria** no **almoço** com nota 5 (muito boa) e a mesma churrascaria no **café da manhã** com nota 1 (muito ruim), então o peso da aresta conectando o usuário a essa churrascaria será $\frac{5+1}{2} = 3$.
2. **Relações usuário-contexto C_i (em vermelho) e usuário-contexto C_j (em verde):** um usuário u está conectado a um contexto c se ele interagiu com algum item nesse contexto. O peso da relação é dado pela média das avaliações que o usuário fez estando nesse contexto. Por exemplo, em recomendações de filmes para se ver **com a família**, se o usuário avaliou **Harry Potter** com nota 5, e **Rei Leão** com nota 4, então o peso da aresta conectando o usuário e o contexto **com a família** será $\frac{5+4}{2} = 4,5$.
3. **Relações item-contexto C_i (em amarelo) e item-contexto C_j (em azul):** um item i está conectado a um contexto c se ele foi visto/avaliado nesse contexto.

O peso da relação é dado pela média das avaliações feitas a esse item e contexto. Por exemplo, em recomendações de pacotes de viagens, se um usuário avaliou uma viagem ao **litoral** no **inverno** com nota 1 e outro usuário avaliou com nota 2, então o peso da aresta conectando **litoral** e **no inverno** será de $\frac{1+2}{2} = 1,5$

4.2.2 Abordagem Heterogênea Usuários

Numa rede heterogênea, além das relações entre nós de tipos diferentes, podem existir relações conectando nós do mesmo tipo. Dessa forma, nessa abordagem, além das relações n-partidas que foram detalhadas na seção anterior, foram acrescentadas relações entre usuários, indicando quando existe similaridade entre eles. Em sistemas de recomendação, essas informações devem ser consideradas, porque, em geral, usuários similares têm padrões de avaliação similares, o que pode impactar nas recomendações geradas. Na Figura 10, é apresentado um esquemático de uma rede de quatro nós (usuários, itens, contextos C_i e contextos C_j), construída por meio dessa abordagem.

Figura 10 – Esquemático da rede heterogênea proposta para a **Abordagem Heterogênea Usuários**. Além das ligações entre entidades de diferentes tipos, existem ligações entre usuários similares (em roxo).

Fonte: Elaborada pelo autor.

Para a definição das arestas entre usuários, foi utilizada a matriz de similaridades de usuários, S_{user} , cujo cálculo foi apresentado na Seção 4.1.1. Dessa forma, um usuário u_i está conectado a um usuário u_j se a similaridade entre eles, s_{u_i, u_j} for superior a um dado limiar, que é um parâmetro de entrada (`threshold_users`) do método **HINCARS**. O peso da aresta é a própria similaridade entre os usuários (s_{u_i, u_j}).

4.2.3 Abordagem Heterogênea Itens

Nessa abordagem, além das relações n-partidas que foram detalhadas na Seção 4.2.1, também foram consideradas relações entre itens, indicando quando existe similaridade entre eles. Na Figura 11, é apresentado um esquemático de uma rede de quatro nós (usuários, itens, contextos C_i e contextos C_j), construída por meio dessa abordagem.

Figura 11 – Esquemático da rede heterogênea proposta para a **Abordagem Heterogênea Itens**. Além das ligações entre entidades de diferentes tipos, existem ligações entre itens similares (em vermelho).

Fonte: Elaborada pelo autor.

Para a definição das arestas entre itens, foi utilizada a matriz de similaridades de itens, S_{item} , que foi apresentada na Seção 4.1.2. Dessa forma, um item i_p está conectado a um item i_q se a similaridade entre eles, s_{i_p, i_q} for superior a um dado limiar, que é um parâmetro (`threshold_items`) do método **HINCARS**. O peso da aresta é a própria similaridade entre os itens.

4.2.4 Abordagem Completa

Nessa abordagem, todas as relações definidas até o momento, que foram descritas nas seções anteriores, são agregadas em uma única representação. Portanto, além das relações n-partidas, são definidas também relações entre usuários e itens similares. Nesse abordagem, como novidade, são criadas relações entre diferentes variáveis contextuais. Na Figura 12, é apresentado um esquemático da rede construída por meio dessa abordagem.

Para a definição das arestas entre as variáveis contextuais, foram utilizados os dados de interação dos usuários com o sistema. Mais especificamente, o contexto t do tipo C_i ($C_{i,t}$) está conectado ao contexto r do tipo C_j ($C_{j,r}$) (aresta dirigida) se usualmente eles são consumidos em conjunto. O peso da relação é dado pela frequência com que isso acontece.

Figura 12 – Esquemático da rede heterogênea proposta para a **Abordagem Completa**. Além das ligações entre entidades de diferentes tipos, existem ligações entre usuários e itens similares (em roxo e vermelho, respectivamente) e também entre diferentes dimensões contextuais (em verde).

Fonte: Elaborada pelo autor.

Para exemplificar, suponha que o domínio é o de recomendações de carros em um serviço de aluguel de automóveis, sendo que os dados das interações dos usuários estão representados na Tabela 6. Há duas variáveis contextuais: **Companhia**, com dois possíveis valores (*família* e *sozinho*) e **Tipo de Viagem**, com três possíveis valores (*aventura*, *negócios* e *lazer*).

Tabela 6 – Dados-exemplo de interação de usuários para recomendações de carros em serviços de aluguel de automóveis

Usuário	Carro	Companhia	Tipo da Viagem	Nota
U1	A	família	aventura	5
U1	B	sozinho	negócios	2
U1	B	família	aventura	4
U2	C	família	lazer	3

Existe uma relação entre *família* (variável contextual **Companhia**) e *aventura* (variável contextual **Tipo da Viagem**), porque eles aparecem juntos em duas das três vezes que o contexto *família* aparece; portanto, o peso da relação é $\frac{2}{3}$. De maneira similar, existe uma relação entre o contexto *sozinho* (variável contextual **Companhia**) e *negócios* (variável contextual **Tipo da Viagem**), porque em todas as vezes que *sozinho* aparece, *negócios* também aparece (peso $\frac{1}{1}$). Como essas relações entre diferentes dimensões contextuais são dirigidas, também é possível criar uma aresta entre o contexto *Aventura* (variável contextual **Tipo da Viagem**) e o contexto *Família* (variável contextual **Companhia**), porque todas as vezes que *Aventura* aparece, *Família* também aparece (peso $\frac{2}{2}$).

Na próxima seção, será apresentado o processo pelo qual as recomendações são

geradas a partir da rede heterogênea construída.

4.3 Geração das Recomendações

De acordo com [Aggarwal \(2016\)](#), a tarefa de recomendação pode ser modelada de duas maneiras: predição de avaliações ou ranqueamento de itens. A primeira forma consiste em prever os valores das avaliações para os itens ainda não avaliados pelo usuário, enquanto a segunda, consiste em ranquear um conjunto de itens que podem ser de interesse do usuário. A modelagem adotada neste trabalho de mestrado foi o ranqueamento de itens; portanto, para cada usuário, o método **HINCARS** gera como saída uma lista de recomendações de itens.

Em ambas as modelagens, a geração de recomendações pode ser vista como um problema de classificação. Se as avaliações dos usuários são categóricas (como *Muito Bom*, *Bom*, *Regular*, *Ruim*, *Muito Ruim*), os itens avaliados por eles podem ser considerados como os exemplos rotulados na tarefa de classificação. Dessa forma, o objetivo seria então classificar os itens restantes, ainda não avaliados pelos usuários, em uma dessas categorias. No entanto, em razão da esparsidade dos dados inerente aos problemas de recomendação, existem poucos dados rotulados em comparação ao grande número de usuários e itens do sistema, o que pode impactar a acurácia dos algoritmos de classificação tradicionais.

Dessa maneira, a fim de mitigar esse problema, o processo de geração de recomendações pode ser visto como um tipo de aprendizado semi-supervisionado transdutivo, que realiza a classificação de todos os dados a partir de uma pequena quantidade de dados rotulados. Em especial, existem vários algoritmos baseados em redes homogêneas e heterogêneas que podem ser utilizados para esse fim, como o *LLCG* ([ZHOU; SCHÖLKOPF, 2004](#)) e o *GNetMine* ([LI et al., 2010](#)). Diante da boa performance reportada pelos autores do *GNetMine* e da sua capacidade de considerar redes de topologia arbitrária, esse foi o algoritmo escolhido para a geração das recomendações neste trabalho de mestrado.

Como apresentado na Seção 2.2.2.1.2, o *GNetMine* realiza a propagação dos rótulos (classes) dos elementos já rotulados para os nós restantes da rede, respeitando as premissas de consistência e de informação prévia. Essas premissas estabelecem, respectivamente, que nós próximos devem possuir rótulos similares e que nós previamente rotulados, em geral, não devem ter suas classes alteradas no processo de propagação. Para isso, portanto, o algoritmo considera a estrutura da rede (tipos dos objetos e relações entre eles), que é descrita pelas matrizes $R_{i,j}$, e considera também as informações prévias (rótulos dos objetos já classificados), que são descritas pelas matrizes Y_i , tal que $i, j \in \{1, \dots, m\}$, m sendo o número de tipos diferentes de objetos da rede. As matrizes $R_{i,j}$ são as matrizes de adjacências da rede heterogênea proposta na Seção 4.2, considerando as relações entre

os nós do tipo i e do tipo j . O processo para definição das matrizes Y_i será apresentado na seção seguinte.

4.3.1 Abordagens para definição das matrizes de informação prévia

No caso dos sistemas de recomendação, como mencionado anteriormente, a informação prévia de objetos já rotulados consiste na avaliação categórica que um dado usuário fez aos itens do sistema. Dessa forma, é a partir dos dados de interação do usuário com o sistema, que as matrizes de informação prévia são criadas. Neste trabalho de mestrado, foram propostas três abordagens para a definição dessas matrizes, a fim de explorar como elas impactam a acurácia das recomendações geradas. Na Tabela 7, são apresentados alguns dados de interação de usuários em um serviço de recomendação de filmes, que servirão para exemplificar o processo de construção dessas matrizes em cada uma das abordagens.

Tabela 7 – Dados-exemplo de interação de usuários para recomendações em serviços de *streaming* de filmes

Usuário	Filme	Companhia	Nota
U_1	Harry Potter	Família	5
U_1	Rei Leão	Sozinho	1
U_1	Harry Potter	Sozinho	4
U_2	Anabelle	Sozinho	3
U_2	Harry Potter	Família	5
U_3	Anabelle	Família	1

Como o processo de recomendação é realizado para apenas um usuário por vez, para a construção das matrizes de informação prévia, são utilizados apenas os dados de interação desse usuário com o sistema. A seguir, as três abordagens para a definição dessas matrizes serão apresentadas em detalhes. Para exemplificar cada uma das abordagens, será considerado que as recomendações têm como alvo o usuário U_1 .

- **Abordagem Simples:** apenas os nós do tipo item são rotulados, e o rótulo de cada item é dado pela avaliação que o usuário fez a esse item. Se o usuário avaliou o item em mais de um contexto, é considerado o teto da média das avaliações. Para o item *Harry Potter*, que foi avaliado em dois diferentes contextos (*família* e *sozinho*) pelo usuário U_1 , é considerado o rótulo 5 ($\lceil \frac{5+4}{2} \rceil = \lceil 4,5 \rceil = 5$). Para o item *Rei Leão*, é atribuído o rótulo 1. Na Figura 13a, é apresentada a matriz de informação prévia para o exemplo.
- **Abordagem colaborativa:** além de rotular os itens que o usuário alvo avaliou, como definido na abordagem anterior, a matriz de informação prévia de itens é enriquecida com as avaliações feitas pelos usuários similares. Seja o conjunto $U_{similar}$

dos usuários similares ao usuário u . Para cada avaliação $r_{u_s,i}$ feita pelo usuário $u_s \in U_{similar}$ ao item i , rotula-se o item i com o valor da avaliação feita por u_s . Da mesma forma como no item anterior, se o usuário similar tiver avaliado o item em diferentes contextos, é considerado o teto da média das avaliações como o rótulo do item. Para exemplificar, considere os dados da Tabela 7. Nota-se que o usuário U_2 é similar ao usuário U_1 , porque ambos avaliaram *Harry Potter* da mesma forma. Em razão disso, o item *Anabelle*, ainda não visto por U_1 , é rotulado com a nota atribuída por U_2 (nesse caso, 3).

- **Abordagem baseada em usuários similares:** a matriz de informação prévia de itens, Y_{item} , é rotulada da mesma forma como na **abordagem simples**. No entanto, nessa abordagem, propõe-se também definir a matriz de informação prévia de usuários, Y_{user} , considerando as informações de similaridade entre usuários, que são valiosas no processo de recomendação, como apresentado na Seção 4.1. Seja $U_{similar}$ o conjunto dos usuários similares ao usuário alvo da recomendação. A ideia é rotular os usuários similares de acordo com o teto do valor da métrica de similaridade, que foi previamente reescalada para o intervalo das avaliações. Ou seja, quanto mais similares os usuários, maior o rótulo que irão receber. No caso do exemplo, as similaridades foram reescaladas do intervalo $[-1, 1]$ para o intervalo $[1, 5]$, que é o intervalo das avaliações. Dessa forma, como o usuário similar a U_1 é o usuário U_2 com similaridade máxima, rotula-se o usuário U_2 com o rótulo 5.

Y_{item}	1	2	3	4	5
Harry Potter	0	0	0	0	1
Rei Leão	1	0	0	0	0
Anabelle	0	0	0	0	0

(a) Abordagem simples

Y_{item}	1	2	3	4	5
Harry Potter	0	0	0	0	1
Rei Leão	1	0	0	0	0
Anabelle	0	0	1	0	0

(b) Abordagem colaborativa

Y_{item}	1	2	3	4	5
Harry Potter	0	0	0	0	1
Rei Leão	1	0	0	0	0
Anabelle	0	0	0	0	0

(c) Abordagem baseada em usuários similares

$Y_{usuario}$	1	2	3	4	5
U₁	0	0	0	0	0
U₂	0	0	0	0	1
U₃	0	0	0	0	0

Figura 13 – Matrizes de informação prévia para os dados de exemplo considerando cada uma das abordagens. Só são exibidas as matrizes de informação prévia dos tipos definidas na abordagem. As matrizes para os outros tipos são todas zero.

Na próxima seção, será apresentado como as matrizes de informação prévia, Y_i e as matrizes de relações, $R_{i,j}$ são usadas pelo algoritmo *GNetMine* para a propagação dos rótulos já definidos aos nós restantes da rede.

4.3.2 Propagação dos rótulos pelo *GNetMine*

Na Seção 2.2.2.1.2, o funcionamento do algoritmo *GNetMine* foi detalhado. De maneira geral, o objetivo principal do algoritmo é minimizar uma equação custo (Equação 2.9), respeitando os diferentes tipos de relações (matrizes $R_{i,j}$) e os rótulos iniciais dos objetos (matrizes Y_i). Para facilitar o entendimento, a Equação 2.9 é replicada a seguir:

$$J(f_1^{(k)}, \dots, f_m^{(k)}) = \sum_{i,j=1}^m \lambda_{i,j} \sum_{p=1}^{n_i} \sum_{q=1}^{n_j} R_{ij,pq} \left(\frac{1}{\sqrt{D_{ij,pp}}} f_{ip}^{(k)} - \frac{1}{\sqrt{D_{ji,qq}}} f_{jq}^{(k)} \right) + \sum_{i=1}^m \alpha_i (f_i^{(k)} - y_i^{(k)})^T (f_i^{(k)} - y_i^{(k)}). \quad (4.4)$$

tal que m é o número de tipos de objetos, e n_i é o número de objetos do tipo i . Há dois conjuntos de parâmetros que podem impactar fortemente a performance do algoritmo em termos de acurácia das classificações, que são $\lambda_{i,j}$ e α_i . O objetivo da minimização é determinar as matrizes F_i , tal que $f_{ip}^{(k)}$ indica a confiança do nó p do tipo i pertencer à classe k . Essas confianças serão utilizadas para a geração da lista de recomendações, o que será discutido na próxima seção.

O parâmetro $\lambda_{i,j}$ é usado para ponderar a importância das relações entre os objetos, isto é, quanto maior o seu valor, maior o impacto terão as relações dos tipos i e j no processo de rotulação. O parâmetro α_i , por sua vez, pondera o peso que as informações de rótulo iniciais terão no processo de classificação. Em termos práticos, esses dois conjuntos de parâmetros guiam a propagação de rótulos como um todo: quanto maiores os valores de $\lambda_{i,j}$ em comparação aos de α_i , maior será o peso dado à estrutura da rede no processo. Quanto maiores os valores de α_i , maior será a importância da informação de rótulos inicial. Dessa forma, durante a avaliação experimental, esses conjuntos de parâmetros devem ser estimados cuidadosamente, o que será detalhado no Capítulo 5.

4.3.3 Abordagens para o ranqueamento dos itens

Como mencionado anteriormente, o *GNetMine* estima valores para as matrizes F_i , que são uma medida da confiança de cada nó do tipo i pertencer a cada uma das classes do problema. No caso do método **HINCARS**, portanto, em que as classes são as avaliações categóricas do usuário (como *muito bom* (5), *bom* (4), *regular* (3), *ruim* (2) e *muito ruim* (1)), é possível prever a probabilidade de cada um dos nós ser avaliado dessa forma.

Na Figura 14, são apresentadas as matrizes F_{usuario} , F_{item} e F_{contexto} , estimadas pelo algoritmo *GNetMine*, para um cenário onde a recomendação é feita para o usuário U_1 e há três usuários no total (U_1 , U_2 e U_3), três itens (*Harry Potter*, *Rei Leão*, *Annabelle*) e o contexto de companhia, com duas possibilidades (*Família* e *Sozinho*). Para se fazer o ranqueamento dos itens, deve ser considerada a matriz F_{item} , como a apresentada na

Figura 14b. Nesse caso, pode-se observar, por exemplo, que há uma probabilidade de 35% de *Harry Potter* ser rotulado com a classe 3, 15% de ser rotulado com 4 e 50% de ser rotulado com 5.

Figura 14 – Exemplo de matrizes de confianças estimadas pelo algoritmo *GNetMine*

F_{usuario}	1	2	3	4	5
U_1	0.3	0.6	0.1	0	0
U_2	0	0	0.95	0.05	0
U_3	0.4	0.3	0	0.2	0.1

(a) Matriz F_{usuario}

F_{item}	1	2	3	4	5
Harry Potter	0	0	0.35	0.15	0.50
Rei Leão	0	0.95	0.05	0	0
Anabelle	0.1	0.2	0.2	0.5	0

(b) Matriz F_{item}

F_{contexto}	1	2	3	4	5
Família	0	0	0.99	0.01	0
Sozinho	0	0	0	0.95	0.05

(c) Matriz F_{contexto}

Ao final do processo, ao invés das confianças calculadas, é necessário apresentar uma lista de recomendações para o usuário, de tal forma que itens com maior probabilidade de serem consumidos devem estar nas posições iniciais da lista. Dessa forma, foram propostas duas abordagens que, a partir dos valores das confianças para cada item p ($\vec{f}_{\text{item},p}$), definem um valor numérico que indica a preferência do usuário em relação a cada item do sistema:

- **Máxima confiança:** o rótulo atribuído ao item p será dado pela classe k que possuir o maior valor de confiança $\vec{f}_{\text{item},p}^{(k)}$. No caso do exemplo da Figura 14b, *Harry Potter* será da classe 5 (uma vez que a confiança de 50% é maior do que as outras confianças para esse item - 35% e 15% para os rótulos 3 e 4, respectivamente). O rótulo final atribuído ao item é convertido para um valor numérico: no caso do exemplo, a conversão é trivial; caso os rótulos sejam categóricos (como *muito bom*, *bom*, *regular*, *ruim* e *muito ruim*), é preciso mapeá-los para um valor numérico, respeitando a ordem entre os valores (por exemplo, de 5 a 1, respectivamente).
- **Combinação linear:** cada rótulo inicialmente é mapeado a um valor numérico (por exemplo, *muito bom* é mapeado a 5, e *muito ruim* é mapeado a 1), como no caso anterior. A partir disso, é calculado o produto escalar entre o vetor de confianças, $\vec{f}_{\text{item},p}$, com um vetor de pesos $w = [w_1, \dots, w_K]^T$, em que K é o número de classes. Ou seja, $\hat{r}_{u,p} = \vec{f}_{\text{item},p} \cdot w$, em que $\hat{r}_{u,p}$ é a preferência estimada do usuário u pelo item p . No caso do exemplo da Figura 14b, seja $w = [1, 2, 3, 4, 5]^T$. Então, a preferência do usuário por *Harry Potter* será $\hat{r}_{u,HP} = \vec{f}_{\text{item},HP} \cdot w = 0 \cdot 1 + 0 \cdot 2 + 0.35 \cdot 3 + 0.15 \cdot 4 + 0.5 \cdot 5 = 4.15$

Por meio dessas abordagens, foi possível obter um valor numérico para cada item $\hat{r}_{u,p}$, indicando a preferência do usuário por ele. Por fim, para gerar a lista de recomendações do usuário, são selecionados os N itens com o maior valor de $\hat{r}_{u,p}$. Na próxima seção, será apresentado como as outras matrizes de confiança F_i podem ser utilizadas para trazer interpretabilidade ao modelo.

4.4 Interpretabilidade das recomendações e possíveis explicações

A principal vantagem do algoritmo *GNetMine* e um dos motivos pelo quais ele foi utilizado neste trabalho de mestrado, é que a propagação dos rótulos acontece para todos os objetos da rede, independente de seu tipo. Dessa forma, além da matriz F_{item} , que fornece as confianças de cada objeto do tipo item pertencer a cada uma das classes, que foi utilizada para a geração das recomendações, o algoritmo calcula também matrizes de confiança para os outros tipos de objetos (como $F_{usuario}$ e $F_{contexto}$). Essas outras matrizes podem ser utilizadas para agregar interpretabilidade às recomendações geradas. Como o algoritmo é executado para cada usuário por vez, as informações nessas matrizes podem refletir como cada objeto influenciou as recomendações.

Mais especificamente, a partir das matrizes de confiança das variáveis de contexto, é possível identificar também quais foram os contextos mais importantes para o usuário, num processo similar ao apresentado na Seção 4.3.3. Tomando como exemplo a matriz de contexto apresentada na Figura 14c e uma abordagem de ranqueamento baseada na confiança máxima, o usuário prefere o contexto *Sozinho* (com preferência 4 - confiança de 95%) do que o contexto *Família* (com preferência 3 - confiança de 99%). Dessa forma, o contexto *Sozinho* poderia ser utilizado para explicar essa recomendação, como, por exemplo, “O filme *Harry Potter* é adequado para ser visto *Sozinho*”.

De maneira similar, a matriz de confiança do usuário, $F_{usuario}$, pode ser usada para identificar quais são os usuários mais próximos (importantes) em relação ao usuário alvo da recomendação. Por exemplo, na Figura 14a, numa abordagem baseada na confiança máxima, o usuário U_2 seria rotulado com a classe 3, e o usuário U_3 com a classe 1, o que implicaria que U_2 é mais importante do que U_3 no processo de geração de recomendações para U_1 . Essas informações poderiam ser utilizadas, por exemplo, para ponderar a lista de recomendações geradas, dando maior peso aos itens que o usuário próximo (U_2) avaliou bem. Com isso, poderiam ser geradas explicações do tipo “O seu amigo U_2 gostou de *Harry Potter*... talvez você goste também”.

Em resumo, as matrizes de confianças obtidas ao final do processo de propagação dos rótulos abre uma gama de possibilidades para geração de explicações. Pelo fato de cada

objeto da rede ter sido rotulado, independente de seu tipo (usuário, item ou contexto), é possível verificar quais objetos da rede mais impactaram o processo de recomendação. Dessa forma, tais rótulos podem ser usados como fonte de dados para um método de geração de explicações. Em trabalhos futuros, pretende-se gerar explicações para o método **HINCARS**, utilizando os conceitos abordados nesta seção.

4.5 Considerações Finais

Neste capítulo, foi apresentado o método proposto neste trabalho de mestrado, intitulado **HINCARS**, cujo objetivo é gerar recomendações interpretáveis considerando as diversas entidades envolvidas no processo de recomendação, como usuários, itens e contextos. A fim de agregar todas essas entidades em uma única representação de dados, foi utilizada uma rede heterogênea, que permite modelar todas as interações existentes entre essas entidades e entender como elas influenciam o processo de recomendação como um todo, o que traz semântica ao processo de recomendação.

O método **HINCARS** é composto por três etapas principais, que são: cálculo de similaridades, construção da rede heterogênea e geração das recomendações. A primeira etapa teve como objetivo calcular a similaridade entre usuários (itens), considerando as interações deles com o sistema, porque essas informações podem servir como fonte valiosa de informação adicional, que pode ser agregada no processo de recomendação. A segunda etapa, por sua vez, estabeleceu diversas abordagens para a construção da rede heterogênea, explorando as diferentes relações existentes entre os objetos. Como mencionado anteriormente, a estrutura da rede pode impactar severamente a acurácia das recomendações. Por fim, a terceira etapa definiu um processo para a geração das recomendações, utilizando as diferentes redes heterogêneas construídas.

Além disso, foi apresentado como as recomendações produzidas podem ser interpretadas utilizando outras informações disponíveis no processo de recomendação, como informações de usuários similares e também informações de contextos preferidos pelos usuários. Por fim, apesar de não ser o foco deste mestrado, foram sugeridas algumas maneiras para gerar explicações para as recomendações utilizando tais informações. No capítulo seguinte, serão apresentados os experimentos conduzidos a fim de validar o método **HINCARS**.

Avaliação Experimental

Neste capítulo, é apresentada a avaliação experimental do método **HINCARS**, que foi proposto neste trabalho para geração de recomendações interpretáveis utilizando contexto. Para isso, na Seção 5.1, serão retomadas as questões de pesquisa e os objetivos deste mestrado, a fim de detalhar o escopo da avaliação realizada. Além disso, na Seção 5.2, serão apresentadas as bases de dados utilizadas, bem como o modelo de validação e a medida de precisão adotados. O *baseline* utilizado para comparação dos resultados, por sua vez, será apresentado na Seção 5.3. Por fim, nas Seções 5.5 e 5.6 serão apresentados, respectivamente, os resultados obtidos e as considerações finais deste capítulo de avaliação experimental.

5.1 Escopo da avaliação

O objetivo desta avaliação experimental teve como propósito responder às duas questões de pesquisa que nortearam o desenvolvimento deste mestrado, que foram:

- Q1** É possível agregar em uma única representação de dados as diferentes entidades envolvidas na tarefa de recomendação, de tal forma que o modelo de recomendação produzido seja interpretável?
- Q2** A agregação dessas diferentes entidades em uma única representação de dados leva a recomendações com acurácia igual ou superior a de outros métodos de recomendação considerados estado-da-arte?

Conforme apresentado na Seção 4.4, o método **HINCARS** gera recomendações que de fato são interpretáveis, o que responde à questão de pesquisa **Q1**. Dessa forma, esta avaliação experimental focou em verificar a validade da questão de pesquisa **Q2**. Para

isso, foram escolhidas três bases de dados reais, que serão apresentadas na Seção 5.2.1, e o método *TriRank* para servir como *baseline* de comparação, que é considerado estado-da-arte para recomendações em redes heterogêneas e será apresentado na Seção 5.3. Com isso, a principal questão que se buscou responder é se as recomendações geradas pelo método *HINCARS* possuem acurácia igual ou superior a do *TriRank* e, se sim, quais são as suas principais vantagens/desvantagens em relação aos outros métodos existentes.

5.2 Configuração Experimental

Como mencionado na Seção 2.5, existem três tipos possíveis de avaliação experimental a serem realizadas em sistemas de recomendação, que são: **estudo com usuários**, quando usuários são recrutados para interagirem com um sistema de recomendação; **avaliação online**, quando as recomendações são apresentadas a usuários reais em um sistema já em execução; e avaliação **offline**, quando são utilizados dados históricos para a predição de métricas de performance. Neste trabalho de mestrado, adotou-se a avaliação *offline*, em razão da sua simplicidade e por já atender aos propósitos desta avaliação. Dessa forma, nas seções seguintes, serão apresentadas as bases de dados históricas utilizadas, bem como o protocolo de avaliação adotado.

5.2.1 Bases de dados utilizadas

O método *HINCARS* agrega diferentes entidades do processo de recomendação em uma única representação de dados, como detalhado na Seção 4.2. Diante disso, o requisito essencial que guiou o processo de escolha das bases usadas para validação foi a presença dessas três entidades, que são usuários, itens e contextos. Além disso, outro aspecto considerado foi que as dimensões contextuais fossem legíveis pelos usuários. Como a interpretabilidade do modelo proposto advém da possibilidade de explicar as recomendações com as informações de contexto, os usuários devem ser capazes de entender quais são esses contextos.

Dessa forma, foi identificada uma base de dados que atendeu a esses requisitos, sendo considerada, portanto, adequada para esta avaliação experimental. Essa base de dados é a *Depaul Movie* (ZHENG *et al.*, 2016), e tem como domínio a recomendação de filmes. Ela é composta por 3595 avaliações, 81 usuários, 79 itens e três diferentes dimensões contextuais (Dia da Semana, Companhia e Localização). Em razão do número relativamente baixo de avaliações, foi possível realizar uma grande variedade de experimentos, de forma a calibrar os principais hiper-parâmetros do método *HINCARS*.

5.2.2 Protocolo de avaliação

Os experimentos realizados foram executados utilizando *10-fold cross validation*. Nesse modelo de validação, os dados são divididos em 10 partições, sendo uma utilizada para teste e as partições restantes para treinamento. A ideia principal desse modelo é executar o experimento 10 vezes, alternando as partições utilizadas para treinamento e teste a cada iteração, tal que ao final do processo calcula-se uma medida média da performance do modelo (RICCI *et al.*, 2015; AGGARWAL, 2016).

A métrica de performance adotada nos experimentos foi a MAP@N (*Mean Average Precision*), descrita na Seção 2.5, tal que $N = 10$ foi o tamanho das listas de recomendações geradas. A principal característica dessa métrica é a capacidade de atribuir maior peso a acertos que acontecem no começo da lista de recomendações. Além disso, o intervalo de valores dessa métrica é $[0, 1]$, e quanto maiores os valores, melhores foram as listas de recomendações geradas.

Dessa forma, para a avaliação experimental do método **HINCARS**, foram calculados os valores da métrica MAP tanto para as recomendações geradas pelo *TriRank* (*baseline*), que foi descrito na Seção 3.2, quanto para o método proposto neste trabalho. Os resultados foram comparados utilizando o teste estatístico de *Wilcoxon*, a fim de verificar se havia significância estatística entre os dois métodos, e esses resultados serão apresentados em detalhes na Seção 5.5. Na seção seguinte, serão apresentados o resultados obtidos pelo *TriRank*.

5.3 Resultados do Baseline (*TriRank*)

O método *TriRank*, proposto por He *et al.* (2015), foi escolhido como *baseline* dos experimentos deste trabalho de mestrado em razão de dois motivos principais: da mesma forma como no método **HINCARS**, o *TriRank* (i) modela o sistema utilizando redes heterogêneas; e (ii) realiza o aprendizado semi-supervisionado transdutivo por meio de uma instanciamento do algoritmo *GNetMine*, descrito na Seção 2.2.2.1.2. Além disso, He *et al.* (2015) mostrou em seus experimentos que o *TriRank* foi capaz de superar o desempenho de vários outros métodos, considerados estado-da-arte.

De maneira geral, como mencionado na Seção 3.2, o objetivo do *TriRank* consiste em estimar para cada usuário valores numéricos para três vetores, $f(u)$, $f(p)$ e $f(g)$, que indicam, respectivamente, o grau de preferência do usuário-alvo em relação aos outros usuários, itens e aspectos do sistema. Para isso, é feita a minimização da Equação 5.1, que é apresentada novamente a seguir, com o objetivo de facilitar a leitura deste texto.

$$\begin{aligned}
Q(f) = & \alpha \sum_{i,j} r_{ij} \left(\frac{f(u_i)}{\sqrt{d_i^u}} - \frac{f(p_j)}{\sqrt{d_j^p}} \right)^2 + \beta \sum_{j,k} x_{jk} \left(\frac{f(p_j)}{\sqrt{d_j^p}} - \frac{f(g_k)}{\sqrt{d_k^g}} \right)^2 + \gamma \sum_{i,k} y_{ik} \left(\frac{f(u_i)}{\sqrt{d_i^u}} - \frac{f(g_k)}{\sqrt{d_k^g}} \right)^2 + \\
& \eta_U \sum_i (f(u_i) - u_i^0)^2 + \eta_P \sum_j (f(p_j) - p_j^0)^2 + \eta_G \sum_k (f(g_k) - g_h^0)^2 \quad (5.1)
\end{aligned}$$

Em linhas gerais, o *TriRank* minimiza a equação ajustando os vetores $f(u)$, $f(p)$ e $f(g)$, de forma a satisfazer as premissas de consistência e informação prévia. O método utiliza seis parâmetros para ajustar o quanto cada uma dessas premissas impacta o aprendizado do algoritmo: α , β e γ são utilizados para a premissa de consistência (nós próximos devem possuir rótulos similares), e η_U , η_P e η_G controlam o impacto da premissa de informação prévia (nós previamente rotulados não devem ter seus rótulos iniciais alterados).

Dessa forma, foram feitos experimentos variando tais parâmetros do *TriRank*. Para isso, foram escolhidos os valores $\alpha, \beta, \gamma \in \{0.1, 0.5, 0.9\}$ e $\eta_U, \eta_P, \eta_G \in \{0.1, 0.5, 0.9\}$, ou seja, atribuindo pouca (valor 0.1), média (valor 0.5), ou muita (valor 0.9) importância aos diferentes tipos de relacionamento e de informação prévia disponíveis. Além disso, foi seguido o protocolo apresentado na Seção 5.2. No entanto, como o *TriRank* suporta apenas três tipos diferentes de objetos (usuários, itens e uma entidade adicional), não foi possível considerar simultaneamente todas as dimensões contextuais da base de dados *DePaul Movie* (Dia da Semana, Companhia e Localização). Dessa forma, cada experimento foi executado três vezes, cada qual com uma variável contextual diferente. Na Tabela 8, são apresentados os resultados obtidos, sendo que em negrito é destacado o experimento que obteve o melhor resultado para cada variável de contexto.

A partir dos resultados apresentados na Tabela 8, é possível observar que o *TriRank* teve um melhor desempenho quando foram utilizados os dados de usuários, itens e o contexto Companhia. No experimento que obteve o melhor resultado (E_8), a MAP obtida para essa variável de contexto foi de 0.1825, enquanto a MAP para as outras variáveis (Dia da Semana e Localização) foram de 0.1809 e 0.1769, respectivamente. Isso motivou uma das hipóteses levantadas neste trabalho de mestrado, em que o uso das três variáveis de contexto simultaneamente gera melhores resultados quando comparado ao uso de apenas uma variável por vez.

Um outro fato interessante a ser observado é que os melhores resultados foram obtidos nos experimentos E_4 e E_8 . O ponto em comum entre esses experimentos é que ambos atribuíram um maior peso à estrutura da rede (premissa de consistência) no processo de aprendizado ($\alpha = \beta = \gamma = 0.5$ e $\alpha = \beta = \gamma = 0.9$), em relação às informações prévias iniciais ($\eta_U = \eta_P = \eta_G = 0.1$). Deseja-se verificar, portanto, se no método **HINCARS** esse comportamento se mantém.

Tabela 8 – Resultados da métrica MAP para a base de dados *DePaul Movie* utilizando o *baseline* (*TriRank*)

Experimentos	Parâmetros	Média da MAP		
		Dia da Semana	Companhia	Localização
E_1	$\alpha = 0.1$	0.1746	0.1733	0.1721
	$\eta_U = 0.1$			
	$\beta = 0.1$			
E_2	$\gamma = 0.1$	0.1686	0.1689	0.1689
	$\eta_P = 0.1$			
	$\eta_G = 0.1$			
E_3	$\alpha = 0.1$	0.1687	0.1692	0.1690
	$\eta_U = 0.5$			
	$\beta = 0.1$			
E_4	$\gamma = 0.1$	0.1755	0.1775	0.1769
	$\eta_G = 0.5$			
	$\alpha = 0.5$			
E_5	$\beta = 0.5$	0.1750	0.1733	0.1721
	$\eta_P = 0.5$			
	$\gamma = 0.5$			
E_6	$\eta_G = 0.5$	0.1700	0.1700	0.1693
	$\alpha = 0.5$			
	$\eta_U = 0.9$			
E_7	$\beta = 0.5$	0.1436	0.1437	0.1422
	$\eta_P = 0.9$			
	$\gamma = 0.5$			
E_8	$\eta_G = 0.9$	0.1809	0.1825	0.1741
	$\alpha = 0.9$			
	$\eta_U = 0.5$			
E_9	$\beta = 0.9$	0.1746	0.1733	0.1721
	$\eta_P = 0.9$			
	$\gamma = 0.9$			

Fonte: Elaborada pelo autor.

5.4 Descrição dos Experimentos Realizados

Como mencionado anteriormente, o método **HINCARS** se baseia no algoritmo GNet-Mine para gerar recomendações a partir da rede heterogênea construída. De maneira geral, esse algoritmo busca satisfazer duas premissas, que são a consistência e a informação prévia. A premissa de consistência diz que nós próximos devem ser rotulados de maneira similar, ou seja, que a estrutura da rede heterogênea (nós e relacionamentos) deve ser considerada. A premissa de informação prévia, por sua vez, diz que nós previamente rotulados devem manter o rótulo original sempre que possível.

Para ponderar a importância atribuída a cada uma dessas premissas, o algoritmo faz uso de dois conjuntos de parâmetros, $\lambda_{i,j}$ e α_i , tal que $i, j \in \{1, \dots, m\}$ e m é a quantidade de tipos diferentes de objetos. O primeiro é utilizado para controlar a importância

dos relacionamentos entre objetos de diferentes tipos no processo de aprendizado (premissa de consistência), e o segundo, a importância da rotulação inicial de cada tipo de objeto no processo (premissa de informação prévia). Essa flexibilidade em atribuir importâncias distintas para os relacionamentos entre objetos de tipos diferentes, bem como às informações prévias de tipos diferentes, é uma das principais vantagens do GNetMine.

Dessa forma, a primeira etapa para validação do método **HINCARS** foi a utilização de diferentes valores para os parâmetros de $\lambda_{i,j}$ e α_i , a fim de determinar como a estrutura da rede construída impacta à acurácia final das recomendações geradas. Para isso, foram propostos oito configurações experimentais, que são descritos na Tabela 9. Cada uma dessas configurações atribui um peso diferente a um determinado tipo de relacionamento; por exemplo, enquanto a configuração experimental E_1 atribui a mesma importância a todos os relacionamentos, a configuração E_2 considera que as relações entre usuários e itens são mais importantes.

Tabela 9 – Descrição das configurações experimentais realizadas, considerando a importância atribuída à premissa de consistência e de informação prévia.

Configuração	Descrição	
	Relacionamentos	Informação Prévia
E_1	Mesmo peso para todos os tipos ($\lambda_{i,j} = 0.9$)	Mesmo peso para todos os tipos ($\alpha_i = 0.5$)
E_2	Relação usuário x item com maior peso ($\lambda_{user,item} = 0.9$ e $\lambda_{i,j} = 0.5, i \neq user, i \neq item$)	Mesmo peso para todos os tipos ($\alpha_i = 0.5$)
E_3	Relações contexto com maior peso ($\lambda_{context,j} = 0.9$ e $\lambda_{i,j} = 0.5, i \neq context$)	Mesmo peso para todos os tipos ($\alpha_i = 0.5$)
E_4	Relações usuário com maior peso ($\lambda_{user,j} = 0.9$ e $\lambda_{i,j} = 0.5, i \neq user$)	Mesmo peso para todos os tipos ($\alpha_i = 0.5$)
E_5	Relações item com maior peso ($\lambda_{item,j} = 0.9$ e $\lambda_{i,j} = 0.5, i \neq item$)	Mesmo peso para todos os tipos ($\alpha_i = 0.5$)
E_6	Relações com contexto dia da semana com maior peso ($\lambda_{dia,j} = 0.9$ e $\lambda_{i,j} = 0.5, i \neq dia$)	Mesmo peso para todos os tipos ($\alpha_i = 0.5$)
E_7	Relações com contexto companhia com maior peso ($\lambda_{companhia,j} = 0.9$ e $\lambda_{i,j} = 0.5, i \neq companhia$)	Mesmo peso para todos os tipos ($\alpha_i = 0.5$)
E_8	Relações com contexto localização com maior peso ($\lambda_{localizacao,j} = 0.9$ e $\lambda_{i,j} = 0.5, i \neq localizacao$)	Mesmo peso para todos os tipos ($\alpha_i = 0.5$)

Fonte: Elaborada pelo autor.

Cada configuração experimental apresentada na Tabela 9 foi executada várias vezes, considerando tanto as diferentes abordagens utilizadas na construção da rede e definição da matriz de informação prévia, quanto os diferentes valores que os outros parâmetros do método **HINCARS** podem assumir. A ideia é analisar o impacto dos relacionamentos entre as entidades de diferentes tipos (dado pelas diferentes configurações experimentais), bem como identificar a melhor abordagem de construção da rede com o melhor conjunto de parâmetros possível.

Mais especificamente, como mencionado na Seção 4.2, há quatro abordagens para a construção da rede heterogênea, a saber: **N-Partida**, **Heterogênea Usuários**, **Heterogênea Itens** e **Completa**. Além disso, como apresentado na Seção 4.3.1, foram propostas duas formas para o enriquecimento das matrizes de informação prévia: **Abordagem Colaborativa** e **Abordagem baseada em usuários similares**. Quanto a possíveis parâmetros a serem utilizados, na Seção 4.3.3, mostrou-se a necessidade de definição de um vetor de pesos (parâmetro **Pesos**). A ideia foi combinar as confianças preditas pelo algoritmo em relação a cada uma das classes consideradas em um único valor numérico. Além disso, o método **HINCARS** considerou, em várias etapas do processo, usuários similares ao usuário alvo da recomendação. Dessa forma, foi definido um parâmetro (**Taxa Usuário**), que indica a proporção de usuários similares, dentre o número total de usuários. Portanto, também foram realizados experimentos para estimar os melhores conjuntos de parâmetros a utilizar. No caso do parâmetro **Pesos**, foram considerados os vetores de pesos, w , como $[0, 0, 1, 1, 1]$, $[0, 0, 1, 3, 5]$, $[0, 0, 1, 5, 10]$, $[1, 1, 1, 1, 1]$ e $[1, 2, 3, 4, 5]$. Para o parâmetro **Taxa Usuário**, foram avaliados os valores de 5%, 10% e 20%.

Para resumir, é apresentado na Figura 15 um esquemático do processo de avaliação experimental realizado. Para simplificar a imagem, está marcado apenas o fluxo dos primeiros três experimentos. A ideia do processo de avaliação é variar as possibilidades para cada uma das variáveis do problema que foram apresentadas no parágrafo anterior. Por exemplo, o primeiro experimento utiliza as seguintes combinações: configuração experimental E_1 , abordagem *N-Partida*, vetor de pesos $[0, 0, 1, 1, 1]$ e taxa de usuários de 0.05. Os outros experimentos, então, seguem o mesmo princípio. Assim, na seção seguinte, serão apresentados os resultados de todos esses experimentos.

5.5 Resultados e Discussão

Considerando todas as diferentes possibilidades de configurações experimentais e parâmetros do método **HINCARS** que foram apresentados na seção anterior, obteve-se um total de mais de 1000 experimentos. Em razão do número elevado de experimentos, são apresentados na Tabela 10 apenas os experimentos que obtiveram resultado estatisticamente superior ou equivalente ao *baseline*, de acordo com o teste estatístico de *Wilcoxon*.

Figura 15 – Esquemático do processo de avaliação experimental realizado neste trabalho de mestrado

Fonte: Elaborada pelo autor.

Os resultados de todos experimentos encontram-se no Apêndice A.

A partir dos resultados apresentados na tabela anterior, é possível observar que o método **HINCARS** apresentou resultados numericamente superiores ao *baseline TriRank*, que obteve MAP igual a 0.1825 no seu melhor experimento. No entanto, ao executar o teste estatístico de *Wilcoxon*, pode-se observar que não houve significância estatística em nenhum dos experimentos, o que indica que os resultados foram estatisticamente equivalentes. Apesar disso, o método **HINCARS** apresenta a possibilidade de gerar e explicar as recomendações utilizando todas as variáveis contextuais, ao invés de apenas uma, como no caso do *TriRank*. Para exemplificar essa possibilidade, considere que o usuário esteja buscando recomendações de filmes para serem vistos no *final de semana* (variável contextual *Dia da Semana*) com a *família* (variável contextual *Companhia*). Enquanto o método *TriRank* não é capaz de gerar as recomendações e explicações considerando as duas variáveis contextuais simultaneamente, o método **HINCARS** sim. Dessa forma, pode-se argumentar que as recomendações apresentadas pelo método **HINCARS** seriam mais adequadas, uma vez que estariam considerando a situação contextual do usuário em questão como um todo.

Além disso, na Seção 5.4, foi apresentado um conjunto de configurações experimentais, a fim de verificar como os relacionamentos entre as entidades da rede heterogênea construída impactavam às recomendações produzidas. Considerando o total dos experimentos realizados, apresentados no Apêndice A, e os resultados que de fato foram estatisticamente equivalentes ou superiores ao baseline, apresentados na Tabela 10, pode-se calcular a frequência com que cada configuração experimental gerou resultados estatisticamente equivalentes ou superiores. Na Figura 16, são apresentadas tais frequências para

Tabela 10 – Resultados obtidos pelo método **HINCARS** que foram estatisticamente iguais ou superiores ao *baseline*

Configuração	Taxa Usuário	Abordagem	Pesos	MAP
E_1	0.05	Completa	1,1,1,1,1	0.1954
E_1	0.2	Completa	1,1,1,1,1	0.1954
E_7	0.1	Heterogênea Itens	1,1,1,1,1	0.1940
E_7	0.1	Completa	1,1,1,1,1	0.1934
E_1	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	0.19321
E_1	0.05	Heterogênea Itens	1,1,1,1,1	0.1930
E_1	0.2	Heterogênea Itens	1,1,1,1,1	0.1930
E_1	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	0.1917
E_7	0.1	Enriquecimento Usuários Similares	1,1,1,1,1	0.1917
E_6	0.1	Heterogênea Itens	1,1,1,1,1	0.1908
E_6	0.05	Heterogênea Itens	1,1,1,1,1	0.1878
E_6	0.2	Heterogênea Itens	1,1,1,1,1	0.1878
E_6	0.1	Completa	1,1,1,1,1	0.1878
E_4	0.05	Heterogênea Itens	1,1,1,1,1	0.1872
E_4	0.2	Heterogênea Itens	1,1,1,1,1	0.1872
E_5	0.05	Completa	1,1,1,1,1	0.1866
E_5	0.2	Completa	1,1,1,1,1	0.1866
E_5	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	0.1865
E_6	0.1	Enriquecimento Usuários Similares	1,1,1,1,1	0.1862
E_8	0.05	Heterogênea Itens	0,0,1,1,1	0.1848
E_8	0.1	Heterogênea Itens	0,0,1,1,1	0.1848
E_8	0.2	Heterogênea Itens	0,0,1,1,1	0.1848
E_5	0.05	Heterogênea Itens	1,1,1,1,1	0.1846
E_5	0.2	Heterogênea Itens	1,1,1,1,1	0.1846
E_7	0.05	Heterogênea Itens	1,1,1,1,1	0.1846
E_7	0.2	Heterogênea Itens	1,1,1,1,1	0.1846
E_8	0.1	Enriquecimento Usuários Similares	1,1,1,1,1	0.1841
E_6	0.1	Completa	0,0,1,5,10	0.1841
E_6	0.05	Completa	1,1,1,1,1	0.1838
E_6	0.2	Completa	1,1,1,1,1	0.1838
E_5	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	0.1837
E_6	0.1	Completa	0,0,1,1,1	0.1835
E_8	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	0.1834
E_6	0.1	Heterogênea Itens	0,0,1,1,1	0.1831
E_6	0.1	Heterogênea Itens	0,0,1,5,10	0.1826
E_6	0.05	Heterogênea Itens	0,0,1,5,10	0.1826
E_6	0.2	Heterogênea Itens	0,0,1,5,10	0.1826

Fonte: Elaborada pelo autor.

cada configuração experimental.

Figura 16 – Frequência com que cada configuração experimental gerou resultados estatisticamente equivalentes ou superiores ao *baseline*.

Fonte: Elaborada pelo autor.

Como é possível observar, a configuração experimental que obteve o maior número de resultados estatisticamente equivalentes ou superiores ao *baseline* foi a E_6 , que obteve frequência de 35,14%. Nessa configuração, foi atribuída maior importância às relações que envolviam a variável contextual *Dia da Semana*, o que pode ser um indicativo de que esse contexto é um melhor discriminante para identificar as preferências dos usuários. Por outro lado, as configurações experimentais E_2 e E_3 obtiveram frequência zero, o que indica que elas não geraram nenhum resultado pelo menos equivalente ao *baseline*. Ou seja, atribuir quase nenhuma importância (E_2) ou atribuir importância demais (E_3) às variáveis contextuais, pode não ser uma boa ideia. De fato, isso já foi comprovado por vários trabalhos em sistemas de recomendação sensíveis ao contexto (KARATZOGLOU *et al.*, 2010; ADOMAVICIUS; TUZHILIN, 2011; SUNDERMANN *et al.*, 2016), que mostraram que as informações contextuais contribuem a gerar melhores recomendações, mas que ao mesmo tempo podem trazer uma esparsidade ainda maior ao problema de recomendação.

Quanto às abordagens propostas para a construção da rede heterogênea utilizada pelo método **HINCARS**, na Figura 17, são apresentadas as frequências com que cada abordagem gera resultados iguais ou superiores ao *baseline*. Nota-se que a abordagem *Heterogênea Itens* foi a que obteve a maior frequência, tendo sido utilizada em 51.35% dos experimentos que obtiveram os melhores resultados. Para recapitular, nessa abordagem,

além das relações n-partidas ($\text{usuário} \times \text{item}$, $\text{usuário} \times \text{contexto}_i$ e $\text{item} \times \text{contexto}_i$), são definidas relações entre itens similares. Esse resultado indica que as informações de similaridade entre itens foram importantes para a geração das recomendações. A abordagem de enriquecimento das matrizes de informação prévia com os usuários similares (*Enriquecimento Usuários Similares*), por sua vez, obteve resultados equivalentes ou superiores em 21.62% dos experimentos da Tabela 10. Isso indica, de maneira similar ao caso anterior, que as informações de similaridade entre usuários são relevantes no processo de recomendação.

Figura 17 – Frequência com que cada abordagem utilizada para construção da rede heterogênea gerou resultados estaticamente iguais ou superiores ao *baseline*.

Fonte: Elaborada pelo autor.

Ainda considerando a Figura 17, observa-se que a abordagem *Completa* também gerou bons resultados, o que sugere que os relacionamentos entre diferentes variáveis contextuais, aliados aos relacionamentos entre usuários e itens, bem como às informações de similaridade entre eles, impacta positivamente nas recomendações geradas. Por fim, observa-se que as abordagens *Enriquecimento Colaborativo*, *Heterogênea Usuários* e *N-Partida* não foram suficientes para gerar recomendações melhores ou iguais ao *baseline*.

Na Figura 18, é apresentada a frequência com que cada abordagem de construção da rede heterogênea gera resultados estatisticamente iguais ou superiores ao *baseline*, mas desta vez considerando cada configuração experimental. Não são apresentadas as configurações E_2 e E_3 , e nem as abordagens *Heterogênea Usuários*, *Enriquecimento Colaborativo* e *N-Partida*, porque não geraram nenhum resultado ao menos igual ao *baseline*, como

mencionado anteriormente nas análises das Figuras 16 e 17, respectivamente.

Figura 18 – Para cada configuração experimental, é apresentada a frequência com que as abordagens utilizadas para construção da rede heterogênea geraram resultados estatisticamente iguais ou superiores ao *baseline*.

Fonte: Elaborada pelo autor.

O padrão observado na Figura 17 se manteve para todas as configurações experimentais, isto é, a abordagem *Heterogênea Itens* sempre se sobressaiu frente às outras abordagens, mesmo alterando as importâncias dos relacionamentos da rede. Isso pode ser um indicativo de que essa abordagem é de fato adequada para a construção da rede heterogênea.

Como mencionado na Seção 4.3, o método **HINCARS** utiliza o algoritmo *GNetMine*, que é um algoritmo de classificação, para a geração das recomendações. Dado um conjunto de classes, o *GNetMine* retorna um vetor de confianças, que indica a probabilidade daquele dado pertencer a cada uma das classes. Como exemplo, sejam as classes $\{1, 2, 3, 4, 5\}$, e o vetor de confianças $\vec{f} = [0.1, 0.2, 0.5, 0.2, 0]$, o que indica que existe uma probabilidade de 10% do dado pertencer à classe 1, 20% de pertencer à classe 2, 50%, à classe 3, e assim por diante. Como o método **HINCARS** é um método baseado em regressão, cujo objetivo é prever um valor numérico de preferência para cada item, as confianças preditas são combinadas utilizando um vetor de pesos, que é um dos parâmetros do método, como descrito na seção anterior.

Na Figura 19, são apresentadas as frequências com que cada um dos vetores de pesos utilizados gera resultados estatisticamente iguais ou superiores ao *baseline*. Como é possível observar na figura, existe uma prevalência do vetor $\vec{w} = [1, 1, 1, 1, 1]$ (ocorrência de 75.68% dos experimentos), o que provavelmente indica que as confianças calculadas pelo *GNetMine* são suficientes para geração das recomendações, não sendo necessárias outras abordagens para a combinação das classes.

Figura 19 – Frequência com que cada vetor de pesos considerado gerou resultados estatisticamente iguais ou superiores ao *baseline*.

Fonte: Elaborada pelo autor.

Por fim, na Figura 20, são apresentadas as frequências com que as diferentes taxas de usuários similares consideradas apresentaram resultados estatisticamente iguais ou superiores ao *baseline*. É possível notar que as três taxas consideradas (0.05, 0.10 e 0.20) obtiveram frequência praticamente equivalentes. Conclui-se, portanto, que os valores considerados não impactaram à qualidade das recomendações geradas.

Na seção seguinte, são apresentadas as considerações finais acerca do processo de avaliação experimental, bem como dos resultados obtidos.

5.6 Considerações Finais

Neste capítulo, foi apresentado o processo de avaliação utilizado para validar o método **HINCARS**, proposto neste trabalho de mestrado. Mais especificamente, foi apresentado o escopo da avaliação, a base de dados utilizada, o protocolo de avaliação, bem como os resultados do *baseline* considerado e do método proposto.

Nesse processo de avaliação, foi considerada apenas uma base de dados (*Depaul Movie*) por dois motivos complementares: (i) seu tamanho relativamente pequeno; e (ii) quantidade elevada de experimentos a serem realizados para validação das abordagens e dos parâmetros considerados. De maneira geral, considerou-se que a utilização de ou-

Figura 20 – Frequência com que as diferentes taxas de usuários similares consideradas geraram resultados estatisticamente iguais ou superiores ao *baseline*.

Fonte: Elaborada pelo autor.

tras bases de dados maiores teriam inviabilizado a execução dos experimentos planejados. Quanto ao protocolo de avaliação, foi utilizado o *10-fold cross validation*, métrica de performance *MAP*, e o teste estatístico de *Wilcoxon*.

Os experimentos realizados permitiram verificar que o método **HINCARS** de fato é competitivo para gerar recomendações interpretáveis, uma vez que possibilita a utilização de diversas variáveis contextuais, ao mesmo tempo que mantém a qualidade das recomendações do *baseline* considerado, que utiliza apenas uma variável de contexto. Os resultados obtidos foram numericamente superiores; no entanto, não foi identificada significância estatística nesses resultados.

Além disso, o processo de avaliação experimental permitiu validar as diferentes abordagens utilizadas pelo método **HINCARS**. Mais especificamente, observou-se a importância em se utilizar moderada da informação contextual; verificou-se que atribuir pouca importância ou atribuir importância demais a esse tipo de informação é prejudicial para as recomendações. Ademais, foram propostas diversas abordagens para a construção da rede heterogênea utilizada pelo método **HINCARS**. A abordagem *Heterogênea Itens* foi a que obteve bons resultados no maior número de experimentos, tanto considerando os experimentos como um todo quanto considerando cada configuração experimental individualmente.

Por fim, foram explorados diferentes valores para alguns dos parâmetros do método **HINCARS**. Mais especificamente, foram considerados os parâmetros *Pesos* e *Taxa de Usuários*. Os experimentos mostraram que a confiança das classes retornada pelo algoritmo *GNetMine*, utilizado pelo método **HINCARS**, é suficiente para predizer a preferência do usuário. Além disso, observou-se que o parâmetro *Taxa de Usuários* não impactou às recomendações geradas.

Conclusões

Neste capítulo são apresentadas as conclusões desta dissertação de mestrado. Para isso, as questões de pesquisa apresentadas na Introdução são retomadas e relacionadas com as principais contribuições alcançadas por este trabalho. Além disso, é apresentada uma síntese dos artigos publicados e como eles se relacionam a essa dissertação de mestrado. Por fim, são listadas as principais limitações deste trabalho, bem como os direcionamentos para trabalhos futuros.

6.1 Contribuições Científicas

Os sistemas de recomendação consistem em um conjunto de métodos e técnicas cujo objetivo principal é filtrar a grande quantidade de informação disponível, apresentando recomendações personalizadas ao usuário (AGGARWAL, 2016). Inúmeras pesquisas têm sido feitas para identificar quais tipos de informações adicionais podem ser agregadas nesses processo para enriquecer a qualidade das recomendações geradas. Em especial, a informação do contexto no qual o usuário está inserido tem se mostrado realmente importante para esse processo, uma vez que permite uma personalização ainda maior das recomendações geradas (ADOMAVICIUS; TUZHILIN, 2011; DOMINGUES *et al.*, 2014; SATO *et al.*, 2018; SUNDERMANN *et al.*, 2020).

Além disso, há vários anos, têm sido desenvolvidos inúmeros algoritmos e técnicas cujo objetivo é lidar com toda essa informação disponível (usuários, itens, contextos, dentre outros). Em especial, são utilizados algoritmos baseados em vizinhança (AGGARWAL, 2016), algoritmos baseados em técnicas de fatoração de matrizes (KOREN *et al.*, 2009), bem como algoritmos de aprendizado baseados em redes heterogêneas. Nesse sentido, a principal questão a ser considerada é que calcular apenas a acurácia das recomendações como um medidor de performnce não é uma estratégia adequada, visto que os usuários

têm cada vez mais buscado entender como e por que as recomendações lhe são apresentadas (TINTAREV; MASTHOFF, 2007; ZANKER; NINAUS, 2010; BARAL *et al.*, 2018). Diante disso, o principal objetivo deste trabalho de mestrado que permitiu responder às questões de pesquisa foi propor um método para geração de recomendações interpretáveis utilizando o contexto do usuário. As questões de pesquisa que se buscou responder são apresentadas a seguir.

Questão Q1: *É possível agregar em uma única representação de dados as diferentes entidades envolvidas na tarefa de recomendação (usuários, itens e contextos), de tal forma que o modelo de recomendação produzido seja interpretável?*

Como apresentado no Capítulo 4, o método **HINCARS** utiliza as informações de usuários, itens e N dimensões contextuais para construir uma rede heterogênea relacionando essas diferentes entidades. Com base na rede construída, o método proposto executa o algoritmo *GNetMine* para propagar a informação já existente a respeito dos itens (dada pela preferência/nota do usuário por esse item) a todos os outros nós da rede. Com isso, ao final do processo, é possível determinar “a preferência do usuário” por todas as outras entidades consideradas, como itens, outros usuários e contextos.

Esse processo de aprendizado é bastante transparente, porque permite visualizar como os rótulos se propagam pelos relacionamentos da rede construída. Além disso, fica clara a preferência do usuário em relação às outras entidades do sistema (usuários e contextos). Assim, ao predizer que um item deve ser recomendado ao usuário, é possível identificar também quais os usuários e contextos “preferidos” para esse cenário. Essas informações podem ser utilizadas para explicar as recomendações.

Portanto, por meio da definição e proposta do método **HINCARS**, que relaciona diferentes entidades em uma única representação (rede heterogênea), foi possível confirmar essa questão de pesquisa. Além disso, como mencionado no parágrafo anterior, o algoritmo de aprendizado utilizado permite que o processo seja interpretável, o que novamente atende à questão de pesquisa Q1.

Questão Q2: *A agregação dessas diferentes entidades em uma única representação de dados leva a recomendações com acurácia igual ou superior a de outros métodos de recomendação considerados estado-da-arte?*

No Capítulo 5, foram apresentados todos os experimentos realizados para validar o método **HINCARS**. Como apresentado, foi feita uma avaliação exaustiva do método, avaliando a acurácia das recomendações para as diferentes abordagens adotadas para a construção da rede heterogênea, bem como para os diferentes parâmetros considerados.

Os resultados obtidos mostraram que o método **HINCARS** obteve métrica MAP, utilizada para medir a acurácia das recomendações, numericamente superior às obtidas pelo *baseline* considerado (*TriRank*). No entanto, os testes estatísticos realizados não fo-

ram capazes de identificar significância estatística nos resultados, o que possibilita concluir que eles foram estatisticamente equivalentes ao *baseline*.

Ainda assim, diferentemente do *baseline*, o método **HINCARS** tem como vantagem a possibilidade de agregar mais de uma dimensão contextual simultaneamente, o que é de grande valia no processo de recomendação. Dessa forma, a questão de pesquisa Q2 foi atendida pelos experimentos realizados.

6.2 Publicações

Durante o desenvolvimento deste mestrado, foram publicados diversos artigos científicos com os progressos parciais obtidos. A seguir, essas publicações são listadas, apresentando como elas se relacionam a este trabalho.

6.2.1 Artigos publicados em periódicos

SUNDERMANN, Camila Vaccari; PADUA, RENAN; **TONON, Vítor Rodrigues**; MARCACINI, RICARDO MARCONDES ; DOMINGUES, Marcos Aurélio ; REZENDE, Solange Oliveira. A context-aware recommender method based on text and opinion mining. EXPERT SYSTEMS, v.1, p.1, 2020 (**QUALIS B1**).

Nesta publicação, foi desenvolvido um método para recomendação sensível ao contexto utilizando revisões textuais de usuários e mineração de opiniões. Ela se relaciona a esse trabalho de mestrado por ter permitido a extração e utilização do contexto em sistemas de recomendação.

6.2.2 Capítulos de livro publicados

SUNDERMANN, Camila Vaccari; PÁDUA, Renan; **TONON, Vítor Rodrigues**; DOMINGUES, Marcos Aurélio; REZENDE, Solange Oliveira. A Context-Aware Recommender Method Based on Text Mining. Lecture Notes in Computer Science. 1ed.: Springer International Publishing, 2019, v. , p. 385-396 (**QUALIS B1**).

Essa publicação também propôs um método para recomendação de itens utilizando informação contextual extraída de revisões de usuários. Da mesma forma, ela possibilitou a utilização do contexto nos sistemas de recomendação.

6.2.3 Artigos publicados em conferências

RODRIGUES TONON, VITOR; CARVALHO OLIVEIRA, CINTIA ; CARVALHO OLIVEIRA, DANIELE ; DE ANDRADE LOPES, ALNEU ; AKEMI SINOARA, ROBERTA ; MARCONDES MARCACINI, RICARDO ; OLIVEIRA REZENDE, SOLANGE . Improving Recommendations by Using a Heterogeneous Network and User's Reviews. In: 2019 8th Brazilian Conference on Intelligent Systems (BRACIS), 2019, Salvador. 2019 8th Brazilian Conference on Intelligent Systems (BRACIS), 2019. p. 639-644 (**QUALIS B2**).

Essa publicação propôs um método para construção de uma rede heterogênea utilizando informações de usuários, itens e substantivos extraídos das revisões de usuários. Ela foi uma publicação essencial para o desenvolvimento deste mestrado, porque forneceu a experiência necessária para se trabalhar com redes heterogêneas. Além disso, nessa publicação, foi implementado o algoritmo *TriRank* para geração das recomendações, que posteriormente foi utilizado como *baseline* deste mestrado.

TONON, V. R.; SUNDERMANN, C. V. ; REZENDE, S. O.. Implementação e avaliação de sistemas de recomendação, tradicional e sensível ao contexto, baseados em técnicas de fatoração de matrizes.. In: XLIV Latin American Computing Conference (CLATG), 2018, São Paulo. XLIV Latin American Computing Conference (CLATG), 2018. v. 1. p. 1-10. (**QUALIS B3**).

Essa publicação buscou avaliar como a qualidade das recomendações é impactada pelo uso das informações contextuais. Para isso, foram utilizados dois algoritmos de recomendação baseados em fatoração de matrizes: um tradicional, que não utilizava a informação de contexto, e outro, que utilizava. O desempenho obtido pelos dois algoritmos foi comparado e novamente foi mostrado que existe sim benefícios em se utilizar o contexto.

TONON, Vítor Rodrigues; SILVA, T. P.; FERREIRA, V.; PEREIRA, G. T.; REZENDE, S. O.. Evaluating Vector Representations from User's Reviews in a Recommendation Task. In: Encontro Nacional de Inteligência Artificial e Computacional (ENIAC 2019), 2019, Salvador, BA. Anais do Encontro Nacional de Inteligência Artificial e Computacional, 2019. p. 1-11 (**QUALIS B4**).

Essa publicação buscou avaliar como o uso de diferentes representações vetoriais para textos impactam a qualidade das recomendações produzidas.

6.3 Limitações e Trabalhos Futuros

Nessa seção, primeiramente são descritas as limitações identificadas na condução dessa dissertação de mestrado que podem impactar os resultados e as contribuições científicas:

- **Avaliação experimental realizada:** Mesmo que a avaliação experimental tenha sido realizada de maneira exaustiva para validar as abordagens de construção da rede heterogênea e os parâmetros utilizados, ela foi feita considerando apenas uma base de dados. Em geral, é interessante realizar a avaliação em mais bases de dados, preferencialmente de diferentes domínios e características, a fim de verificar a validade/viabilidade em se utilizar o método proposto em diferentes cenários.
- **Ausência da geração de explicações:** Apesar do método *HINCARS* gerar recomendações interpretáveis, não são criadas explicações propriamente ditas. A interpretabilidade das recomendações já é um passo inicial nesse sentido, porém ainda há muito o que ser feito, como por exemplo definir a melhor abordagem para apresentação/visualização dessas explicações (TINTAREV; MASTHOFF, 2007).

De acordo com os pontos levantados acima, surgem direcionamentos de trabalhos futuros, que são apresentados a seguir:

- **Avaliação experimental em mais bases de dados:** a avaliação experimental deveria ser realizada em duas bases de dados ou mais. Dessa forma, outras bases de dados reais devem ser exploradas e utilizadas na avaliação, desde que sejam consideradas apropriadas para o problema em questão.
- **Proposta de um método para geração de explicações:** Considerando o funcionamento do método *HINCARS*, bem como suas entradas e saídas, novos trabalhos devem ser realizados a fim de identificar a melhor abordagem para geração de explicações. A partir disso, estudos com usuários devem ser feitos para avaliar o impacto dessas explicações em outros aspectos diferentes da acurácia, como satisfação e confiança do usuário.
- **Utilização de outras fontes de informação:** Além das informações de contexto, existem muitas outras fontes de informação que podem ser relevantes para o processo de recomendação, como textos, áudios e imagens, que também se mostraram bastante promissoras. Nesse sentido, novos estudos podem explorar a utilização dessas outras informações no método *HINCARS*, que foi projetado para lidar com vários objetos de tipos diferentes.

Referências

- ABBAS, S. M.; ALAM, K. A. Exploiting relevant context with soft-rough sets in context-aware video recommender systems. In: IEEE. **2019 IEEE International Conference on Fuzzy Systems (FUZZ-IEEE)**. Louisiana, USA, 2019. p. 1–6. Citado nas páginas 7 e 8.
- ABDOLLAHI, B.; NASRAOUI, O. Using explainability for constrained matrix factorization. In: ACM. **Proceedings of the Eleventh ACM Conference on Recommender Systems**. Como, Italy, 2017. p. 79–83. Citado nas páginas 3, 34 e 41.
- ADOMAVICIUS, G.; SANKARANARAYANAN, R.; SEN, S.; TUZHILIN, A. Incorporating contextual information in recommender systems using a multidimensional approach. **ACM Transactions on Information Systems (TOIS)**, ACM, v. 23, n. 1, p. 103–145, 2005. Citado nas páginas 2 e 25.
- ADOMAVICIUS, G.; TUZHILIN, A. Context-aware recommender systems. In: **Recommender systems handbook**. Boston, USA: Springer, 2011. p. 217–253. Citado nas páginas 2, 11, 24, 43, 70 e 77.
- AGGARWAL, C. C. **Recommender Systems: The textbook**. 1. ed. Switzerland: Springer, 2016. Citado nas páginas 1, 2, 7, 9, 12, 14, 15, 16, 17, 23, 28, 29, 30, 47, 54, 63 e 77.
- ALI, W.; DIN, S. U.; KHAN, A. A.; TUMRANI, S.; WANG, X.; SHAO, J. Context-aware collaborative filtering framework for rating prediction based on novel similarity estimation. **Computers, Materials & Continua**, v. 63, n. 2, p. 1065–1078, 2020. Citado na página 2.
- BARAL, R.; ZHU, X.; IYENGAR, S.; LI, T. Reel: Review aware explanation of location recommendation. In: ACM. **Proceedings of the 26th Conference on User Modeling, Adaptation and Personalization**. Singapore, 2018. p. 23–32. Citado nas páginas 2, 7, 8, 14, 17, 25, 34, 35, 39, 43, 45 e 78.
- BELEVESLIS, D.; TJORTJIS, C. Promoting diversity in content based recommendation using feature weighting and lsh. In: MAGLOGIANNIS, I.; ILIADIS, L.; PIMENIDIS, E. (Ed.). **Artificial Intelligence Applications and Innovations**. Cham: Springer International Publishing, 2020. p. 452–461. ISBN 978-3-030-49161-1. Citado na página 15.
- BERTOSSI, L.; GEERTS, F. Data quality and explainable ai. **Journal of Data and Information Quality (JDIQ)**, ACM New York, NY, USA, v. 12, n. 2, p. 1–9, 2020. Citado nas páginas 2 e 14.
- BLANCO-MALLO, E.; REMESEIRO, B.; BOLÓN-CANEDO, V.; ALONSO-BETANZOS, A. On the effectiveness of convolutional autoencoders on image-based personalized recommender systems. **arXiv preprint arXiv:2003.06205**, 2020. Citado nas páginas 7 e 8.

- BOTTOU, L. Stochastic gradient descent tricks. **Neural networks: Tricks of the trade**, Springer, p. 421–436, 2012. Citado na página 22.
- CHANG, S.; HARPER, F. M.; TERVEEN, L. G. Crowd-based personalized natural language explanations for recommendations. In: ACM. **Proceedings of the 10th ACM Conference on Recommender Systems**. Boston, USA, 2016. p. 175–182. Citado nas páginas 34, 41, 43 e 45.
- CHEN, L.; WANG, F. Explaining recommendations based on feature sentiments in product reviews. In: ACM. **Proceedings of the 22nd International Conference on Intelligent User Interfaces**. Limassol, Cyprus, 2017. p. 17–28. Citado nas páginas 34, 41 e 45.
- CHEN, W.; HSU, W.; LEE, M. L. Tagcloud-based explanation with feedback for recommender systems. In: ACM. **Proceedings of the 36th international ACM SIGIR conference on Research and development in information retrieval**. Dublin, Ireland, 2013. p. 945–948. Citado nas páginas 34, 40 e 45.
- CHEN, X.; QIN, Z.; ZHANG, Y.; XU, T. Learning to rank features for recommendation over multiple categories. In: ACM. **Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval**. Pisa, Italy, 2016. (SIGIR '16), p. 305–314. Citado na página 3.
- CHENG, Z.; CHANG, X.; ZHU, L.; KANJIRATHINKAL, R. C.; KANKANHALLI, M. Mmalfm: Explainable recommendation by leveraging reviews and images. **ACM Transactions on Information Systems (TOIS)**, ACM New York, NY, USA, v. 37, n. 2, p. 1–28, 2019. Citado nas páginas 7 e 8.
- DESHPANDE, M.; KARYPIS, G. Item-based top-n recommendation algorithms. **ACM Transactions on Information Systems (TOIS)**, ACM, v. 22, n. 1, p. 143–177, 2004. Citado nas páginas 25 e 43.
- DESROSIERS, C.; KARYPIS, G. A comprehensive survey of neighborhood-based recommendation methods. In: **Recommender systems handbook**. Boston, USA: Springer, 2011. p. 107–144. Citado na página 15.
- DEY, A. K. Understanding and using context. **Personal and ubiquitous computing**, Springer-Verlag, v. 5, n. 1, p. 4–7, 2001. Citado na página 2.
- DOMINGUES, M. A.; JORGE, A. M.; SOARES, C. Dimensions as virtual items: Improving the predictive ability of top-n recommender systems. **Information Processing & Management**, Elsevier, v. 49, n. 3, p. 698–720, 2013. Citado na página 25.
- DOMINGUES, M. A.; SUNDERMANN, C. V.; MANZATO, M. G.; MARCACINI, R. M.; REZENDE, S. O. Exploiting text mining techniques for contextual recommendations. In: IEEE. **Web Intelligence (WI) and Intelligent Agent Technologies (IAT), 2014 IEEE/WIC/ACM International Joint Conferences on**. Warsaw, Poland, 2014. v. 2, p. 210–217. Citado nas páginas 2, 43 e 77.
- DONKERS, T.; KLEEMANN, T.; ZIEGLER, J. Explaining recommendations by means of aspect-based transparent memories. In: **Proceedings of the 25th International Conference on Intelligent User Interfaces**. New York, NY, USA: Association for

Computing Machinery, 2020. (IUI '20), p. 166–176. ISBN 9781450371186. Citado nas páginas 34, 42 e 43.

FRIEDMAN, A.; BERKOVSKY, S.; KAAFAR, M. A. A differential privacy framework for matrix factorization recommender systems. **User Modeling and User-Adapted Interaction**, Springer, v. 26, n. 5, p. 425–458, 2016. Citado na página 21.

GETOOR, L.; DIEHL, C. P. Link mining: a survey. **Acm Sigkdd Explorations Newsletter**, ACM, v. 7, n. 2, p. 3–12, 2005. Citado na página 10.

GHAZIMATIN, A.; BALALAU, O.; ROY, R. S.; WEIKUM, G. Prince: provider-side interpretability with counterfactual explanations in recommender systems. In: **ACM. Proceedings of the 13th International Conference on Web Search and Data Mining**. Houston, USA, 2020. p. 196–204. Citado nas páginas 34, 35 e 40.

GOMEZ-URIBE, C. A.; HUNT, N. The netflix recommender system: Algorithms, business value, and innovation. **ACM Transactions on Management Information Systems (TMIS)**, ACM New York, NY, USA, v. 6, n. 4, p. 1–19, 2015. Citado na página 1.

GORGOGNONE, M.; PANNIELLO, U.; TUZHILIN, A. The effect of context-aware recommendations on customer purchasing behavior and trust. In: **ACM. Proceedings of the fifth ACM conference on Recommender systems**. Chicago, USA, 2011. p. 85–92. Citado na página 2.

GUAN, X.; LI, C.-T.; GUAN, Y. Matrix factorization with rating completion: An enhanced svd model for collaborative filtering recommender systems. **IEEE access**, IEEE, v. 5, p. 27668–27678, 2017. Citado na página 21.

GUO, Q.; SUN, Z.; ZHANG, J.; CHEN, Q.; THENG, Y.-L. Aspect-aware point-of-interest recommendation with geo-social influence. In: **Adjunct Publication of the 25th Conference on User Modeling, Adaptation and Personalization**. Bratislava, Slovakia: ACM, 2017. (UMAP '17), p. 17–22. Citado nas páginas 34, 35, 38, 43 e 45.

HARIRI, N.; MOBASHER, B.; BURKE, R.; ZHENG, Y. Context-aware recommendation based on review mining. In: **CITESEER. Proceedings of the 9th Workshop on Intelligent Techniques for Web Personalization and Recommender Systems (ITWP 2011)**. Barcelona, Spain, 2011. p. 30. Citado na página 2.

HAVELIWALA, T. H. Topic-sensitive pagerank. In: **ACM. Proceedings of the 11th international conference on World Wide Web**. Hawaii, USA, 2002. p. 517–526. Citado na página 39.

HE, X.; CHEN, T.; KAN, M.-Y.; CHEN, X. Trirank: Review-aware explainable recommendation by modeling aspects. In: **Proceedings of the 24th ACM International on Conference on Information and Knowledge Management**. Melbourne, Australia: ACM, 2015. (CIKM '15), p. 1661–1670. Citado nas páginas 11, 20, 34, 35, 37, 38, 45 e 63.

HERLOCKER, J. L.; KONSTAN, J. A.; RIEDL, J. Explaining collaborative filtering recommendations. In: **ACM. Proceedings of the 2000 ACM conference on Computer supported cooperative work**. Philadelphia, USA, 2000. p. 241–250. Citado nas páginas 15, 26, 27, 34, 40 e 45.

- HOLZINGER, A. From machine learning to explainable ai. In: IEEE. **2018 World Symposium on Digital Intelligence for Systems and Machines (DISA)**. Kosice, Slovakia, 2018. p. 55–66. Citado nas páginas 2 e 14.
- JI, M.; SUN, Y.; DANILEVSKY, M.; HAN, J.; GAO, J. Graph regularized transductive classification on heterogeneous information networks. In: SPRINGER. **Joint European Conference on Machine Learning and Knowledge Discovery in Databases**. Barcelona, Spain, 2010. p. 570–586. Citado na página 18.
- JIANG, Z.; LIU, H.; FU, B.; WU, Z.; ZHANG, T. Recommendation in heterogeneous information networks based on generalized random walk model and bayesian personalized ranking. In: ACM. **Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining**. Marina Del Rey, USA, 2018. p. 288–296. Citado nas páginas 34, 35, 40 e 45.
- JUAN, Y.; ZHUANG, Y.; CHIN, W.-S.; LIN, C.-J. Field-aware factorization machines for ctr prediction. In: ACM. **Proceedings of the 10th ACM Conference on Recommender Systems**. Boston, USA, 2016. p. 43–50. Citado na página 36.
- KARATZOGLOU, A.; AMATRIAIN, X.; BALTRUNAS, L.; OLIVER, N. Multiverse recommendation: n-dimensional tensor factorization for context-aware collaborative filtering. In: ACM. **Proceedings of the fourth ACM conference on Recommender systems**. Barcelona, Spain, 2010. p. 79–86. Citado nas páginas 2, 43 e 70.
- KOREN, Y.; BELL, R. Advances in collaborative filtering. In: **Recommender systems handbook**. USA: Springer, 2011. p. 145–186. Citado na página 21.
- KOREN, Y.; BELL, R.; VOLINSKY, C. *et al.* Matrix factorization techniques for recommender systems. **Computer**, Institute of Electrical and Electronics Engineers, Inc., 3 Park Avenue, 17 th Fl New York NY 10016-5997 United States, v. 42, n. 8, p. 30–37, 2009. Citado nas páginas 2, 21, 25, 41, 43 e 77.
- KOUKI, P.; SCHAFFER, J.; PUJARA, J.; O'DONOVAN, J.; GETOOR, L. Personalized explanations for hybrid recommender systems. In: ACM. **Proceedings of the 24th International Conference on Intelligent User Interfaces**. California, USA, 2019. p. 379–390. Citado nas páginas 34 e 42.
- LAMCHE, B.; ADIGÜZEL, U.; WÖRNDL, W. Interactive explanations in mobile shopping recommender systems. In: ACM. **Joint Workshop on Interfaces and Human Decision Making in Recommender Systems**. California, USA, 2014. p. 14. Citado nas páginas 2, 25, 26 e 43.
- LAWSON, C. L.; HANSON, R. J. **Solving least squares problems**. USA: Siam, 1995. v. 15. Citado na página 22.
- LI, Y.; NIE, J.; ZHANG, Y.; WANG, B.; YAN, B.; WENG, F. Contextual recommendation based on text mining. In: ASSOCIATION FOR COMPUTATIONAL LINGUISTICS. **Proceedings of the 23rd International Conference on Computational Linguistics: Posters**. USA, 2010. p. 692–700. Citado nas páginas 2 e 54.
- LOPS, P.; GEMMIS, M. D.; SEMERARO, G. Content-based recommender systems: State of the art and trends. In: **Recommender systems handbook**. Boston, USA: Springer, 2011. p. 73–105. Citado nas páginas 25 e 43.

- LOPS, P.; JANNACH, D.; MUSTO, C.; BOGERS, T.; KOOLEN, M. Trends in content-based recommendation. **User Modeling and User-Adapted Interaction**, Springer, v. 29, n. 2, p. 239–249, 2019. Citado na página 15.
- MCAULEY, J.; LESKOVEC, J. Hidden factors and hidden topics: understanding rating dimensions with review text. In: ACM. **Proceedings of the 7th ACM conference on Recommender systems**. Hong Kong, China, 2013. p. 165–172. Citado na página 38.
- MUSTO, C.; NARDUCCI, F.; LOPS, P.; GEMMIS, M. de; SEMERARO, G. Linked open data-based explanations for transparent recommender systems. **International Journal of Human-Computer Studies**, Elsevier, v. 121, p. 93–107, 2019. Citado nas páginas 34 e 42.
- NELSON, N. The power of a picture. In: <https://media.netflix.com/en/company-blog/the-power-of-a-picture>. .: Access in 20/05/2020, 2016. Citado na página 2.
- NEWMAN, M. **Networks: An Introduction**. New York, NY, USA: Oxford University Press, Inc., 2010. ISBN 0199206651, 9780199206650. Citado nas páginas 9, 10 e 49.
- NUNES, I.; JANNACH, D. A systematic review and taxonomy of explanations in decision support and recommender systems. **User Modeling and User-Adapted Interaction**, v. 27, n. 3, p. 393–444, 2017. Citado na página 26.
- PANNIELLO, U.; GORGOGNONE, M. Incorporating context into recommender systems: an empirical comparison of context-based approaches. **Electronic Commerce Research**, Springer, v. 12, n. 1, p. 1–30, 2012. Citado nas páginas 24 e 25.
- PAZZANI, M. J.; BILLSUS, D. Content-based recommendation systems. In: **The adaptive web**. Berlin, Germany: Springer, 2007. p. 325–341. Citado na página 14.
- PHAM, T.-A.; LI, X.; CONG, G.; ZHANG, Z. A general recommendation model for heterogeneous networks. **IEEE Transactions on Knowledge & Data Engineering**, IEEE, n. 1, p. 1–1, 2016. Citado nas páginas 3, 8, 11, 20, 31, 34, 35, 38, 40 e 45.
- RAZA, S.; DING, C. Progress in context-aware recommender systems—an overview. **Computer Science Review**, Elsevier, v. 31, p. 84–97, 2019. Citado na página 2.
- RENDLE, S. Factorization machines. In: IEEE. **Data Mining (ICDM), 2010 IEEE 10th International Conference on**. Sydney, Australia, 2010. p. 995–1000. Citado na página 39.
- RENJITH, S.; SREEKUMAR, A.; JATHAVEDAN, M. An extensive study on the evolution of context-aware personalized travel recommender systems. **Information Processing & Management**, Elsevier, v. 57, n. 1, p. 102078, 2020. Citado na página 2.
- RICCI, F.; ROKACH, L.; SHAPIRA, B. Recommender systems: introduction and challenges. In: **Recommender systems handbook**. Boston, USA: Springer, 2015. p. 1–34. Citado nas páginas 12, 14, 17, 28 e 63.
- SAMEK, W. **Explainable AI: interpreting, explaining and visualizing deep learning**. Switzerland: Springer Nature, 2019. v. 11700. Citado nas páginas 2 e 14.

- SATO, M.; AHSAN, B.; NAGATANI, K.; SONODA, T.; ZHANG, Q.; OHKUMA, T. Explaining recommendations using contexts. In: **23rd International Conference on Intelligent User Interfaces**. Japan: ACM, 2018. p. 659–664. Citado nas páginas [3](#), [7](#), [8](#), [17](#), [34](#), [35](#), [36](#), [43](#), [45](#) e [77](#).
- SHAPIRA, B.; RICCI, F.; KANTOR, P. B.; ROKACH, L. Recommender systems handbook. Springer, 2011. Citado na página [9](#).
- SHI, C.; LI, Y.; ZHANG, J.; SUN, Y.; PHILIP, S. Y. A survey of heterogeneous information network analysis. **IEEE Transactions on Knowledge and Data Engineering**, IEEE, v. 29, n. 1, p. 17–37, 2017. Citado nas páginas [8](#), [10](#), [11](#), [20](#), [31](#), [43](#), [45](#) e [49](#).
- SHU, J.; SHEN, X.; LIU, H.; YI, B.; ZHANG, Z. A content-based recommendation algorithm for learning resources. **Multimedia Systems**, Springer, v. 24, n. 2, p. 163–173, 2018. Citado na página [15](#).
- SUN, Y.; HAN, J.; YAN, X.; YU, P. S.; WU, T. Pathsim: Meta path-based top-k similarity search in heterogeneous information networks. **Proceedings of the VLDB Endowment**, Citeseer, v. 4, n. 11, p. 992–1003, 2011. Citado na página [39](#).
- SUNDERMANN, C. V.; DOMINGUES, M. A.; CONRADO, M. da S.; REZENDE, S. O. Privileged contextual information for context-aware recommender systems. **Expert Systems with Applications**, Elsevier, v. 57, p. 139–158, 2016. Citado nas páginas [2](#), [43](#) e [70](#).
- SUNDERMANN, C. V.; DOMINGUES, M. A.; SINOARA, R. A.; MARCACINI, R. M.; REZENDE, S. O. Using opinion mining in context-aware recommender systems: A systematic review. **Information**, Multidisciplinary Digital Publishing Institute, v. 10, n. 2, p. 42, 2019. Citado na página [2](#).
- SUNDERMANN, C. V.; PADUA, R. de; TONON, V. R.; MARCACINI, R. M.; DOMINGUES, M. A.; REZENDE, S. O. A context-aware recommender method based on text and opinion mining. **Expert Systems**, v. 37, n. 6, p. e12618, 2020. Citado nas páginas [7](#), [8](#) e [77](#).
- TINTAREV, N.; MASTHOFF, J. A survey of explanations in recommender systems. In: IEEE. **Data Engineering Workshop, 2007 IEEE 23rd International Conference on**. Turkey, 2007. p. 801–810. Citado nas páginas [2](#), [17](#), [25](#), [26](#), [43](#), [78](#) e [81](#).
- TONON, V. R.; OLIVEIRA, C. C.; OLIVEIRA, D. C.; de A. Lopes, A.; SINOARA, R. A.; MARCACINI, R. M.; REZENDE, S. O. Improving recommendations by using a heterogeneous network and user’s reviews. In: IEEE. **2019 8th Brazilian Conference on Intelligent Systems (BRACIS)**. Salvador, Brasil, 2019. p. 639–644. Citado nas páginas [7](#) e [8](#).
- VASWANI, A.; SHAZEER, N.; PARMAR, N.; USZKOREIT, J.; JONES, L.; GOMEZ, A. N.; KAISER, L.; POLOSUKHIN, I. Attention is all you need. **arXiv preprint arXiv:1706.03762**, 2017. Citado na página [43](#).
- WANG, H.; FU, Q.; LIU, L.; SONG, W. A probabilistic rating prediction and explanation inference model for recommender systems. **China Communications**, v. 13, n. 2, p. 79–94, 2016. Citado na página [3](#).

- WU, H.; ZHANG, Z.; YUE, K.; ZHANG, B.; HE, J.; SUN, L. Dual-regularized matrix factorization with deep neural networks for recommender systems. **Knowledge-Based Systems**, Elsevier, v. 145, p. 46–58, 2018. Citado na página 21.
- XUE, H.-J.; DAI, X.; ZHANG, J.; HUANG, S.; CHEN, J. Deep matrix factorization models for recommender systems. In: ACM. **IJCAI**. Melbourne, Australia, 2017. v. 17, p. 3203–3209. Citado na página 21.
- YUAN, W.; WANG, H.; YU, X.; LIU, N.; LI, Z. Attention-based context-aware sequential recommendation model. **Information Sciences**, Elsevier, v. 510, p. 122–134, 2020. Citado na página 2.
- ZANKER, M.; NINAUS, D. Knowledgeable explanations for recommender systems. In: IEEE. **Web Intelligence and Intelligent Agent Technology (WI-IAT), 2010 IEEE/WIC/ACM International Conference on**. Canada, 2010. v. 1, p. 657–660. Citado nas páginas 2, 25, 26 e 78.
- ZHANG, S.; YAO, L.; SUN, A. Deep learning based recommender system: A survey and new perspectives. **arXiv preprint arXiv:1707.07435**, 2017. Citado nas páginas 25 e 43.
- ZHANG, Y.; LAI, G.; ZHANG, M.; ZHANG, Y.; LIU, Y.; MA, S. Explicit factor models for explainable recommendation based on phrase-level sentiment analysis. In: **Proceedings of the 37th International ACM SIGIR Conference on Research & Development in Information Retrieval**. New York, NY, USA: ACM, 2014. (SIGIR '14), p. 83–92. Citado nas páginas 3, 34, 41 e 45.
- ZHENG, Y.; MOBASHER, B.; BURKE, R. Carskit: A java-based context-aware recommendation engine. In: IEEE. **2015 IEEE International Conference on Data Mining Workshop (ICDMW)**. USA, 2015. p. 1668–1671. Citado na página 4.
- ZHENG, Y.; MOBASHER, B.; BURKE, R. User-oriented context suggestion. In: ACM. **Proceedings of the 2016 Conference on User Modeling Adaptation and Personalization**. Canada, 2016. p. 249–258. Citado nas páginas 34, 35, 36, 43, 45 e 62.
- ZHOU, D.; SCHÖLKOPF, B. A regularization framework for learning from graph data. In: ACM. **ICML 2004 Workshop on Statistical Relational Learning and Its Connections to Other Fields (SRL 2004)**. Canada, 2004. p. 132–137. Citado nas páginas 18 e 54.

Resultados do método *HINCARS*

Na Tabela 11, são apresentados os resultados obtidos pelos experimentos realizados neste trabalho de mestrado. Em negrito, está destacado o valor da métrica MAP para os experimentos que foram estatisticamente iguais ou superiores ao *baseline*. A coluna *Normaliza* indica se o vetor de confianças retornado pelo *GNetMine* foi normalizado ou não. Essa coluna foi suprimida da Tabela 10, porque todos os experimentos nela apresentados tiveram o mesmo valor.

Tabela 11 – Resultados de todos os experimentos realizados

Experimento	Taxa Usuário	Abordagem	Pesos	Normaliza	MAP
E_1	0.05	Abordagem	1,1,1,1,1	✗	0.19541
E_1	0.2	Completa	1,1,1,1,1	✗	0.19541
E_7	0.1	Heterogênea Itens	1,1,1,1,1	✗	0.19402
E_7	0.1	Completa	1,1,1,1,1	✗	0.19349
E_1	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.19321
E_1	0.05	Heterogênea Itens	1,1,1,1,1	✗	0.19304
E_1	0.2	Heterogênea Itens	1,1,1,1,1	✗	0.19304
E_1	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.19174
E_7	0.1	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.19170
E_6	0.1	Heterogênea Itens	1,1,1,1,1	✗	0.19080
E_6	0.05	Heterogênea Itens	1,1,1,1,1	✗	0.18777
E_6	0.2	Heterogênea Itens	1,1,1,1,1	✗	0.18777
E_6	0.1	Completa	1,1,1,1,1	✗	0.18775

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_4	0.05	Heterogênea Itens	1,1,1,1,1	✖	0.18723
E_4	0.2	Heterogênea Itens	1,1,1,1,1	✖	0.18723
E_5	0.05	Completa	1,1,1,1,1	✖	0.18663
E_5	0.2	Completa	1,1,1,1,1	✖	0.18663
E_5	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✖	0.18648
E_6	0.1	Enriquecimento Usuários Similares	1,1,1,1,1	✖	0.18618
E_8	0.05	Heterogênea Itens	0,0,1,1,1	✖	0.18475
E_8	0.1	Heterogênea Itens	0,0,1,1,1	✖	0.18475
E_8	0.2	Heterogênea Itens	0,0,1,1,1	✖	0.18475
E_5	0.05	Heterogênea Itens	1,1,1,1,1	✖	0.18459
E_5	0.2	Heterogênea Itens	1,1,1,1,1	✖	0.18459
E_7	0.05	Heterogênea Itens	1,1,1,1,1	✖	0.18459
E_7	0.2	Heterogênea Itens	1,1,1,1,1	✖	0.18459
E_8	0.1	Enriquecimento Usuários Similares	1,1,1,1,1	✖	0.18414
E_6	0.1	Completa	0,0,1,5,10	✖	0.18410
E_6	0.05	Completa	1,1,1,1,1	✖	0.18377
E_6	0.2	Completa	1,1,1,1,1	✖	0.18377
E_5	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✖	0.18369
E_6	0.1	Completa	0,0,1,1,1	✖	0.18351
E_8	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✖	0.18341
E_6	0.1	Heterogênea Itens	0,0,1,1,1	✖	0.18310
E_6	0.1	Heterogênea Itens	0,0,1,5,10	✖	0.18260
E_6	0.05	Heterogênea Itens	0,0,1,5,10	✖	0.18260
E_6	0.2	Heterogênea Itens	0,0,1,5,10	✖	0.18260
E_6	0.05	Heterogênea Itens	0,0,1,1,1	✖	0.18227
E_6	0.2	Heterogênea Itens	0,0,1,1,1	✖	0.18227
E_8	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✖	0.18226
E_3	0.05	Heterogênea Usuários	1,1,1,1,1	✖	0.18195

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_3	0.2	Heterogênea Usuários	1,1,1,1,1	✗	0.18195
E_3	0.05	N-Partida	1,1,1,1,1	✗	0.18180
E_3	0.2	N-Partida	1,1,1,1,1	✗	0.18180
E_6	0.1	Completa	0,0,1,3,5	✗	0.18136
E_6	0.05	Heterogênea Itens	0,0,1,3,5	✗	0.18127
E_6	0.2	Heterogênea Itens	0,0,1,3,5	✗	0.18127
E_8	0.05	Completa	1,1,1,1,1	✗	0.18115
E_8	0.1	Completa	1,1,1,1,1	✗	0.18115
E_8	0.2	Completa	1,1,1,1,1	✗	0.18115
E_2	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.18098
E_3	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.18096
E_7	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.18072
E_7	0.1	Heterogênea Usuários	1,1,1,1,1	✗	0.18066
E_2	0.05	Completa	1,1,1,1,1	✗	0.18042
E_2	0.2	Completa	1,1,1,1,1	✗	0.18042
E_5	0.05	Heterogênea Usuários	1,1,1,1,1	✗	0.18003
E_5	0.2	Heterogênea Usuários	1,1,1,1,1	✗	0.18003
E_6	0.1	Completa	1,2,3,4,5	✗	0.17995
E_7	0.1	N-Partida	1,1,1,1,1	✗	0.17988
E_5	0.05	N-Partida	1,1,1,1,1	✗	0.17965
E_5	0.2	N-Partida	1,1,1,1,1	✗	0.17965
E_3	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.17960
E_6	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.17957
E_6	0.1	Heterogênea Itens	0,0,1,3,5	✗	0.17955
E_1	0.05	N-Partida	1,1,1,1,1	✗	0.17948
E_1	0.2	N-Partida	1,1,1,1,1	✗	0.17948
E_4	0.05	Heterogênea Itens	1,2,3,4,5	✗	0.17941

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_4	0.2	Heterogênea Itens	1,2,3,4,5	✖	0.17941
E_3	0.05	Heterogênea Itens	1,1,1,1,1	✖	0.17935
E_3	0.2	Heterogênea Itens	1,1,1,1,1	✖	0.17935
E_8	0.05	N-Partida	1,2,3,4,5	✖	0.17915
E_8	0.1	N-Partida	1,2,3,4,5	✖	0.17915
E_8	0.2	N-Partida	1,2,3,4,5	✖	0.17915
E_6	0.1	Heterogênea Itens	1,2,3,4,5	✖	0.17915
E_6	0.1	N-Partida	1,1,1,1,1	✖	0.17914
E_1	0.05	Heterogênea Itens	0,0,1,1,1	✖	0.17912
E_1	0.2	Heterogênea Itens	0,0,1,1,1	✖	0.17912
E_3	0.05	Completa	1,1,1,1,1	✖	0.17906
E_3	0.2	Completa	1,1,1,1,1	✖	0.17906
E_4	0.05	Heterogênea Itens	0,0,1,5,10	✖	0.17898
E_4	0.2	Heterogênea Itens	0,0,1,5,10	✖	0.17898
E_1	0.05	Completa	0,0,1,1,1	✖	0.17890
E_1	0.2	Completa	0,0,1,1,1	✖	0.17890
E_6	0.05	Heterogênea Itens	1,2,3,4,5	✖	0.17873
E_6	0.2	Heterogênea Itens	1,2,3,4,5	✖	0.17873
E_8	0.05	N-Partida	1,1,1,1,1	✖	0.17868
E_8	0.1	N-Partida	1,1,1,1,1	✖	0.17868
E_8	0.2	N-Partida	1,1,1,1,1	✖	0.17868
E_7	0.05	Heterogênea Itens	1,2,3,4,5	✖	0.17861
E_7	0.2	Heterogênea Itens	1,2,3,4,5	✖	0.17861
E_2	0.05	Heterogênea Itens	1,1,1,1,1	✖	0.17858
E_2	0.2	Heterogênea Itens	1,1,1,1,1	✖	0.17858
E_2	0.05	Heterogênea Itens	0,0,1,5,10	✖	0.17849
E_2	0.2	Heterogênea Itens	0,0,1,5,10	✖	0.17849
E_7	0.05	N-Partida	1,1,1,1,1	✖	0.17838
E_7	0.2	N-Partida	1,1,1,1,1	✖	0.17838
E_4	0.05	Heterogênea Itens	0,0,1,1,1	✖	0.17828
E_4	0.2	Heterogênea Itens	0,0,1,1,1	✖	0.17828
E_3	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✖	0.17828
E_4	0.05	Completa	0,0,1,5,10	✖	0.17819
E_4	0.2	Completa	0,0,1,5,10	✖	0.17819
E_2	0.05	N-Partida	1,1,1,1,1	✖	0.17817

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_2	0.2	N-Partida	1,1,1,1,1	✖	0.17817
E_6	0.05	Heterogênea Usuários	1,1,1,1,1	✖	0.17810
E_6	0.2	Heterogênea Usuários	1,1,1,1,1	✖	0.17810
E_8	0.05	N-Partida	0,0,1,5,10	✖	0.17810
E_8	0.1	N-Partida	0,0,1,5,10	✖	0.17810
E_8	0.2	N-Partida	0,0,1,5,10	✖	0.17810
E_8	0.05	N-Partida	0,0,1,1,1	✖	0.17771
E_8	0.1	N-Partida	0,0,1,1,1	✖	0.17771
E_8	0.2	N-Partida	0,0,1,1,1	✖	0.17771
E_6	0.05	N-Partida	1,1,1,1,1	✖	0.17770
E_6	0.2	N-Partida	1,1,1,1,1	✖	0.17770
E_6	0.1	Completa	0,0,0,1,1	✖	0.17767
E_4	0.05	Completa	1,1,1,1,1	✖	0.17760
E_4	0.2	Completa	1,1,1,1,1	✖	0.17760
E_4	0.05	Heterogênea Itens	0,0,1,3,5	✖	0.17756
E_4	0.2	Heterogênea Itens	0,0,1,3,5	✖	0.17756
E_4	0.05	N-Partida	1,1,1,1,1	✖	0.17756
E_4	0.2	N-Partida	1,1,1,1,1	✖	0.17756
E_2	0.05	Heterogênea Usuários	1,1,1,1,1	✖	0.17756
E_2	0.2	Heterogênea Usuários	1,1,1,1,1	✖	0.17756
E_7	0.05	Heterogênea Itens	0,0,1,5,10	✖	0.17751
E_7	0.2	Heterogênea Itens	0,0,1,5,10	✖	0.17751
E_4	0.05	Heterogênea Usuários	1,1,1,1,1	✖	0.17749
E_4	0.2	Heterogênea Usuários	1,1,1,1,1	✖	0.17749
E_7	0.1	Heterogênea Itens	0,0,1,1,1	✖	0.17742
E_6	0.05	Completa	1,2,3,4,5	✖	0.17722
E_6	0.2	Completa	1,2,3,4,5	✖	0.17722
E_8	0.05	Heterogênea Itens	1,1,1,1,1	✖	0.17713
E_8	0.1	Heterogênea Itens	1,1,1,1,1	✖	0.17713
E_8	0.2	Heterogênea Itens	1,1,1,1,1	✖	0.17713

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_7	0.05	Heterogênea Itens	0,0,1,1,1	✖	0.17709
E_7	0.2	Heterogênea Itens	0,0,1,1,1	✖	0.17709
E_8	0.05	Heterogênea Usuários	1,1,1,1,1	✖	0.17708
E_8	0.1	Heterogênea Usuários	1,1,1,1,1	✖	0.17708
E_8	0.2	Heterogênea Usuários	1,1,1,1,1	✖	0.17708
E_2	0.05	Heterogênea Itens	1,2,3,4,5	✖	0.17707
E_2	0.2	Heterogênea Itens	1,2,3,4,5	✖	0.17707
E_6	0.1	Heterogênea Usuários	1,1,1,1,1	✖	0.17694
E_7	0.1	Completa	0,0,1,1,1	✖	0.17692
E_1	0.05	Heterogênea Usuários	1,1,1,1,1	✖	0.17692
E_1	0.2	Heterogênea Usuários	1,1,1,1,1	✖	0.17692
E_2	0.05	N-Partida	0,0,1,5,10	✖	0.17682
E_2	0.2	N-Partida	0,0,1,5,10	✖	0.17682
E_7	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✖	0.17682
E_2	0.05	Heterogênea Usuários	1,2,3,4,5	✖	0.17681
E_2	0.2	Heterogênea Usuários	1,2,3,4,5	✖	0.17681
E_6	0.1	Heterogênea Usuários	0,0,1,3,5	✖	0.17668
E_7	0.05	Heterogênea Itens	0,0,1,3,5	✖	0.17663
E_7	0.2	Heterogênea Itens	0,0,1,3,5	✖	0.17663
E_7	0.05	Completa	0,0,1,5,10	✖	0.17655
E_7	0.2	Completa	0,0,1,5,10	✖	0.17655
E_6	0.05	Completa	0,0,1,3,5	✖	0.17653
E_6	0.2	Completa	0,0,1,3,5	✖	0.17653
E_7	0.05	Heterogênea Usuários	1,1,1,1,1	✖	0.17649

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_7	0.2	Heterogênea Usuários	1,1,1,1,1	✗	0.17649
E_6	0.1	Heterogênea Usuários	0,0,1,5,10	✗	0.17648
E_3	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.17646
E_8	0.05	N-Partida	0,0,1,3,5	✗	0.17641
E_8	0.1	N-Partida	0,0,1,3,5	✗	0.17641
E_8	0.2	N-Partida	0,0,1,3,5	✗	0.17641
E_5	0.05	Completa	0,0,1,1,1	✗	0.17637
E_5	0.2	Completa	0,0,1,1,1	✗	0.17637
E_2	0.05	Heterogênea Itens	0,0,1,3,5	✗	0.17634
E_2	0.2	Heterogênea Itens	0,0,1,3,5	✗	0.17634
E_2	0.05	N-Partida	1,2,3,4,5	✗	0.17632
E_2	0.2	N-Partida	1,2,3,4,5	✗	0.17632
E_6	0.1	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17632
E_4	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.17631
E_4	0.05	N-Partida	0,0,1,5,10	✗	0.17626
E_4	0.2	N-Partida	0,0,1,5,10	✗	0.17626
E_6	0.05	Completa	0,0,1,1,1	✗	0.17626
E_6	0.2	Completa	0,0,1,1,1	✗	0.17626
E_3	0.05	Heterogênea Itens	0,0,1,1,1	✗	0.17622
E_3	0.2	Heterogênea Itens	0,0,1,1,1	✗	0.17622
E_6	0.05	Completa	0,0,1,5,10	✗	0.17618
E_6	0.2	Completa	0,0,1,5,10	✗	0.17618
E_2	0.05	Completa	0,0,1,5,10	✗	0.17616
E_2	0.2	Completa	0,0,1,5,10	✗	0.17616
E_7	0.05	N-Partida	1,2,3,4,5	✗	0.17616
E_7	0.2	N-Partida	1,2,3,4,5	✗	0.17616
E_2	0.05	Heterogênea Usuários	0,0,1,5,10	✗	0.17615
E_2	0.2	Heterogênea Usuários	0,0,1,5,10	✗	0.17615
E_3	0.05	Heterogênea Itens	1,2,3,4,5	✗	0.17613

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_3	0.2	Heterogênea Itens	1,2,3,4,5	✖	0.17613
E_8	0.05	Heterogênea Itens	1,2,3,4,5	✖	0.17600
E_8	0.1	Heterogênea Itens	1,2,3,4,5	✖	0.17600
E_8	0.2	Heterogênea Itens	1,2,3,4,5	✖	0.17600
E_5	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✖	0.17599
E_8	0.05	Completa	0,0,1,1,1	✖	0.17598
E_8	0.1	Completa	0,0,1,1,1	✖	0.17598
E_8	0.2	Completa	0,0,1,1,1	✖	0.17598
E_3	0.05	Completa	1,2,3,4,5	✖	0.17597
E_3	0.2	Completa	1,2,3,4,5	✖	0.17597
E_6	0.1	Heterogênea Itens	0,0,0,1,1	✖	0.17597
E_2	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✖	0.17593
E_6	0.05	Heterogênea Itens	0,0,0,1,1	✖	0.17585
E_6	0.2	Heterogênea Itens	0,0,0,1,1	✖	0.17585
E_4	0.05	N-Partida	1,2,3,4,5	✖	0.17577
E_4	0.2	N-Partida	1,2,3,4,5	✖	0.17577
E_4	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✖	0.17576
E_2	0.05	N-Partida	0,0,1,3,5	✖	0.17574
E_2	0.2	N-Partida	0,0,1,3,5	✖	0.17574
E_1	0.05	Completa	0,0,1,3,5	✖	0.17571
E_1	0.2	Completa	0,0,1,3,5	✖	0.17571
E_7	0.05	Heterogênea Usuários	1,2,3,4,5	✖	0.17571
E_7	0.2	Heterogênea Usuários	1,2,3,4,5	✖	0.17571
E_6	0.1	N-Partida	0,0,1,3,5	✖	0.17569
E_3	0.05	Completa	0,0,1,1,1	✖	0.17567
E_3	0.2	Completa	0,0,1,1,1	✖	0.17567
E_2	0.05	Heterogênea Usuários	0,0,1,3,5	✖	0.17559
E_2	0.2	Heterogênea Usuários	0,0,1,3,5	✖	0.17559

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17559
E_6	0.05	N-Partida	1,2,3,4,5	✗	0.17557
E_6	0.2	N-Partida	1,2,3,4,5	✗	0.17557
E_2	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.17554
E_8	0.05	Heterogênea Usuários	0,0,1,3,5	✗	0.17553
E_8	0.1	Heterogênea Usuários	0,0,1,3,5	✗	0.17553
E_8	0.2	Heterogênea Usuários	0,0,1,3,5	✗	0.17553
E_6	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17549
E_3	0.05	Heterogênea Itens	0,0,1,3,5	✗	0.17549
E_3	0.2	Heterogênea Itens	0,0,1,3,5	✗	0.17549
E_2	0.05	Completa	0,0,1,3,5	✗	0.17546
E_2	0.2	Completa	0,0,1,3,5	✗	0.17546
E_4	0.05	Heterogênea Usuários	1,2,3,4,5	✗	0.17543
E_4	0.2	Heterogênea Usuários	1,2,3,4,5	✗	0.17543
E_3	0.05	Completa	0,0,1,5,10	✗	0.17538
E_3	0.2	Completa	0,0,1,5,10	✗	0.17538
E_8	0.05	Heterogênea Usuários	0,0,1,5,10	✗	0.17537
E_8	0.1	Heterogênea Usuários	0,0,1,5,10	✗	0.17537
E_8	0.2	Heterogênea Usuários	0,0,1,5,10	✗	0.17537
E_6	0.05	N-Partida	0,0,1,5,10	✗	0.17534
E_6	0.2	N-Partida	0,0,1,5,10	✗	0.17534
E_3	0.05	Heterogênea Itens	0,0,1,5,10	✗	0.17533
E_3	0.2	Heterogênea Itens	0,0,1,5,10	✗	0.17533
E_3	0.05	Completa	0,0,1,3,5	✗	0.17530
E_3	0.2	Completa	0,0,1,3,5	✗	0.17530

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_4	0.05	Heterogênea Usuários	0,0,1,3,5	✖	0.17527
E_4	0.2	Heterogênea Usuários	0,0,1,3,5	✖	0.17527
E_7	0.1	Heterogênea Usuários	1,2,3,4,5	✖	0.17524
E_7	0.05	Heterogênea Usuários	0,0,1,3,5	✖	0.17522
E_7	0.2	Heterogênea Usuários	0,0,1,3,5	✖	0.17522
E_7	0.1	Enriquecimento Usuários Similares	0,0,1,5,10	✖	0.17520
E_8	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✖	0.17520
E_4	0.05	Heterogênea Usuários	0,0,1,5,10	✖	0.17519
E_4	0.2	Heterogênea Usuários	0,0,1,5,10	✖	0.17519
E_4	0.05	Completa	0,0,1,3,5	✖	0.17519
E_4	0.2	Completa	0,0,1,3,5	✖	0.17519
E_6	0.05	N-Partida	0,0,1,3,5	✖	0.17511
E_6	0.2	N-Partida	0,0,1,3,5	✖	0.17511
E_7	0.05	Completa	0,0,1,3,5	✖	0.17508
E_7	0.2	Completa	0,0,1,3,5	✖	0.17508
E_6	0.05	Heterogênea Usuários	0,0,1,3,5	✖	0.17507
E_6	0.2	Heterogênea Usuários	0,0,1,3,5	✖	0.17507
E_6	0.1	N-Partida	0,0,1,5,10	✖	0.17502
E_7	0.1	Enriquecimento Usuários Similares	0,0,1,3,5	✖	0.17501
E_6	0.05	N-Partida	0,0,1,1,1	✖	0.17499
E_6	0.2	N-Partida	0,0,1,1,1	✖	0.17499
E_3	0.05	Heterogênea Usuários	1,2,3,4,5	✖	0.17497

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_3	0.2	Heterogênea Usuários	1,2,3,4,5	✗	0.17497
E_3	0.05	N-Partida	1,2,3,4,5	✗	0.17495
E_3	0.2	N-Partida	1,2,3,4,5	✗	0.17495
E_6	0.1	N-Partida	0,0,1,1,1	✗	0.17494
E_5	0.05	Heterogênea Itens	0,0,1,5,10	✗	0.17488
E_5	0.2	Heterogênea Itens	0,0,1,5,10	✗	0.17488
E_7	0.1	Completa	0,0,1,3,5	✗	0.17481
E_6	0.05	Heterogênea Usuários	1,2,3,4,5	✗	0.17481
E_6	0.2	Heterogênea Usuários	1,2,3,4,5	✗	0.17481
E_1	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17473
E_5	0.05	Heterogênea Itens	0,0,1,3,5	✗	0.17468
E_5	0.2	Heterogênea Itens	0,0,1,3,5	✗	0.17468
E_4	0.05	Completa	1,2,3,4,5	✗	0.17465
E_4	0.2	Completa	1,2,3,4,5	✗	0.17465
E_7	0.05	N-Partida	0,0,1,5,10	✗	0.17464
E_7	0.2	N-Partida	0,0,1,5,10	✗	0.17464
E_4	0.05	N-Partida	0,0,1,3,5	✗	0.17461
E_4	0.2	N-Partida	0,0,1,3,5	✗	0.17461
E_7	0.05	Heterogênea Usuários	0,0,1,5,10	✗	0.17458
E_7	0.2	Heterogênea Usuários	0,0,1,5,10	✗	0.17458
E_1	0.05	Heterogênea Itens	1,2,3,4,5	✗	0.17457
E_1	0.2	Heterogênea Itens	1,2,3,4,5	✗	0.17457
E_7	0.1	Completa	0,0,1,5,10	✗	0.17455
E_6	0.1	N-Partida	1,2,3,4,5	✗	0.17450
E_5	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17447
E_8	0.05	Heterogênea Itens	0,0,1,5,10	✗	0.17446
E_8	0.1	Heterogênea Itens	0,0,1,5,10	✗	0.17446
E_8	0.2	Heterogênea Itens	0,0,1,5,10	✗	0.17446

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.05	Heterogênea Usuários	1,2,3,4,5	✖	0.17440
E_8	0.1	Heterogênea Usuários	1,2,3,4,5	✖	0.17440
E_8	0.2	Heterogênea Usuários	1,2,3,4,5	✖	0.17440
E_2	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✖	0.17437
E_4	0.05	Completa	0,0,1,1,1	✖	0.17433
E_4	0.2	Completa	0,0,1,1,1	✖	0.17433
E_2	0.05	Heterogênea Usuários	0,0,1,1,1	✖	0.17430
E_2	0.2	Heterogênea Usuários	0,0,1,1,1	✖	0.17430
E_1	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✖	0.17428
E_3	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✖	0.17427
E_3	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✖	0.17425
E_7	0.05	N-Partida	0,0,1,3,5	✖	0.17423
E_7	0.2	N-Partida	0,0,1,3,5	✖	0.17423
E_8	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✖	0.17422
E_3	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✖	0.17422
E_1	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✖	0.17420
E_8	0.05	N-Partida	0,0,0,1,1	✖	0.17416
E_8	0.1	N-Partida	0,0,0,1,1	✖	0.17416
E_8	0.2	N-Partida	0,0,0,1,1	✖	0.17416
E_6	0.1	Heterogênea Usuários	1,2,3,4,5	✖	0.17411
E_8	0.05	Completa	1,2,3,4,5	✖	0.17410
E_8	0.1	Completa	1,2,3,4,5	✖	0.17410
E_8	0.2	Completa	1,2,3,4,5	✖	0.17410

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.05	Completa	0,0,1,5,10	✗	0.17406
E_1	0.2	Completa	0,0,1,5,10	✗	0.17406
E_8	0.05	Heterogênea Itens	0,0,1,3,5	✗	0.17405
E_8	0.1	Heterogênea Itens	0,0,1,3,5	✗	0.17405
E_8	0.2	Heterogênea Itens	0,0,1,3,5	✗	0.17405
E_1	0.05	Heterogênea Itens	0,0,1,3,5	✗	0.17402
E_1	0.2	Heterogênea Itens	0,0,1,3,5	✗	0.17402
E_5	0.05	Heterogênea Usuários	1,2,3,4,5	✗	0.17397
E_5	0.2	Heterogênea Usuários	1,2,3,4,5	✗	0.17397
E_5	0.05	N-Partida	1,2,3,4,5	✗	0.17393
E_5	0.2	N-Partida	1,2,3,4,5	✗	0.17393
E_5	0.05	Heterogênea Itens	0,0,1,1,1	✗	0.17390
E_5	0.2	Heterogênea Itens	0,0,1,1,1	✗	0.17390
E_7	0.1	N-Partida	1,2,3,4,5	✗	0.17388
E_6	0.05	Heterogênea Usuários	0,0,1,5,10	✗	0.17387
E_6	0.2	Heterogênea Usuários	0,0,1,5,10	✗	0.17387
E_4	0.05	N-Partida	0,0,1,1,1	✗	0.17386
E_4	0.2	N-Partida	0,0,1,1,1	✗	0.17386
E_3	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17384
E_5	0.05	Heterogênea Itens	1,2,3,4,5	✓	0.17379
E_5	0.2	Heterogênea Itens	1,2,3,4,5	✓	0.17379
E_7	0.1	Heterogênea Itens	1,2,3,4,5	✗	0.17369
E_7	0.1	Heterogênea Itens	0,0,1,5,10	✗	0.17369
E_7	0.05	Completa	1,1,1,1,1	✗	0.17368
E_7	0.2	Completa	1,1,1,1,1	✗	0.17368
E_6	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✗	0.17364
E_2	0.05	Completa	1,2,3,4,5	✗	0.17363
E_2	0.2	Completa	1,2,3,4,5	✗	0.17363
E_7	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.17360

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_5	0.05	Heterogênea Usuários	0,0,1,3,5	✖	0.17352
E_5	0.2	Heterogênea Usuários	0,0,1,3,5	✖	0.17352
E_7	0.1	Enriquecimento Usuários Similares	0,0,1,1,1	✖	0.17349
E_2	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✖	0.17347
E_7	0.05	N-Partida	0,0,1,1,1	✖	0.17341
E_7	0.2	N-Partida	0,0,1,1,1	✖	0.17341
E_5	0.05	Completa	0,0,1,3,5	✖	0.17340
E_5	0.2	Completa	0,0,1,3,5	✖	0.17340
E_5	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✖	0.17340
E_5	0.05	N-Partida	0,0,1,1,1	✖	0.17337
E_5	0.2	N-Partida	0,0,1,1,1	✖	0.17337
E_5	0.05	Completa	0,0,1,5,10	✖	0.17328
E_5	0.2	Completa	0,0,1,5,10	✖	0.17328
E_6	0.05	Heterogênea Usuários	0,0,1,1,1	✖	0.17321
E_6	0.2	Heterogênea Usuários	0,0,1,1,1	✖	0.17321
E_7	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✖	0.17320
E_7	0.1	Completa	1,2,3,4,5	✖	0.17320
E_1	0.05	Completa	1,2,3,4,5	✖	0.17313
E_1	0.2	Completa	1,2,3,4,5	✖	0.17313
E_1	0.05	N-Partida	0,0,1,3,5	✖	0.17313
E_1	0.2	N-Partida	0,0,1,3,5	✖	0.17313
E_1	0.05	Heterogênea Usuários	1,2,3,4,5	✖	0.17306
E_1	0.2	Heterogênea Usuários	1,2,3,4,5	✖	0.17306
E_5	0.05	N-Partida	0,0,1,3,5	✖	0.17304
E_5	0.2	N-Partida	0,0,1,3,5	✖	0.17304
E_8	0.05	Completa	0,0,1,5,10	✖	0.17300

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.1	Completa	0,0,1,5,10	✗	0.17300
E_8	0.2	Completa	0,0,1,5,10	✗	0.17300
E_7	0.1	N-Partida	0,0,1,3,5	✗	0.17299
E_1	0.05	N-Partida	1,2,3,4,5	✗	0.17298
E_1	0.2	N-Partida	1,2,3,4,5	✗	0.17298
E_5	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.17293
E_1	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.17293
E_3	0.05	Heterogênea Usuários	0,0,1,3,5	✗	0.17291
E_3	0.2	Heterogênea Usuários	0,0,1,3,5	✗	0.17291
E_2	0.05	Heterogênea Itens	0,0,1,1,1	✗	0.17287
E_2	0.2	Heterogênea Itens	0,0,1,1,1	✗	0.17287
E_7	0.1	Heterogênea Itens	1,2,3,4,5	✓	0.17286
E_5	0.05	N-Partida	0,0,1,5,10	✗	0.17286
E_5	0.2	N-Partida	0,0,1,5,10	✗	0.17286
E_2	0.05	N-Partida	0,0,1,1,1	✗	0.17286
E_2	0.2	N-Partida	0,0,1,1,1	✗	0.17286
E_7	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17284
E_3	0.05	N-Partida	0,0,1,3,5	✗	0.17284
E_3	0.2	N-Partida	0,0,1,3,5	✗	0.17284
E_2	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.17282
E_7	0.1	Heterogênea Usuários	0,0,1,3,5	✗	0.17282
E_5	0.05	Heterogênea Usuários	0,0,1,5,10	✗	0.17281
E_5	0.2	Heterogênea Usuários	0,0,1,5,10	✗	0.17281
E_3	0.05	Heterogênea Usuários	0,0,1,5,10	✗	0.17280
E_3	0.2	Heterogênea Usuários	0,0,1,5,10	✗	0.17280

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.05	N-Partida	0,0,1,5,10	✗	0.17280
E_1	0.2	N-Partida	0,0,1,5,10	✗	0.17280
E_7	0.1	Heterogênea Itens	0,0,0,1,1	✗	0.17278
E_7	0.1	N-Partida	0,0,1,5,10	✗	0.17275
E_7	0.1	Heterogênea Itens	0,0,1,3,5	✗	0.17274
E_5	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17273
E_3	0.05	N-Partida	0,0,1,5,10	✗	0.17273
E_3	0.2	N-Partida	0,0,1,5,10	✗	0.17273
E_7	0.1	N-Partida	0,0,1,1,1	✗	0.17271
E_1	0.05	Heterogênea Itens	0,0,1,5,10	✗	0.17264
E_1	0.2	Heterogênea Itens	0,0,1,5,10	✗	0.17264
E_1	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17263
E_6	0.1	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.17262
E_4	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17258
E_4	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.17256
E_5	0.05	Heterogênea Itens	1,2,3,4,5	✗	0.17254
E_5	0.2	Heterogênea Itens	1,2,3,4,5	✗	0.17254
E_7	0.1	Completa	1,2,3,4,5	✓	0.17251
E_6	0.1	Heterogênea Usuários	0,0,1,1,1	✗	0.17249
E_1	0.05	Completa	1,2,3,4,5	✓	0.17247
E_1	0.2	Completa	1,2,3,4,5	✓	0.17247
E_7	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17244
E_7	0.1	Heterogênea Usuários	0,0,1,5,10	✗	0.17241
E_8	0.1	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.17238
E_3	0.05	Heterogênea Usuários	0,0,1,1,1	✗	0.17233

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_3	0.2	Heterogênea Usuários	0,0,1,1,1	✖	0.17233
E_8	0.05	Heterogênea Usuários	0,0,1,1,1	✖	0.17226
E_8	0.1	Heterogênea Usuários	0,0,1,1,1	✖	0.17226
E_8	0.2	Heterogênea Usuários	0,0,1,1,1	✖	0.17226
E_3	0.05	N-Partida	0,0,1,1,1	✖	0.17220
E_3	0.2	N-Partida	0,0,1,1,1	✖	0.17220
E_2	0.05	Heterogênea Itens	0,0,0,1,1	✖	0.17220
E_2	0.2	Heterogênea Itens	0,0,0,1,1	✖	0.17220
E_1	0.05	Heterogênea Usuários	0,0,1,3,5	✖	0.17205
E_1	0.2	Heterogênea Usuários	0,0,1,3,5	✖	0.17205
E_7	0.05	Completa	1,2,3,4,5	✖	0.17204
E_7	0.2	Completa	1,2,3,4,5	✖	0.17204
E_7	0.1	Heterogênea Usuários	0,0,1,1,1	✖	0.17200
E_2	0.05	Completa	0,0,1,1,1	✖	0.17191
E_2	0.2	Completa	0,0,1,1,1	✖	0.17191
E_8	0.1	Enriquecimento Usuários Similares	0,0,1,1,1	✖	0.17186
E_1	0.05	Heterogênea Usuários	0,0,1,5,10	✖	0.17184
E_1	0.2	Heterogênea Usuários	0,0,1,5,10	✖	0.17184
E_7	0.05	Completa	0,0,1,1,1	✖	0.17173
E_7	0.2	Completa	0,0,1,1,1	✖	0.17173
E_6	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✖	0.17159
E_4	0.05	Completa	0,0,0,1,1	✖	0.17159
E_4	0.2	Completa	0,0,0,1,1	✖	0.17159
E_8	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✖	0.17158

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_5	0.05	Completa	1,2,3,4,5	✓	0.17158
E_5	0.2	Completa	1,2,3,4,5	✓	0.17158
E_1	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17152
E_5	0.05	Heterogênea Usuários	0,0,1,1,1	✗	0.17151
E_5	0.2	Heterogênea Usuários	0,0,1,1,1	✗	0.17151
E_7	0.1	Completa	0,0,0,1,1	✗	0.17149
E_1	0.05	N-Partida	0,0,1,1,1	✗	0.17147
E_1	0.2	N-Partida	0,0,1,1,1	✗	0.17147
E_7	0.1	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.17143
E_7	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.17143
E_4	0.05	Heterogênea Itens	0,0,0,1,1	✗	0.17138
E_4	0.2	Heterogênea Itens	0,0,0,1,1	✗	0.17138
E_8	0.05	Completa	0,0,0,1,1	✗	0.17137
E_8	0.1	Completa	0,0,0,1,1	✗	0.17137
E_8	0.2	Completa	0,0,0,1,1	✗	0.17137
E_8	0.05	Completa	0,0,1,3,5	✗	0.17121
E_8	0.1	Completa	0,0,1,3,5	✗	0.17121
E_8	0.2	Completa	0,0,1,3,5	✗	0.17121
E_8	0.1	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17118
E_8	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17118
E_3	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17104
E_7	0.05	Heterogênea Itens	1,2,3,4,5	✓	0.17099
E_7	0.2	Heterogênea Itens	1,2,3,4,5	✓	0.17099
E_4	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.17098
E_8	0.1	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.17094
E_5	0.05	Completa	0,0,0,1,1	✗	0.17094

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_5	0.2	Completa	0,0,0,1,1	✗	0.17094
E_1	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17088
E_7	0.05	N-Partida	0,0,0,1,1	✗	0.17082
E_7	0.2	N-Partida	0,0,0,1,1	✗	0.17082
E_1	0.05	Completa	0,0,0,1,1	✗	0.17075
E_1	0.2	Completa	0,0,0,1,1	✗	0.17075
E_4	0.05	Heterogênea Usuários	0,0,1,1,1	✗	0.17064
E_4	0.2	Heterogênea Usuários	0,0,1,1,1	✗	0.17064
E_5	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17063
E_5	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.17062
E_6	0.05	Heterogênea Usuários	0,0,0,1,1	✗	0.17057
E_6	0.2	Heterogênea Usuários	0,0,0,1,1	✗	0.17057
E_6	0.05	Heterogênea Itens	1,2,3,4,5	✓	0.17054
E_6	0.2	Heterogênea Itens	1,2,3,4,5	✓	0.17054
E_7	0.05	Completa	0,0,0,1,1	✗	0.17053
E_7	0.2	Completa	0,0,0,1,1	✗	0.17053
E_5	0.05	Completa	1,2,3,4,5	✗	0.17051
E_5	0.2	Completa	1,2,3,4,5	✗	0.17051
E_6	0.05	Completa	0,0,0,1,1	✗	0.17045
E_6	0.2	Completa	0,0,0,1,1	✗	0.17045
E_4	0.05	Completa	1,2,3,4,5	✓	0.17040
E_4	0.2	Completa	1,2,3,4,5	✓	0.17040
E_4	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.17040
E_4	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17035
E_2	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.17033

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_2	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.17033
E_6	0.1	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.17031
E_7	0.1	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.17031
E_5	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.17028
E_6	0.1	N-Partida	0,0,0,1,1	✗	0.17026
E_8	0.05	Heterogênea Itens	0,0,0,1,1	✗	0.17025
E_8	0.1	Heterogênea Itens	0,0,0,1,1	✗	0.17025
E_8	0.2	Heterogênea Itens	0,0,0,1,1	✗	0.17025
E_6	0.1	Heterogênea Itens	1,2,3,4,5	✓	0.17023
E_7	0.05	Heterogênea Itens	0,0,0,1,1	✗	0.17018
E_7	0.2	Heterogênea Itens	0,0,0,1,1	✗	0.17018
E_6	0.05	N-Partida	0,0,0,1,1	✗	0.17008
E_6	0.2	N-Partida	0,0,0,1,1	✗	0.17008
E_2	0.05	Completa	0,0,0,1,1	✗	0.17004
E_2	0.2	Completa	0,0,0,1,1	✗	0.17004
E_1	0.05	Heterogênea Itens	1,2,3,4,5	✓	0.17004
E_1	0.2	Heterogênea Itens	1,2,3,4,5	✓	0.17004
E_7	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.17002
E_5	0.05	Heterogênea Itens	0,0,1,3,5	✓	0.17001
E_5	0.2	Heterogênea Itens	0,0,1,3,5	✓	0.17001
E_8	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.16996
E_7	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.16996
E_6	0.1	Completa	1,0,0,0,1	✗	0.16993
E_5	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.16991
E_8	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.16984
E_5	0.05	Completa	0,0,1,3,5	✓	0.16970
E_5	0.2	Completa	0,0,1,3,5	✓	0.16970

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_6	0.05	Completa	1,2,3,4,5	✓	0.16966
E_6	0.2	Completa	1,2,3,4,5	✓	0.16966
E_4	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.16952
E_1	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.16947
E_4	0.05	Heterogênea Itens	1,2,3,4,5	✓	0.16945
E_4	0.2	Heterogênea Itens	1,2,3,4,5	✓	0.16945
E_8	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.16944
E_2	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.16944
E_8	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16927
E_7	0.05	Heterogênea Usuários	0,0,1,1,1	✗	0.16926
E_7	0.2	Heterogênea Usuários	0,0,1,1,1	✗	0.16926
E_7	0.1	N-Partida	0,0,0,1,1	✗	0.16918
E_8	0.05	Heterogênea Usuários	0,0,0,1,1	✗	0.16917
E_8	0.1	Heterogênea Usuários	0,0,0,1,1	✗	0.16917
E_8	0.2	Heterogênea Usuários	0,0,0,1,1	✗	0.16917
E_6	0.1	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.16905
E_8	0.05	Heterogênea Itens	1,2,3,4,5	✓	0.16898
E_8	0.1	Heterogênea Itens	1,2,3,4,5	✓	0.16898
E_8	0.2	Heterogênea Itens	1,2,3,4,5	✓	0.16898
E_3	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.16898
E_4	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.16884
E_7	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.16881

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_5	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16877
E_5	0.05	Heterogênea Usuários	0,0,0,1,1	✗	0.16877
E_5	0.2	Heterogênea Usuários	0,0,0,1,1	✗	0.16877
E_1	0.05	Heterogênea Usuários	0,0,1,1,1	✗	0.16866
E_1	0.2	Heterogênea Usuários	0,0,1,1,1	✗	0.16866
E_7	0.05	N-Partida	1,0,0,0,1	✗	0.16866
E_7	0.2	N-Partida	1,0,0,0,1	✗	0.16866
E_6	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✗	0.16862
E_6	0.05	Heterogênea Itens	1,0,0,0,1	✗	0.16859
E_6	0.2	Heterogênea Itens	1,0,0,0,1	✗	0.16859
E_3	0.05	Completa	1,2,3,4,5	✓	0.16853
E_3	0.2	Completa	1,2,3,4,5	✓	0.16853
E_2	0.05	N-Partida	1,0,0,0,1	✗	0.16851
E_2	0.2	N-Partida	1,0,0,0,1	✗	0.16851
E_4	0.05	N-Partida	0,0,0,1,1	✗	0.16850
E_4	0.2	N-Partida	0,0,0,1,1	✗	0.16850
E_7	0.1	Heterogênea Itens	0,0,1,3,5	✓	0.16844
E_8	0.05	Completa	1,2,3,4,5	✓	0.16843
E_8	0.1	Completa	1,2,3,4,5	✓	0.16843
E_8	0.2	Completa	1,2,3,4,5	✓	0.16843
E_2	0.05	Heterogênea Usuários	1,0,0,0,1	✗	0.16840
E_2	0.2	Heterogênea Usuários	1,0,0,0,1	✗	0.16840
E_4	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.16837
E_6	0.1	Completa	1,2,3,4,5	✓	0.16837
E_7	0.1	Completa	0,0,1,3,5	✓	0.16828
E_1	0.05	Heterogênea Itens	0,0,0,1,1	✗	0.16822
E_1	0.2	Heterogênea Itens	0,0,0,1,1	✗	0.16822

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_4	0.05	Heterogênea Usuários	0,0,0,1,1	✗	0.16820
E_4	0.2	Heterogênea Usuários	0,0,0,1,1	✗	0.16820
E_3	0.05	Heterogênea Itens	1,2,3,4,5	✓	0.16815
E_3	0.2	Heterogênea Itens	1,2,3,4,5	✓	0.16815
E_2	0.05	Heterogênea Usuários	0,0,0,1,1	✗	0.16812
E_2	0.2	Heterogênea Usuários	0,0,0,1,1	✗	0.16812
E_7	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16811
E_2	0.05	N-Partida	0,0,0,1,1	✗	0.16809
E_2	0.2	N-Partida	0,0,0,1,1	✗	0.16809
E_4	0.05	Heterogênea Itens	1,0,0,0,1	✗	0.16796
E_4	0.2	Heterogênea Itens	1,0,0,0,1	✗	0.16796
E_3	0.05	Completa	0,0,0,1,1	✗	0.16785
E_3	0.2	Completa	0,0,0,1,1	✗	0.16785
E_4	0.05	N-Partida	1,0,0,0,1	✗	0.16783
E_4	0.2	N-Partida	1,0,0,0,1	✗	0.16783
E_5	0.05	N-Partida	0,0,0,1,1	✗	0.16782
E_5	0.2	N-Partida	0,0,0,1,1	✗	0.16782
E_1	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16778
E_3	0.05	Heterogênea Usuários	0,0,0,1,1	✗	0.16768
E_3	0.2	Heterogênea Usuários	0,0,0,1,1	✗	0.16768
E_3	0.05	N-Partida	0,0,0,1,1	✗	0.16763
E_3	0.2	N-Partida	0,0,0,1,1	✗	0.16763
E_7	0.1	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16756
E_7	0.05	Heterogênea Usuários	0,0,0,1,1	✗	0.16754
E_7	0.2	Heterogênea Usuários	0,0,0,1,1	✗	0.16754

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.16737
E_8	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16731
E_7	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16729
E_1	0.05	Completa	0,0,1,3,5	✓	0.16721
E_1	0.2	Completa	0,0,1,3,5	✓	0.16721
E_5	0.05	Heterogênea Itens	0,0,0,1,1	✗	0.16714
E_5	0.2	Heterogênea Itens	0,0,0,1,1	✗	0.16714
E_6	0.1	Heterogênea Usuários	0,0,0,1,1	✗	0.16708
E_6	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✗	0.16704
E_7	0.1	Heterogênea Usuários	0,0,0,1,1	✗	0.16696
E_6	0.05	N-Partida	1,0,0,0,1	✗	0.16695
E_6	0.2	N-Partida	1,0,0,0,1	✗	0.16695
E_3	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.16694
E_4	0.05	Completa	0,0,1,3,5	✓	0.16690
E_4	0.2	Completa	0,0,1,3,5	✓	0.16690
E_8	0.1	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16688
E_7	0.05	Heterogênea Usuários	1,0,0,0,1	✗	0.16670
E_7	0.2	Heterogênea Usuários	1,0,0,0,1	✗	0.16670
E_7	0.05	Heterogênea Itens	0,0,1,3,5	✓	0.16653
E_7	0.2	Heterogênea Itens	0,0,1,3,5	✓	0.16653
E_3	0.05	Heterogênea Itens	0,0,0,1,1	✗	0.16650
E_3	0.2	Heterogênea Itens	0,0,0,1,1	✗	0.16650
E_6	0.1	Heterogênea Usuários	1,0,0,0,1	✗	0.16649
E_6	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.16648

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.05	Heterogênea Itens	0,0,1,3,5	✓	0.16646
E_1	0.2	Heterogênea Itens	0,0,1,3,5	✓	0.16646
E_5	0.05	Heterogênea Itens	0,0,1,5,10	✓	0.16643
E_5	0.2	Heterogênea Itens	0,0,1,5,10	✓	0.16643
E_4	0.05	Heterogênea Usuários	1,0,0,0,1	✗	0.16626
E_4	0.2	Heterogênea Usuários	1,0,0,0,1	✗	0.16626
E_2	0.05	Heterogênea Itens	1,0,0,0,1	✗	0.16625
E_2	0.2	Heterogênea Itens	1,0,0,0,1	✗	0.16625
E_6	0.1	N-Partida	1,0,0,0,1	✗	0.16608
E_6	0.05	Heterogênea Usuários	1,0,0,0,1	✗	0.16598
E_6	0.2	Heterogênea Usuários	1,0,0,0,1	✗	0.16598
E_2	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.16597
E_7	0.1	Heterogênea Itens	0,0,1,5,10	✓	0.16596
E_5	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.16592
E_3	0.05	Completa	0,0,1,3,5	✓	0.16589
E_3	0.2	Completa	0,0,1,3,5	✓	0.16589
E_8	0.05	Heterogênea Usuários	1,0,0,0,1	✗	0.16588
E_8	0.1	Heterogênea Usuários	1,0,0,0,1	✗	0.16588
E_8	0.2	Heterogênea Usuários	1,0,0,0,1	✗	0.16588
E_6	0.05	Completa	1,0,0,0,1	✗	0.16581
E_6	0.2	Completa	1,0,0,0,1	✗	0.16581
E_3	0.05	Heterogênea Itens	0,0,1,3,5	✓	0.16569
E_3	0.2	Heterogênea Itens	0,0,1,3,5	✓	0.16569
E_4	0.05	Heterogênea Itens	0,0,1,3,5	✓	0.16568
E_4	0.2	Heterogênea Itens	0,0,1,3,5	✓	0.16568
E_6	0.05	Completa	0,0,1,3,5	✓	0.16559
E_6	0.2	Completa	0,0,1,3,5	✓	0.16559

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_7	0.05	Heterogênea Itens	1,0,0,0,1	✗	0.16558
E_7	0.2	Heterogênea Itens	1,0,0,0,1	✗	0.16558
E_7	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.16548
E_6	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.16546
E_5	0.05	Completa	0,0,1,5,10	✓	0.16545
E_5	0.2	Completa	0,0,1,5,10	✓	0.16545
E_6	0.1	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.16539
E_3	0.05	N-Partida	1,2,3,4,5	✓	0.16531
E_3	0.2	N-Partida	1,2,3,4,5	✓	0.16531
E_8	0.05	Completa	0,0,1,3,5	✓	0.16530
E_8	0.1	Completa	0,0,1,3,5	✓	0.16530
E_8	0.2	Completa	0,0,1,3,5	✓	0.16530
E_8	0.05	N-Partida	1,0,0,0,1	✗	0.16529
E_8	0.1	N-Partida	1,0,0,0,1	✗	0.16529
E_8	0.2	N-Partida	1,0,0,0,1	✗	0.16529
E_2	0.05	Completa	1,0,0,0,1	✗	0.16528
E_2	0.2	Completa	1,0,0,0,1	✗	0.16528
E_3	0.05	Heterogênea Usuários	1,2,3,4,5	✓	0.16519
E_3	0.2	Heterogênea Usuários	1,2,3,4,5	✓	0.16519
E_7	0.1	Completa	0,0,1,5,10	✓	0.16516
E_7	0.1	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.16504
E_6	0.1	Heterogênea Itens	0,0,1,3,5	✓	0.16496
E_7	0.05	Completa	1,2,3,4,5	✓	0.16487
E_7	0.2	Completa	1,2,3,4,5	✓	0.16487
E_1	0.05	N-Partida	0,0,0,1,1	✗	0.16481
E_1	0.2	N-Partida	0,0,0,1,1	✗	0.16481
E_2	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16481
E_7	0.05	Heterogênea Itens	0,0,1,5,10	✓	0.16470
E_7	0.2	Heterogênea Itens	0,0,1,5,10	✓	0.16470

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_6	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16463
E_6	0.1	Heterogênea Itens	1,0,0,0,1	✗	0.16446
E_4	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16443
E_1	0.05	Completa	0,0,1,5,10	✓	0.16437
E_1	0.2	Completa	0,0,1,5,10	✓	0.16437
E_6	0.05	Heterogênea Itens	0,0,1,3,5	✓	0.16427
E_6	0.2	Heterogênea Itens	0,0,1,3,5	✓	0.16427
E_3	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16419
E_4	0.05	Completa	1,0,0,0,1	✗	0.16408
E_4	0.2	Completa	1,0,0,0,1	✗	0.16408
E_5	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16406
E_7	0.1	Heterogênea Itens	1,0,0,0,1	✗	0.16404
E_6	0.1	Completa	0,0,1,3,5	✓	0.16393
E_2	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.16383
E_1	0.05	Heterogênea Usuários	0,0,0,1,1	✗	0.16382
E_1	0.2	Heterogênea Usuários	0,0,0,1,1	✗	0.16382
E_2	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16375
E_2	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.16374
E_3	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16361
E_6	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✗	0.16343
E_2	0.05	Completa	1,2,3,4,5	✓	0.16335
E_2	0.2	Completa	1,2,3,4,5	✓	0.16335
E_8	0.05	Heterogênea Itens	0,0,1,3,5	✓	0.16324
E_8	0.1	Heterogênea Itens	0,0,1,3,5	✓	0.16324
E_8	0.2	Heterogênea Itens	0,0,1,3,5	✓	0.16324

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_4	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16314
E_7	0.1	Completa	1,0,0,0,1	✗	0.16307
E_7	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.16299
E_6	0.05	Completa	0,0,1,5,10	✓	0.16299
E_6	0.2	Completa	0,0,1,5,10	✓	0.16299
E_4	0.05	Heterogênea Itens	0,0,1,5,10	✓	0.16292
E_4	0.2	Heterogênea Itens	0,0,1,5,10	✓	0.16292
E_6	0.05	Heterogênea Itens	0,0,1,5,10	✓	0.16289
E_6	0.2	Heterogênea Itens	0,0,1,5,10	✓	0.16289
E_7	0.1	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.16287
E_1	0.05	Heterogênea Usuários	1,0,0,0,1	✗	0.16285
E_1	0.2	Heterogênea Usuários	1,0,0,0,1	✗	0.16285
E_5	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.16275
E_3	0.05	Heterogênea Usuários	0,0,1,3,5	✓	0.16272
E_3	0.2	Heterogênea Usuários	0,0,1,3,5	✓	0.16272
E_7	0.05	Completa	0,0,1,3,5	✓	0.16270
E_7	0.2	Completa	0,0,1,3,5	✓	0.16270
E_3	0.05	N-Partida	0,0,1,3,5	✓	0.16269
E_3	0.2	N-Partida	0,0,1,3,5	✓	0.16269
E_4	0.05	Completa	0,0,1,5,10	✓	0.16261
E_4	0.2	Completa	0,0,1,5,10	✓	0.16261
E_6	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.16258
E_2	0.05	Heterogênea Itens	1,2,3,4,5	✓	0.16228
E_2	0.2	Heterogênea Itens	1,2,3,4,5	✓	0.16228
E_3	0.05	Completa	0,0,1,5,10	✓	0.16214
E_3	0.2	Completa	0,0,1,5,10	✓	0.16214

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_7	0.1	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.16208
E_8	0.05	Completa	1,0,0,0,1	✗	0.16190
E_8	0.1	Completa	1,0,0,0,1	✗	0.16190
E_8	0.2	Completa	1,0,0,0,1	✗	0.16190
E_5	0.05	N-Partida	1,2,3,4,5	✓	0.16181
E_5	0.2	N-Partida	1,2,3,4,5	✓	0.16181
E_1	0.05	N-Partida	1,2,3,4,5	✓	0.16176
E_1	0.2	N-Partida	1,2,3,4,5	✓	0.16176
E_3	0.05	Heterogênea Itens	0,0,1,5,10	✓	0.16171
E_3	0.2	Heterogênea Itens	0,0,1,5,10	✓	0.16171
E_8	0.05	Heterogênea Itens	0,0,0,1,1	✓	0.16170
E_8	0.1	Heterogênea Itens	0,0,0,1,1	✓	0.16170
E_8	0.2	Heterogênea Itens	0,0,0,1,1	✓	0.16170
E_7	0.1	N-Partida	1,2,3,4,5	✓	0.16160
E_1	0.05	Heterogênea Itens	0,0,1,5,10	✓	0.16128
E_1	0.2	Heterogênea Itens	0,0,1,5,10	✓	0.16128
E_7	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.16120
E_1	0.05	Heterogênea Usuários	1,2,3,4,5	✓	0.16105
E_1	0.2	Heterogênea Usuários	1,2,3,4,5	✓	0.16105
E_6	0.1	Completa	0,0,1,5,10	✓	0.16100
E_8	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.16083
E_3	0.05	Heterogênea Usuários	1,0,0,0,1	✗	0.16076
E_3	0.2	Heterogênea Usuários	1,0,0,0,1	✗	0.16076
E_3	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.16072
E_3	0.05	N-Partida	1,0,0,0,1	✗	0.16068
E_3	0.2	N-Partida	1,0,0,0,1	✗	0.16068
E_7	0.1	Heterogênea Usuários	1,2,3,4,5	✓	0.16068

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.16047
E_7	0.05	Completa	1,0,0,0,1	✗	0.16046
E_7	0.2	Completa	1,0,0,0,1	✗	0.16046
E_8	0.1	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.16045
E_5	0.05	Heterogênea Usuários	1,2,3,4,5	✓	0.16040
E_5	0.2	Heterogênea Usuários	1,2,3,4,5	✓	0.16040
E_8	0.05	Heterogênea Itens	0,0,1,5,10	✓	0.16036
E_8	0.1	Heterogênea Itens	0,0,1,5,10	✓	0.16036
E_8	0.2	Heterogênea Itens	0,0,1,5,10	✓	0.16036
E_6	0.1	Heterogênea Itens	0,0,0,1,1	✓	0.16028
E_8	0.05	N-Partida	1,2,3,4,5	✓	0.16021
E_8	0.1	N-Partida	1,2,3,4,5	✓	0.16021
E_8	0.2	N-Partida	1,2,3,4,5	✓	0.16021
E_5	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.16017
E_7	0.05	Heterogênea Usuários	1,2,3,4,5	✓	0.16014
E_7	0.2	Heterogênea Usuários	1,2,3,4,5	✓	0.16014
E_5	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.16010
E_4	0.05	N-Partida	1,2,3,4,5	✓	0.16007
E_4	0.2	N-Partida	1,2,3,4,5	✓	0.16007
E_8	0.05	Completa	0,0,1,5,10	✓	0.16006
E_8	0.1	Completa	0,0,1,5,10	✓	0.16006
E_8	0.2	Completa	0,0,1,5,10	✓	0.16006
E_5	0.05	Heterogênea Itens	1,0,0,0,1	✗	0.16004
E_5	0.2	Heterogênea Itens	1,0,0,0,1	✗	0.16004
E_7	0.05	N-Partida	1,2,3,4,5	✓	0.15999
E_7	0.2	N-Partida	1,2,3,4,5	✓	0.15999
E_6	0.05	N-Partida	1,2,3,4,5	✓	0.15998
E_6	0.2	N-Partida	1,2,3,4,5	✓	0.15998

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✗	0.15996
E_5	0.05	Completa	1,0,0,0,1	✗	0.15994
E_5	0.2	Completa	1,0,0,0,1	✗	0.15994
E_5	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15992
E_1	0.05	Completa	0,0,0,1,1	✓	0.15985
E_1	0.2	Completa	0,0,0,1,1	✓	0.15985
E_4	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15985
E_6	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15985
E_6	0.1	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15984
E_1	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.15981
E_7	0.1	N-Partida	1,0,0,0,1	✗	0.15958
E_5	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.15956
E_1	0.05	N-Partida	0,0,1,3,5	✓	0.15950
E_1	0.2	N-Partida	0,0,1,3,5	✓	0.15950
E_6	0.1	Heterogênea Itens	0,0,1,5,10	✓	0.15936
E_3	0.05	Completa	1,0,0,0,1	✗	0.15932
E_3	0.2	Completa	1,0,0,0,1	✗	0.15932
E_8	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15932
E_7	0.05	Completa	0,0,1,5,10	✓	0.15931
E_7	0.2	Completa	0,0,1,5,10	✓	0.15931
E_3	0.05	Heterogênea Usuários	0,0,1,5,10	✓	0.15928
E_3	0.2	Heterogênea Usuários	0,0,1,5,10	✓	0.15928
E_3	0.05	N-Partida	0,0,1,5,10	✓	0.15925
E_3	0.2	N-Partida	0,0,1,5,10	✓	0.15925
E_1	0.05	Heterogênea Usuários	0,0,1,3,5	✓	0.15923

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.2	Heterogênea Usuários	0,0,1,3,5	✓	0.15923
E_1	0.05	N-Partida	1,0,0,0,1	✗	0.15922
E_1	0.2	N-Partida	1,0,0,0,1	✗	0.15922
E_5	0.05	N-Partida	1,0,0,0,1	✗	0.15921
E_5	0.2	N-Partida	1,0,0,0,1	✗	0.15921
E_2	0.05	Heterogênea Usuários	1,2,3,4,5	✓	0.15918
E_2	0.2	Heterogênea Usuários	1,2,3,4,5	✓	0.15918
E_4	0.05	Heterogênea Usuários	1,2,3,4,5	✓	0.15916
E_4	0.2	Heterogênea Usuários	1,2,3,4,5	✓	0.15916
E_1	0.05	Completa	1,0,0,0,1	✗	0.15909
E_1	0.2	Completa	1,0,0,0,1	✗	0.15909
E_6	0.1	Heterogênea Usuários	1,2,3,4,5	✓	0.15896
E_7	0.1	N-Partida	0,0,1,3,5	✓	0.15894
E_3	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15893
E_5	0.05	N-Partida	0,0,1,3,5	✓	0.15890
E_5	0.2	N-Partida	0,0,1,3,5	✓	0.15890
E_8	0.05	Heterogênea Usuários	1,2,3,4,5	✓	0.15887
E_8	0.1	Heterogênea Usuários	1,2,3,4,5	✓	0.15887
E_8	0.2	Heterogênea Usuários	1,2,3,4,5	✓	0.15887
E_8	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15886
E_6	0.05	Heterogênea Usuários	1,2,3,4,5	✓	0.15880
E_6	0.2	Heterogênea Usuários	1,2,3,4,5	✓	0.15880
E_1	0.05	Heterogênea Itens	1,0,0,0,1	✗	0.15877

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.2	Heterogênea Itens	1,0,0,0,1	✗	0.15877
E_1	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15875
E_3	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15872
E_8	0.05	Completa	0,0,0,1,1	✓	0.15865
E_8	0.1	Completa	0,0,0,1,1	✓	0.15865
E_8	0.2	Completa	0,0,0,1,1	✓	0.15865
E_5	0.05	Heterogênea Usuários	1,0,0,0,1	✗	0.15861
E_5	0.2	Heterogênea Usuários	1,0,0,0,1	✗	0.15861
E_6	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✗	0.15846
E_2	0.05	Completa	0,0,1,3,5	✓	0.15844
E_2	0.2	Completa	0,0,1,3,5	✓	0.15844
E_5	0.05	Heterogênea Itens	0,0,0,1,1	✓	0.15838
E_5	0.2	Heterogênea Itens	0,0,0,1,1	✓	0.15838
E_7	0.1	Heterogênea Usuários	1,0,0,0,1	✗	0.15834
E_4	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15820
E_8	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15819
E_7	0.1	Heterogênea Usuários	0,0,1,3,5	✓	0.15817
E_5	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15806
E_7	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.15801
E_6	0.1	N-Partida	1,2,3,4,5	✓	0.15799
E_5	0.05	Heterogênea Usuários	0,0,1,3,5	✓	0.15786
E_5	0.2	Heterogênea Usuários	0,0,1,3,5	✓	0.15786
E_8	0.05	N-Partida	0,0,1,3,5	✓	0.15771

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.1	N-Partida	0,0,1,3,5	✓	0.15771
E_8	0.2	N-Partida	0,0,1,3,5	✓	0.15771
E_3	0.05	Heterogênea Itens	1,0,0,0,1	✗	0.15770
E_3	0.2	Heterogênea Itens	1,0,0,0,1	✗	0.15770
E_1	0.05	N-Partida	0,0,1,5,10	✓	0.15752
E_1	0.2	N-Partida	0,0,1,5,10	✓	0.15752
E_6	0.05	N-Partida	0,0,1,3,5	✓	0.15736
E_6	0.2	N-Partida	0,0,1,3,5	✓	0.15736
E_1	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15733
E_3	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.15727
E_1	0.05	Heterogênea Itens	0,0,0,1,1	✓	0.15719
E_1	0.2	Heterogênea Itens	0,0,0,1,1	✓	0.15719
E_7	0.1	Heterogênea Itens	0,0,0,1,1	✓	0.15717
E_5	0.05	Completa	0,0,0,1,1	✓	0.15699
E_5	0.2	Completa	0,0,0,1,1	✓	0.15699
E_3	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.15697
E_7	0.05	Heterogênea Usuários	0,0,1,3,5	✓	0.15695
E_7	0.2	Heterogênea Usuários	0,0,1,3,5	✓	0.15695
E_8	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15692
E_4	0.05	N-Partida	0,0,1,3,5	✓	0.15690
E_4	0.2	N-Partida	0,0,1,3,5	✓	0.15690
E_2	0.05	N-Partida	1,2,3,4,5	✓	0.15680
E_2	0.2	N-Partida	1,2,3,4,5	✓	0.15680
E_1	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15673
E_5	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.15672
E_1	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15667

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.05	Heterogênea Usuários	0,0,1,3,5	✓	0.15663
E_8	0.1	Heterogênea Usuários	0,0,1,3,5	✓	0.15663
E_8	0.2	Heterogênea Usuários	0,0,1,3,5	✓	0.15663
E_8	0.05	N-Partida	0,0,1,5,10	✓	0.15658
E_8	0.1	N-Partida	0,0,1,5,10	✓	0.15658
E_8	0.2	N-Partida	0,0,1,5,10	✓	0.15658
E_1	0.05	Heterogênea Usuários	0,0,1,5,10	✓	0.15657
E_1	0.2	Heterogênea Usuários	0,0,1,5,10	✓	0.15657
E_5	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15656
E_8	0.1	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15653
E_2	0.05	Heterogênea Itens	0,0,1,3,5	✓	0.15644
E_2	0.2	Heterogênea Itens	0,0,1,3,5	✓	0.15644
E_6	0.05	Heterogênea Itens	0,0,0,1,1	✓	0.15635
E_6	0.2	Heterogênea Itens	0,0,0,1,1	✓	0.15635
E_4	0.05	Heterogênea Usuários	0,0,1,3,5	✓	0.15600
E_4	0.2	Heterogênea Usuários	0,0,1,3,5	✓	0.15600
E_8	0.1	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15596
E_7	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.15594
E_6	0.1	Completa	0,0,0,1,1	✓	0.15589
E_2	0.05	Completa	0,0,1,5,10	✓	0.15583
E_2	0.2	Completa	0,0,1,5,10	✓	0.15583
E_5	0.05	N-Partida	0,0,1,5,10	✓	0.15572
E_5	0.2	N-Partida	0,0,1,5,10	✓	0.15572
E_2	0.05	N-Partida	0,0,1,3,5	✓	0.15556
E_2	0.2	N-Partida	0,0,1,3,5	✓	0.15556

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_6	0.1	N-Partida	0,0,1,3,5	✓	0.15554
E_6	0.05	Heterogênea Usuários	0,0,1,3,5	✓	0.15538
E_6	0.2	Heterogênea Usuários	0,0,1,3,5	✓	0.15538
E_7	0.1	Completa	0,0,0,1,1	✓	0.15538
E_6	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✗	0.15537
E_1	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.15514
E_7	0.1	N-Partida	0,0,1,5,10	✓	0.15507
E_7	0.1	Heterogênea Usuários	0,0,1,5,10	✓	0.15506
E_6	0.1	N-Partida	0,0,1,5,10	✓	0.15497
E_5	0.05	Heterogênea Usuários	0,0,1,5,10	✓	0.15494
E_5	0.2	Heterogênea Usuários	0,0,1,5,10	✓	0.15494
E_3	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.15491
E_7	0.05	N-Partida	0,0,1,3,5	✓	0.15484
E_7	0.2	N-Partida	0,0,1,3,5	✓	0.15484
E_2	0.05	N-Partida	0,0,1,5,10	✓	0.15455
E_2	0.2	N-Partida	0,0,1,5,10	✓	0.15455
E_7	0.05	Heterogênea Usuários	0,0,1,5,10	✓	0.15442
E_7	0.2	Heterogênea Usuários	0,0,1,5,10	✓	0.15442
E_8	0.05	Heterogênea Itens	1,0,0,0,1	✗	0.15404
E_8	0.1	Heterogênea Itens	1,0,0,0,1	✗	0.15404
E_8	0.2	Heterogênea Itens	1,0,0,0,1	✗	0.15404
E_6	0.1	Heterogênea Usuários	0,0,1,3,5	✓	0.15397
E_7	0.1	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15392

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.15391
E_8	0.05	Heterogênea Usuários	0,0,1,5,10	✓	0.15382
E_8	0.1	Heterogênea Usuários	0,0,1,5,10	✓	0.15382
E_8	0.2	Heterogênea Usuários	0,0,1,5,10	✓	0.15382
E_8	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.15365
E_8	0.05	Heterogênea Itens	1,0,0,0,1	✓	0.15354
E_8	0.1	Heterogênea Itens	1,0,0,0,1	✓	0.15354
E_8	0.2	Heterogênea Itens	1,0,0,0,1	✓	0.15354
E_2	0.05	Heterogênea Itens	0,0,1,5,10	✓	0.15346
E_2	0.2	Heterogênea Itens	0,0,1,5,10	✓	0.15346
E_2	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.15341
E_4	0.05	N-Partida	0,0,1,5,10	✓	0.15329
E_4	0.2	N-Partida	0,0,1,5,10	✓	0.15329
E_2	0.05	Heterogênea Usuários	0,0,1,3,5	✓	0.15309
E_2	0.2	Heterogênea Usuários	0,0,1,3,5	✓	0.15309
E_7	0.05	Heterogênea Itens	0,0,0,1,1	✓	0.15306
E_7	0.2	Heterogênea Itens	0,0,0,1,1	✓	0.15306
E_6	0.05	N-Partida	0,0,1,5,10	✓	0.15304
E_6	0.2	N-Partida	0,0,1,5,10	✓	0.15304
E_4	0.05	Heterogênea Usuários	0,0,1,5,10	✓	0.15301
E_4	0.2	Heterogênea Usuários	0,0,1,5,10	✓	0.15301
E_4	0.05	Heterogênea Itens	0,0,0,1,1	✓	0.15298
E_4	0.2	Heterogênea Itens	0,0,0,1,1	✓	0.15298
E_7	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.15277

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.15255
E_6	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15249
E_6	0.05	Heterogênea Usuários	0,0,1,5,10	✓	0.15245
E_6	0.2	Heterogênea Usuários	0,0,1,5,10	✓	0.15245
E_7	0.05	N-Partida	0,0,1,5,10	✓	0.15234
E_7	0.2	N-Partida	0,0,1,5,10	✓	0.15234
E_8	0.05	Heterogênea Itens	0,0,1,1,1	✓	0.15223
E_8	0.1	Heterogênea Itens	0,0,1,1,1	✓	0.15223
E_8	0.2	Heterogênea Itens	0,0,1,1,1	✓	0.15223
E_2	0.05	Heterogênea Usuários	0,0,1,5,10	✓	0.15204
E_2	0.2	Heterogênea Usuários	0,0,1,5,10	✓	0.15204
E_6	0.05	Completa	0,0,0,1,1	✓	0.15200
E_6	0.2	Completa	0,0,0,1,1	✓	0.15200
E_8	0.05	Completa	1,0,0,0,1	✓	0.15176
E_8	0.1	Completa	1,0,0,0,1	✓	0.15176
E_8	0.2	Completa	1,0,0,0,1	✓	0.15176
E_6	0.1	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15171
E_8	0.1	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.15166
E_6	0.1	Heterogênea Usuários	0,0,1,5,10	✓	0.15062
E_4	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.15058
E_8	0.1	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.15049
E_4	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15049
E_8	0.05	Completa	0,0,1,1,1	✓	0.15024
E_8	0.1	Completa	0,0,1,1,1	✓	0.15024

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.2	Completa	0,0,1,1,1	✓	0.15024
E_6	0.1	N-Partida	0,0,1,1,1	✓	0.15016
E_4	0.05	Completa	0,0,0,1,1	✓	0.15010
E_4	0.2	Completa	0,0,0,1,1	✓	0.15010
E_6	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.15007
E_6	0.1	Completa	0,0,1,1,1	✓	0.14990
E_8	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14987
E_6	0.1	Heterogênea Itens	0,0,1,1,1	✓	0.14961
E_3	0.05	Heterogênea Itens	0,0,0,1,1	✓	0.14944
E_3	0.2	Heterogênea Itens	0,0,0,1,1	✓	0.14944
E_8	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.14931
E_6	0.05	Heterogênea Usuários	0,0,1,1,1	✓	0.14918
E_6	0.2	Heterogênea Usuários	0,0,1,1,1	✓	0.14918
E_3	0.05	Completa	0,0,0,1,1	✓	0.14916
E_3	0.2	Completa	0,0,0,1,1	✓	0.14916
E_8	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14914
E_8	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14897
E_6	0.05	Heterogênea Itens	0,0,1,1,1	✓	0.14892
E_6	0.2	Heterogênea Itens	0,0,1,1,1	✓	0.14892
E_8	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14890
E_8	0.05	N-Partida	0,0,1,1,1	✓	0.14882
E_8	0.1	N-Partida	0,0,1,1,1	✓	0.14882
E_8	0.2	N-Partida	0,0,1,1,1	✓	0.14882
E_2	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.14877
E_7	0.05	Completa	0,0,0,1,1	✓	0.14863
E_7	0.2	Completa	0,0,0,1,1	✓	0.14863

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_5	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14810
E_1	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14798
E_3	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.14786
E_4	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.14781
E_6	0.1	Heterogênea Itens	1,0,0,0,1	✓	0.14757
E_7	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.14744
E_5	0.05	Heterogênea Itens	1,0,0,0,1	✓	0.14743
E_5	0.2	Heterogênea Itens	1,0,0,0,1	✓	0.14743
E_8	0.1	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14742
E_5	0.05	Completa	1,0,0,0,1	✓	0.14708
E_5	0.2	Completa	1,0,0,0,1	✓	0.14708
E_3	0.05	Completa	1,0,0,0,1	✓	0.14700
E_3	0.2	Completa	1,0,0,0,1	✓	0.14700
E_3	0.05	Heterogênea Itens	1,0,0,0,1	✓	0.14689
E_3	0.2	Heterogênea Itens	1,0,0,0,1	✓	0.14689
E_7	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.14687
E_5	0.05	N-Partida	0,0,1,1,1	✓	0.14673
E_5	0.2	N-Partida	0,0,1,1,1	✓	0.14673
E_3	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.14668
E_6	0.05	Completa	0,0,1,1,1	✓	0.14664
E_6	0.2	Completa	0,0,1,1,1	✓	0.14664
E_7	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.14658
E_2	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14654
E_3	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14627

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.05	Heterogênea Usuários	0,0,1,1,1	✓	0.14623
E_8	0.1	Heterogênea Usuários	0,0,1,1,1	✓	0.14623
E_8	0.2	Heterogênea Usuários	0,0,1,1,1	✓	0.14623
E_6	0.05	N-Partida	0,0,1,1,1	✓	0.14623
E_6	0.2	N-Partida	0,0,1,1,1	✓	0.14623
E_7	0.1	Completa	1,0,0,0,1	✓	0.14621
E_3	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.14603
E_4	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.14601
E_4	0.05	Heterogênea Itens	0,0,1,1,1	✓	0.14596
E_4	0.2	Heterogênea Itens	0,0,1,1,1	✓	0.14596
E_3	0.05	Heterogênea Usuários	0,0,1,1,1	✓	0.14582
E_3	0.2	Heterogênea Usuários	0,0,1,1,1	✓	0.14582
E_3	0.05	N-Partida	0,0,1,1,1	✓	0.14576
E_3	0.2	N-Partida	0,0,1,1,1	✓	0.14576
E_4	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14572
E_4	0.05	N-Partida	0,0,1,1,1	✓	0.14555
E_4	0.2	N-Partida	0,0,1,1,1	✓	0.14555
E_7	0.1	Heterogênea Itens	1,0,0,0,1	✓	0.14554
E_4	0.05	Completa	1,0,0,0,1	✓	0.14553
E_4	0.2	Completa	1,0,0,0,1	✓	0.14553
E_5	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14551
E_1	0.05	Heterogênea Itens	1,0,0,0,1	✓	0.14551
E_1	0.2	Heterogênea Itens	1,0,0,0,1	✓	0.14551
E_7	0.05	Heterogênea Itens	0,0,1,1,1	✓	0.14546
E_7	0.2	Heterogênea Itens	0,0,1,1,1	✓	0.14546
E_2	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.14544

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.05	Heterogênea Itens	0,0,1,1,1	✓	0.14525
E_1	0.2	Heterogênea Itens	0,0,1,1,1	✓	0.14525
E_6	0.1	Completa	1,0,0,0,1	✓	0.14512
E_5	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14497
E_1	0.05	N-Partida	0,0,1,1,1	✓	0.14489
E_1	0.2	N-Partida	0,0,1,1,1	✓	0.14489
E_5	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14481
E_7	0.1	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14479
E_3	0.05	Heterogênea Usuários	1,0,0,0,1	✓	0.14478
E_3	0.2	Heterogênea Usuários	1,0,0,0,1	✓	0.14478
E_7	0.05	Heterogênea Itens	1,0,0,0,1	✓	0.14473
E_7	0.2	Heterogênea Itens	1,0,0,0,1	✓	0.14473
E_4	0.05	Heterogênea Itens	1,0,0,0,1	✓	0.14455
E_4	0.2	Heterogênea Itens	1,0,0,0,1	✓	0.14455
E_3	0.05	N-Partida	1,0,0,0,1	✓	0.14453
E_3	0.2	N-Partida	1,0,0,0,1	✓	0.14453
E_6	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14446
E_6	0.05	Heterogênea Itens	1,0,0,0,1	✓	0.14445
E_6	0.2	Heterogênea Itens	1,0,0,0,1	✓	0.14445
E_6	0.1	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14442
E_8	0.05	N-Partida	0,0,0,1,1	✓	0.14437
E_8	0.1	N-Partida	0,0,0,1,1	✓	0.14437
E_8	0.2	N-Partida	0,0,0,1,1	✓	0.14437
E_4	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14434
E_3	0.05	N-Partida	0,0,0,1,1	✓	0.14424
E_3	0.2	N-Partida	0,0,0,1,1	✓	0.14424
E_7	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14424

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_7	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14423
E_1	0.05	Completa	1,0,0,0,1	✓	0.14423
E_1	0.2	Completa	1,0,0,0,1	✓	0.14423
E_7	0.05	Heterogênea Usuários	0,0,1,1,1	✓	0.14410
E_7	0.2	Heterogênea Usuários	0,0,1,1,1	✓	0.14410
E_7	0.05	N-Partida	0,0,1,1,1	✓	0.14408
E_7	0.2	N-Partida	0,0,1,1,1	✓	0.14408
E_6	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14406
E_3	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14399
E_3	0.05	Heterogênea Usuários	0,0,0,1,1	✓	0.14395
E_3	0.2	Heterogênea Usuários	0,0,0,1,1	✓	0.14395
E_2	0.05	Heterogênea Usuários	0,0,1,1,1	✓	0.14389
E_2	0.2	Heterogênea Usuários	0,0,1,1,1	✓	0.14389
E_1	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.14364
E_7	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14353
E_7	0.05	Completa	0,0,1,1,1	✓	0.14352
E_7	0.2	Completa	0,0,1,1,1	✓	0.14352
E_8	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.14350
E_5	0.05	Heterogênea Itens	0,0,1,1,1	✓	0.14349
E_5	0.2	Heterogênea Itens	0,0,1,1,1	✓	0.14349
E_1	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14340
E_5	0.05	Completa	0,0,1,1,1	✓	0.14339
E_5	0.2	Completa	0,0,1,1,1	✓	0.14339

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_6	0.05	Completa	1,0,0,0,1	✓	0.14332
E_6	0.2	Completa	1,0,0,0,1	✓	0.14332
E_3	0.05	Completa	0,0,1,1,1	✓	0.14330
E_3	0.2	Completa	0,0,1,1,1	✓	0.14330
E_5	0.05	N-Partida	1,0,0,0,1	✓	0.14326
E_5	0.2	N-Partida	1,0,0,0,1	✓	0.14326
E_5	0.05	Heterogênea Usuários	1,0,0,0,1	✓	0.14316
E_5	0.2	Heterogênea Usuários	1,0,0,0,1	✓	0.14316
E_6	0.1	N-Partida	0,0,0,1,1	✓	0.14313
E_6	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14312
E_1	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14306
E_7	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14296
E_2	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14293
E_4	0.05	Heterogênea Usuários	0,0,1,1,1	✓	0.14293
E_4	0.2	Heterogênea Usuários	0,0,1,1,1	✓	0.14293
E_1	0.05	Completa	0,0,1,1,1	✓	0.14292
E_1	0.2	Completa	0,0,1,1,1	✓	0.14292
E_7	0.05	Completa	1,0,0,0,1	✓	0.14277
E_7	0.2	Completa	1,0,0,0,1	✓	0.14277
E_4	0.05	Completa	0,0,1,1,1	✓	0.14271
E_4	0.2	Completa	0,0,1,1,1	✓	0.14271
E_2	0.05	N-Partida	0,0,1,1,1	✓	0.14255
E_2	0.2	N-Partida	0,0,1,1,1	✓	0.14255
E_8	0.1	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.14253
E_6	0.1	Heterogênea Usuários	0,0,1,1,1	✓	0.14250
E_2	0.05	Completa	0,0,1,1,1	✓	0.14235

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_2	0.2	Completa	0,0,1,1,1	✓	0.14235
E_5	0.05	N-Partida	0,0,0,1,1	✓	0.14217
E_5	0.2	N-Partida	0,0,0,1,1	✓	0.14217
E_5	0.05	Heterogênea Usuários	0,0,1,1,1	✓	0.14209
E_5	0.2	Heterogênea Usuários	0,0,1,1,1	✓	0.14209
E_1	0.05	N-Partida	0,0,0,1,1	✓	0.14206
E_1	0.2	N-Partida	0,0,0,1,1	✓	0.14206
E_7	0.1	Heterogênea Usuários	0,0,1,1,1	✓	0.14199
E_1	0.05	Heterogênea Usuários	1,0,0,0,1	✓	0.14197
E_1	0.2	Heterogênea Usuários	1,0,0,0,1	✓	0.14197
E_1	0.05	Heterogênea Usuários	0,0,0,1,1	✓	0.14197
E_1	0.2	Heterogênea Usuários	0,0,0,1,1	✓	0.14197
E_2	0.05	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14191
E_2	0.05	N-Partida	0,0,0,1,1	✓	0.14187
E_2	0.2	N-Partida	0,0,0,1,1	✓	0.14187
E_7	0.1	N-Partida	1,0,0,0,1	✓	0.14145
E_2	0.2	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.14136
E_6	0.1	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14116
E_6	0.1	N-Partida	1,0,0,0,1	✓	0.14114
E_7	0.1	Heterogênea Usuários	1,0,0,0,1	✓	0.14113
E_6	0.05	N-Partida	1,0,0,0,1	✓	0.14112
E_6	0.2	N-Partida	1,0,0,0,1	✓	0.14112
E_7	0.1	N-Partida	0,0,1,1,1	✓	0.14105
E_1	0.05	Heterogênea Usuários	0,0,1,1,1	✓	0.14098

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.2	Heterogênea Usuários	0,0,1,1,1	✓	0.14098
E_2	0.05	Completa	0,0,0,1,1	✓	0.14096
E_2	0.2	Completa	0,0,0,1,1	✓	0.14096
E_3	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14093
E_6	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14089
E_4	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14076
E_4	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.14073
E_3	0.05	Heterogênea Itens	0,0,1,1,1	✓	0.14071
E_3	0.2	Heterogênea Itens	0,0,1,1,1	✓	0.14071
E_7	0.1	Heterogênea Usuários	0,0,0,1,1	✓	0.14062
E_3	0.2	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14059
E_1	0.05	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.14032
E_2	0.05	Heterogênea Itens	0,0,0,1,1	✓	0.14030
E_2	0.2	Heterogênea Itens	0,0,0,1,1	✓	0.14030
E_7	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.14006
E_5	0.05	Heterogênea Usuários	0,0,0,1,1	✓	0.14002
E_5	0.2	Heterogênea Usuários	0,0,0,1,1	✓	0.14002
E_4	0.05	Heterogênea Usuários	1,0,0,0,1	✓	0.14001
E_4	0.2	Heterogênea Usuários	1,0,0,0,1	✓	0.14001
E_1	0.05	N-Partida	1,0,0,0,1	✓	0.13971
E_1	0.2	N-Partida	1,0,0,0,1	✓	0.13971
E_6	0.05	Heterogênea Usuários	1,0,0,0,1	✓	0.13949

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_6	0.2	Heterogênea Usuários	1,0,0,0,1	✓	0.13949
E_4	0.05	N-Partida	0,0,0,1,1	✓	0.13949
E_4	0.2	N-Partida	0,0,0,1,1	✓	0.13949
E_8	0.05	Heterogênea Usuários	1,0,0,0,1	✓	0.13941
E_8	0.1	Heterogênea Usuários	1,0,0,0,1	✓	0.13941
E_8	0.2	Heterogênea Usuários	1,0,0,0,1	✓	0.13941
E_7	0.05	Heterogênea Usuários	0,0,0,1,1	✓	0.13937
E_7	0.2	Heterogênea Usuários	0,0,0,1,1	✓	0.13937
E_8	0.05	N-Partida	1,0,0,0,1	✓	0.13933
E_8	0.1	N-Partida	1,0,0,0,1	✓	0.13933
E_8	0.2	N-Partida	1,0,0,0,1	✓	0.13933
E_7	0.1	Heterogênea Itens	0,0,1,1,1	✓	0.13910
E_7	0.05	Heterogênea Usuários	1,0,0,0,1	✓	0.13906
E_7	0.2	Heterogênea Usuários	1,0,0,0,1	✓	0.13906
E_4	0.05	N-Partida	1,0,0,0,1	✓	0.13889
E_4	0.2	N-Partida	1,0,0,0,1	✓	0.13889
E_8	0.05	Heterogênea Usuários	0,0,0,1,1	✓	0.13870
E_8	0.1	Heterogênea Usuários	0,0,0,1,1	✓	0.13870
E_8	0.2	Heterogênea Usuários	0,0,0,1,1	✓	0.13870
E_2	0.05	Enriquecimento Usuários Similares	0,0,0,1,1	✓	0.13869
E_7	0.1	N-Partida	0,0,0,1,1	✓	0.13868
E_2	0.05	Heterogênea Itens	0,0,1,1,1	✓	0.13863
E_2	0.2	Heterogênea Itens	0,0,1,1,1	✓	0.13863
E_7	0.1	Completa	0,0,1,1,1	✓	0.13855

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_2	0.05	Heterogênea Usuários	1,0,0,0,1	✓	0.13852
E_2	0.2	Heterogênea Usuários	1,0,0,0,1	✓	0.13852
E_7	0.05	N-Partida	0,0,0,1,1	✓	0.13846
E_7	0.2	N-Partida	0,0,0,1,1	✓	0.13846
E_6	0.1	Heterogênea Usuários	1,0,0,0,1	✓	0.13815
E_2	0.05	Completa	1,0,0,0,1	✓	0.13810
E_2	0.2	Completa	1,0,0,0,1	✓	0.13810
E_2	0.2	Enriquecimento Usuários Similares	1,0,0,0,1	✓	0.13797
E_6	0.05	Heterogênea Usuários	0,0,0,1,1	✓	0.13791
E_6	0.2	Heterogênea Usuários	0,0,0,1,1	✓	0.13791
E_4	0.05	Heterogênea Usuários	0,0,0,1,1	✓	0.13789
E_4	0.2	Heterogênea Usuários	0,0,0,1,1	✓	0.13789
E_2	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.13770
E_2	0.05	N-Partida	1,0,0,0,1	✓	0.13750
E_2	0.2	N-Partida	1,0,0,0,1	✓	0.13750
E_6	0.1	Heterogênea Usuários	0,0,0,1,1	✓	0.13739
E_2	0.05	Heterogênea Itens	1,0,0,0,1	✓	0.13686
E_2	0.2	Heterogênea Itens	1,0,0,0,1	✓	0.13686
E_6	0.05	N-Partida	0,0,0,1,1	✓	0.13678
E_6	0.2	N-Partida	0,0,0,1,1	✓	0.13678
E_2	0.05	Heterogênea Usuários	0,0,0,1,1	✓	0.13678
E_2	0.2	Heterogênea Usuários	0,0,0,1,1	✓	0.13678
E_8	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.13671

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_7	0.05	N-Partida	1,0,0,0,1	✓	0.13633
E_7	0.2	N-Partida	1,0,0,0,1	✓	0.13633
E_7	0.1	Enriquecimento Usuários Similares	0,0,1,1,1	✓	0.13613
E_4	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.13519
E_4	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.13358
E_2	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.13121
E_4	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.12969
E_2	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.12812
E_6	0.05	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.12802
E_6	0.05	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.12683
E_6	0.05	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.12581
E_4	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.12400
E_6	0.1	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.12092
E_6	0.1	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.12074
E_6	0.1	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.11986
E_6	0.2	Enriquecimento Usuários Similares	0,0,1,5,10	✓	0.11610
E_6	0.2	Enriquecimento Usuários Similares	0,0,1,3,5	✓	0.11589
E_6	0.2	Enriquecimento Usuários Similares	1,2,3,4,5	✓	0.11544
E_2	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.11336

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_4	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✖	0.11311
E_7	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✖	0.10893
E_2	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✖	0.10884
E_4	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✖	0.10815
E_4	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✖	0.10681
E_7	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✖	0.10678
E_6	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✖	0.10632
E_6	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✖	0.10383
E_6	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✖	0.10310
E_2	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✖	0.10288
E_7	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✖	0.10001
E_2	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✖	0.09958
E_7	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✖	0.09928
E_7	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✖	0.09870
E_2	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✖	0.09816
E_4	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✖	0.09804
E_4	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✖	0.09772
E_4	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✖	0.09747

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_2	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✖	0.09718
E_7	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✖	0.09670
E_2	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✖	0.09522
E_6	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✖	0.09360
E_4	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✖	0.09280
E_6	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✖	0.09264
E_6	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✖	0.09251
E_7	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✖	0.09109
E_3	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✖	0.09051
E_3	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✖	0.09006
E_3	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✖	0.09002
E_5	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✖	0.08975
E_3	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✖	0.08968
E_3	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✖	0.08951
E_5	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✖	0.08561
E_5	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✖	0.08364
E_5	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✖	0.08362
E_5	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✖	0.08350

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_6	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.08334
E_1	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.08278
E_1	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.07857
E_3	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.07794
E_1	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.07773
E_1	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.07744
E_2	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.07735
E_1	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.07650
E_8	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.07559
E_3	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.07486
E_6	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.07482
E_8	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.07482
E_1	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.07448
E_5	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.07444
E_8	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.07430
E_5	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.07389
E_7	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.07374
E_2	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.07342

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_5	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.07323
E_8	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.07266
E_6	0.1	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.07243
E_8	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.07199
E_2	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.07197
E_1	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.07050
E_6	0.1	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.07029
E_6	0.1	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.07003
E_6	0.1	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.06980
E_8	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.06978
E_1	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.06945
E_6	0.1	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.06929
E_5	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.06920
E_1	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.06907
E_6	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.06906
E_8	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.06860
E_7	0.1	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.06844
E_3	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.06793

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_2	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.06782
E_2	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.06780
E_7	0.1	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.06778
E_8	0.1	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.06759
E_8	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.06748
E_2	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.06747
E_1	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.06736
E_7	0.1	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.06672
E_1	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.06657
E_1	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.06654
E_8	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.06579
E_4	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.06518
E_7	0.1	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.06488
E_6	0.1	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.06478
E_5	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.06459
E_4	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.06421
E_4	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.06405
E_8	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.06383

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_5	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.06368
E_8	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.06337
E_5	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.06295
E_8	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.06294
E_8	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.06282
E_7	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.06271
E_8	0.1	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.06262
E_4	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.06225
E_8	0.1	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.06218
E_6	0.1	N-Partida	1,1,1,1,1	✓	0.06215
E_8	0.1	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.06184
E_6	0.1	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.06121
E_7	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.06115
E_7	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.06108
E_4	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.06084
E_7	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.06067
E_6	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.06048
E_6	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.06021

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_6	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.06009
E_2	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.05962
E_6	0.1	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.05911
E_3	0.05	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.05892
E_7	0.1	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.05879
E_7	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✓	0.05871
E_2	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.05870
E_4	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.05839
E_3	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.05834
E_3	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.05795
E_3	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.05731
E_3	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.05672
E_3	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.05626
E_3	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.05605
E_7	0.1	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.05583
E_7	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.05536
E_4	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.05522
E_6	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.05502

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_6	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.05492
E_4	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.05490
E_6	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.05480
E_8	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.05478
E_4	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.05471
E_7	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.05470
E_6	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.05448
E_7	0.1	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.05436
E_7	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.05432
E_7	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.05396
E_2	0.05	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.05392
E_2	0.05	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.05391
E_7	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.05383
E_2	0.05	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.05350
E_6	0.05	N-Partida	1,1,1,1,1	✓	0.05330
E_6	0.2	N-Partida	1,1,1,1,1	✓	0.05330
E_6	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.05283
E_1	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.05279
E_4	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.05239

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.05228
E_4	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.05198
E_6	0.05	Heterogênea Usuários	1,1,1,1,1	✓	0.05188
E_6	0.2	Heterogênea Usuários	1,1,1,1,1	✓	0.05188
E_8	0.1	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.05160
E_1	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.05133
E_8	0.05	Heterogênea Usuários	1,1,1,1,1	✓	0.05056
E_8	0.1	Heterogênea Usuários	1,1,1,1,1	✓	0.05056
E_8	0.2	Heterogênea Usuários	1,1,1,1,1	✓	0.05056
E_5	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.05029
E_8	0.05	N-Partida	1,1,1,1,1	✓	0.05014
E_8	0.1	N-Partida	1,1,1,1,1	✓	0.05014
E_8	0.2	N-Partida	1,1,1,1,1	✓	0.05014
E_3	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.05002
E_6	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.04946
E_6	0.1	Heterogênea Itens	1,1,1,1,1	✓	0.04938
E_5	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.04877
E_6	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.04858
E_6	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.04781
E_8	0.1	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.04760

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.1	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.04754
E_1	0.05	N-Partida	1,1,1,1,1	✓	0.04737
E_1	0.2	N-Partida	1,1,1,1,1	✓	0.04737
E_8	0.1	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.04718
E_3	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.04716
E_6	0.05	Completa	1,1,1,1,1	✓	0.04694
E_6	0.2	Completa	1,1,1,1,1	✓	0.04694
E_6	0.05	Heterogênea Itens	1,1,1,1,1	✓	0.04694
E_6	0.2	Heterogênea Itens	1,1,1,1,1	✓	0.04694
E_3	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.04658
E_6	0.1	Heterogênea Usuários	1,1,1,1,1	✓	0.04657
E_6	0.1	Completa	1,1,1,1,1	✓	0.04501
E_1	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.04476
E_8	0.1	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.04437
E_2	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.04421
E_1	0.05	Heterogênea Usuários	1,1,1,1,1	✓	0.04407
E_1	0.2	Heterogênea Usuários	1,1,1,1,1	✓	0.04407
E_5	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.04392
E_6	0.1	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.04381
E_7	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.04371
E_5	0.05	N-Partida	1,1,1,1,1	✓	0.04350
E_5	0.2	N-Partida	1,1,1,1,1	✓	0.04350

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_5	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.04347
E_5	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.04341
E_7	0.1	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.04340
E_8	0.05	Completa	1,1,1,1,1	✓	0.04291
E_8	0.1	Completa	1,1,1,1,1	✓	0.04291
E_8	0.2	Completa	1,1,1,1,1	✓	0.04291
E_5	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.04288
E_6	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.04275
E_5	0.05	Heterogênea Usuários	1,1,1,1,1	✓	0.04262
E_5	0.2	Heterogênea Usuários	1,1,1,1,1	✓	0.04262
E_7	0.1	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.04238
E_5	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.04215
E_7	0.1	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.04195
E_6	0.1	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.04176
E_4	0.05	N-Partida	1,1,1,1,1	✓	0.04163
E_4	0.2	N-Partida	1,1,1,1,1	✓	0.04163
E_6	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.04136
E_8	0.1	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.04083
E_4	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.04069
E_6	0.1	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.04054

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_8	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.04043
E_6	0.1	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.04041
E_5	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.04004
E_7	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.03991
E_8	0.1	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03982
E_7	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03957
E_1	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.03938
E_2	0.05	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.03931
E_8	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.03931
E_8	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.03917
E_6	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.03885
E_4	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03885
E_1	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.03877
E_3	0.05	Heterogênea Itens	1,1,1,1,1	✓	0.03870
E_3	0.2	Heterogênea Itens	1,1,1,1,1	✓	0.03870
E_2	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.03869
E_4	0.05	Heterogênea Itens	1,1,1,1,1	✓	0.03866
E_4	0.2	Heterogênea Itens	1,1,1,1,1	✓	0.03866
E_3	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.03826
E_1	0.05	Heterogênea Itens	1,1,1,1,1	✓	0.03822
E_1	0.2	Heterogênea Itens	1,1,1,1,1	✓	0.03822

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_3	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.03810
E_1	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.03797
E_7	0.05	Completa	1,1,1,1,1	✓	0.03792
E_7	0.2	Completa	1,1,1,1,1	✓	0.03792
E_7	0.1	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.03789
E_4	0.05	Heterogênea Usuários	1,1,1,1,1	✓	0.03771
E_4	0.2	Heterogênea Usuários	1,1,1,1,1	✓	0.03771
E_8	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03745
E_7	0.1	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.03714
E_5	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03710
E_7	0.1	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03700
E_4	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.03690
E_1	0.05	Completa	1,1,1,1,1	✓	0.03686
E_1	0.2	Completa	1,1,1,1,1	✓	0.03686
E_3	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.03681
E_3	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03622
E_2	0.05	N-Partida	1,1,1,1,1	✓	0.03599
E_2	0.2	N-Partida	1,1,1,1,1	✓	0.03599
E_1	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03582
E_3	0.05	Heterogênea Usuários	1,1,1,1,1	✓	0.03578
E_3	0.2	Heterogênea Usuários	1,1,1,1,1	✓	0.03578

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.03569
E_3	0.05	N-Partida	1,1,1,1,1	✓	0.03562
E_3	0.2	N-Partida	1,1,1,1,1	✓	0.03562
E_2	0.05	Heterogênea Usuários	1,1,1,1,1	✓	0.03549
E_2	0.2	Heterogênea Usuários	1,1,1,1,1	✓	0.03549
E_2	0.05	Completa	1,1,1,1,1	✓	0.03546
E_2	0.2	Completa	1,1,1,1,1	✓	0.03546
E_5	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.03542
E_4	0.05	Completa	1,1,1,1,1	✓	0.03516
E_4	0.2	Completa	1,1,1,1,1	✓	0.03516
E_6	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.03503
E_7	0.05	Heterogênea Usuários	1,1,1,1,1	✓	0.03502
E_7	0.2	Heterogênea Usuários	1,1,1,1,1	✓	0.03502
E_8	0.05	Heterogênea Itens	1,1,1,1,1	✓	0.03496
E_8	0.1	Heterogênea Itens	1,1,1,1,1	✓	0.03496
E_8	0.2	Heterogênea Itens	1,1,1,1,1	✓	0.03496
E_8	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.03480
E_7	0.1	Heterogênea Itens	1,1,1,1,1	✓	0.03460
E_7	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.03453
E_7	0.1	Completa	1,1,1,1,1	✓	0.03429
E_4	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.03417
E_4	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03402
E_7	0.05	Heterogênea Itens	1,1,1,1,1	✓	0.03391
E_7	0.2	Heterogênea Itens	1,1,1,1,1	✓	0.03391
E_2	0.05	Heterogênea Itens	1,1,1,1,1	✓	0.03367

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_2	0.2	Heterogênea Itens	1,1,1,1,1	✓	0.03367
E_7	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.03347
E_5	0.05	Completa	1,1,1,1,1	✓	0.03334
E_5	0.2	Completa	1,1,1,1,1	✓	0.03334
E_2	0.05	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.03325
E_7	0.1	Heterogênea Usuários	1,1,1,1,1	✓	0.03308
E_6	0.1	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.03270
E_1	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03233
E_5	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.03228
E_2	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03226
E_5	0.05	Heterogênea Itens	1,1,1,1,1	✓	0.03149
E_5	0.2	Heterogênea Itens	1,1,1,1,1	✓	0.03149
E_7	0.1	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.03114
E_3	0.05	Completa	1,1,1,1,1	✓	0.03112
E_3	0.2	Completa	1,1,1,1,1	✓	0.03112
E_8	0.2	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.03112
E_7	0.1	N-Partida	1,1,1,1,1	✓	0.03086
E_8	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.03085
E_1	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.03055
E_4	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.02997
E_8	0.1	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.02949
E_7	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.02948

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_1	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.02868
E_6	0.1	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.02848
E_3	0.05	Enriquecimento Usuários Similares	1,1,1,1,1	✓	0.02841
E_8	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.02829
E_8	0.1	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.02819
E_7	0.05	N-Partida	1,1,1,1,1	✓	0.02814
E_7	0.2	N-Partida	1,1,1,1,1	✓	0.02814
E_2	0.05	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.02798
E_1	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.02745
E_7	0.1	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.02741
E_8	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✗	0.02726
E_8	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✗	0.02690
E_1	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.02679
E_5	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.02679
E_8	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✗	0.02678
E_5	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.02650
E_8	0.1	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.02590
E_1	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.02588
E_5	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.02536

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_5	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.02521
E_6	0.1	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.02333
E_6	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.02220
E_6	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.02201
E_2	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.02111
E_3	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.02106
E_6	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.02102
E_2	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.02085
E_2	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.02058
E_4	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.02010
E_4	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.01991
E_8	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✗	0.01979
E_4	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.01964
E_7	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.01956
E_7	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.01951
E_7	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.01947
E_8	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✗	0.01836
E_1	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.01774

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_3	0.2	Enriquecimento Colaborativo	1,2,3,4,5	✓	0.01638
E_8	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✗	0.01630
E_1	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.01611
E_3	0.2	Enriquecimento Colaborativo	0,0,1,3,5	✓	0.01604
E_3	0.2	Enriquecimento Colaborativo	0,0,1,5,10	✓	0.01602
E_1	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.01558
E_1	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.01536
E_5	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.01447
E_5	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.01428
E_5	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.01353
E_3	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.01149
E_8	0.1	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.01101
E_6	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.01093
E_6	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.01029
E_3	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.00917
E_6	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.00916
E_4	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.00897
E_2	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.00851

Experimento	Taxa Usuário	Abordagem	Peso s	Normaliza	MAP
E_7	0.2	Enriquecimento Colaborativo	0,0,0,1,1	✓	0.00844
E_3	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.00780
E_8	0.2	Enriquecimento Colaborativo	1,1,1,1,1	✗	0.00755
E_4	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.00738
E_2	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.00686
E_7	0.2	Enriquecimento Colaborativo	1,0,0,0,1	✓	0.00686
E_2	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.00591
E_4	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.00580
E_7	0.2	Enriquecimento Colaborativo	0,0,1,1,1	✓	0.00560

Como é possível observar pela tabela, a escolha dos parâmetros do método **HINCARS**, bem como da abordagem de construção da rede heterogênea, impactou fortemente os resultados finais obtidos. Além dos experimentos que obtiveram resultados estatisticamente equivalentes ao *baseline*, que já haviam sido apresentados anteriormente, nota-se também que vários outros experimentos não alcançaram resultados nem próximos ao *baseline*. Isso é um forte indicativo que os parâmetros do método proposto devem ser ajustados cuidadosamente.