

## 融合社交影响扩散的长尾物品推荐模型

张槟淇<sup>1</sup>, 尉译心<sup>1</sup>, 王文剑<sup>1,2\*</sup>

(1. 山西警察学院 网络安全保卫系, 山西 太原 030401;

2. 山西大学 计算智能与中文信息处理教育部重点实验室, 山西 太原 030006)

**摘要:**在推荐系统中,由于用户评分和交互频次存在长尾分布特性,导致长尾物品特征提取困难,现有的方法或者过多关注尾部物品,忽略其与头部物品的联系,或者忽略社交网络对用户偏好的影响,从而影响了推荐效果。因此,本文提出一种融合社会影响扩散的长尾推荐模型 LoSidi (Long-tail Recommendation method Incorporating Social Influence Diffusion)。首先对于每个用户,通过对目标用户各层社交邻居的采样聚合,并结合其已交互的热门物品生成用户兴趣嵌入。其次通过计算长尾物品与用户已交互头部物品间的相似性挖掘长尾物品的潜在特征。最终,LoSidi 模型构建用户与长尾物品间的联系,对长尾物品进行评分预测和推荐。在常用数据集上的实验结果表明,本文提出的模型可显著提高用户推荐列表的新颖性和多样性。

**关键词:**推荐系统;社会推荐;长尾问题;图神经网络

**中图分类号:**TP301 **文献标志码:**A **文章编号:**0253-2395(2025)04-0741-11

## Long-tail Recommendation Method Incorporating Social Influence Diffusion Model

ZHANG Binqi<sup>1</sup>, WEI Yixin<sup>1</sup>, WANG Wenjian<sup>1,2\*</sup>

(1. Network Security Department, Shanxi Police College, Taiyuan 030401, China;

2. Key Laboratory of Computational Intelligence and Chinese Information Processing of Ministry of Education, Shanxi University, Taiyuan 030006, China)

**Abstract:** In recommendation systems, the long-tail distribution of user ratings and interaction frequencies poses challenges for extracting the features of long-tail items. Existing methods either overly focus on tail items while neglecting their connections with head items or disregard the influence of social networks on user preferences, thereby impacting recommendation performance. To address these issues, this paper proposes a novel long-tail recommendation model called LoSidi (Long-tail Recommendation Method Incorporating Social Influence Diffusion). Firstly, for each user, the model aggregates samples of social neighbors at various layers and integrates these with the popular items the user has interacted with to generate user interest embeddings. Secondly, the potential features of long-tail items are mined by calculating the similarity between long-tail items and the head items the user has interacted with. Finally, the LoSidi model establishes links between users and long-tail items, predicting scores and generating recommendations for these items. Experimental results on widely-used datasets demonstrate that the proposed model significantly improves the novelty and diversity of users' recommendation lists.

**Key words:** recommender system; social recommendation; long tail problem; graph neural network

收稿日期:2024-09-02;接受日期:2025-03-08

基金项目:国家自然科学基金(62076154);山西省科技重大专项计划“揭榜挂帅”项目(202101020101019)

作者简介:张槟淇(1996-),女,山西太原人,硕士,助教,研究方向为机器学习、推荐系统。E-mail:853545395@qq.com

\* 通信作者:王文剑(WANG Wenjian),E-mail:wjwang@sxu.edu.cn

引文格式:张槟淇,尉译心,王文剑.融合社交影响扩散的长尾物品推荐模型[J].山西大学学报(自然科学版),2025,48(4):741-751. DOI:10.13451/j.sxu.ns.2025027.

## 0 引言

推荐领域实证研究表明,用户行为数据(包括评分记录和交互频率)普遍遵循长尾分布<sup>[1-2]</sup>,揭示出系统内存在海量具有潜在价值的非流行物品(即长尾物品)亟待有效识别<sup>[3]</sup>。然而,基于协同过滤的经典推荐模型虽然在头部物品推荐中展现出良好的预测性能,但对于长尾物品的精准推荐却面临推荐覆盖率与准确率的双重困境。然而,随着社交平台的发展,社交网络的融入为推荐系统带来了新的机遇。社交网络提供了更为详尽的用户行为数据,使得推荐系统能够更深入地洞悉用户的偏好与社交关系,从而更有效地向用户推荐这些长尾物品,显著提升推荐的精准度<sup>[4-5]</sup>。为此,本文创新性地构建融合社交网络的长尾推荐模型,基于社交网络的多层注意力传播机制,采用图神经网络建模用户社交影响力的扩散路径,生成用户偏好表征;同时,通过头部物品与长尾物品的相似关系进一步挖掘长尾物品的潜在特征,构建用户和长尾物品的联系,为目标用户推荐其喜欢的长尾物品。

当前,研究人员发现推荐系统中的长尾分布首要问题在于样本分布的不均衡,具体表现为头部物品样本量充足,模型易于学习,而长尾物品样本稀缺,模型对其学习不足,导致推荐效果较差。此外,大规模物品种类的指数级扩张加剧了推荐系统的长尾效应呈现持续极化趋势,直接制约推荐效能的边际效益提升。当前主流的方法聚焦于样本平衡策略[如重采样(resampling)<sup>[6]</sup>与损失函数调整方法[如重加权(reweighting)<sup>[7]</sup>]。具体而言,前者是将高频类别稀疏采样与低频类别数据增广相结合缓解类别分布偏斜问题,后者是通过构建类别敏感权重分配机制,在梯度反向传播过程中动态增强尾部样本的梯度更新幅度。然而这类单边优化策略往往局限于尾部商品补偿性处理,未能有效建模头尾部商品间的协同进化关系。谷歌开发了一种新的对偶迁移学习体系<sup>[8]</sup>,利用头项中丰富的用户反馈以及头项和尾项的语义联系,将知识从头项转移到尾项。此外文献<sup>[9]</sup>提出了一种新的基于图的长尾推荐算法,该算法利用无向边加权图表示用户-项目信息,扩

展了Hit Time并提出了高效的Absorbing Time算法来帮助用户找到自己喜欢的长尾项目。但这些方法大多数没有考虑社交关系对用户兴趣偏好的影响,而如今社交网络的迅速发展,将社交信息与推荐系统融合已是大势所趋。

社交图谱蕴含的异构用户关联网络为推荐系统提供了超越传统用户-商品交互矩阵的潜在兴趣表征源,这一发现驱动着融合社交网络的推荐模型成为近年来的研究热点。具体来说,SoRec<sup>[10]</sup>(Social Recommendation Using Probabilistic Matrix Factorization)率先将社交拓拓扑网络整合至概率矩阵分解框架,通过异构数据联合建模有效缓解用户-商品交互矩阵的稀疏性挑战,显著提升评分预测精度。该工作启发了SocialRSTE<sup>[11]</sup>(Recommendation with Social Trust Ensemble),该框架构建信任感知的协同过滤机制,创新性地建立用户本体偏好与社交信任网络成员偏好的贝叶斯耦合关系。研究前沿进一步延伸至正则化技术层面,SoReg<sup>[12]</sup>(Recommender Systems with Social Regularization)通过设计基于图拉普拉斯约束的社交正则化项,在矩阵分解目标函数中编码用户社交近邻的隐式相似性先验。SocialMF<sup>[13]</sup>(Matrix Factorization Based Model for Recommendation in Social Rating Networks)模型在SoRec基础上进行改进,通过引入加权平均机制学习用户特征。TrustMF<sup>[14]</sup>(Social Collaborative Filtering by Trust)进一步从双向信任关系(信任与被信任)的角度构建用户表征,从而提升对未知项目评分的预测精度。LOCABAL<sup>[15]</sup>(Exploiting Local and Global Social Context for Recommendation)提出分层社交上下文建模框架,通过微观用户邻域特征提取与宏观社群结构感知的双流架构,创新性地解耦局部-全局社交影响力传播路径。TrustSVD<sup>[16]</sup>(A Trust-based Matrix Factorization Technique)模型在SVD++<sup>[17]</sup>框架上进行扩展,创新性地融合了显式与隐式双重社交信息<sup>[18]</sup>,不仅整合用户的显式评分和直接社交关系,还引入用户隐式行为数据和间接社交互动,从而构建了更全面的推荐模型。这些社交推荐方法旨在处理一般的推荐问题,追求推荐精度的提高,但没有考虑对长尾商品的推荐。

社交影响力的传播特性推动了图神经网络(Graph Neural Network, GNN)在推荐领域的创新应用。例如,研究者通过动态图表示方法构建社交信息传播路径,结合多层级邻居特征聚合技术,更精准地捕捉用户行为背后的社交驱动因素。典型的方法有DiffNet<sup>[19]</sup>(A neural Influence Diffusion Model for Social Recommendation),提出基于图采样技术GraphSAGE<sup>[20]</sup>(Inductive Representation Learning on Large Graphs)的社交影响力扩散模型,通过融合用户社交圈特征与历史交互行为数据生成动态用户表征。GraphRec<sup>[21]</sup>(Graph Neural Networks for Social Recommendation)则构建异构信息融合框架,从社交关系网和用户-商品交互图中联合学习嵌入表示,其中注意力网络可量化不同社交邻居的贡献权重。这些方法将用户之间的关系与用户项目的关系转化为图结构,利用GNN获取用户节点和项目节点的潜在信息,为推荐系统的研究提供了新的方向。但当前研究在社交网络与长尾推荐的融合方向仍存在双重局限:其一,现有方法多聚焦于直接社交关联(如单跳邻居建模),却忽视社交影响力的多跳传播机制;其二,用户偏好建模缺乏动态适应性,尤其在长尾场景下难以精准捕捉跨层级的兴趣演化路径。

为此,本文创新性地提出一种整合社交影响力传播机制与图神经网络的长尾推荐模型——融合社交影响扩散的长尾物品推荐模型LoSidi。首先,基于用户社交矩阵生成社会化网络图,为每个用户构建个性化影响力传播路径,建模用户兴趣随社交网络演化的动态过程,并结合其历史交互的头部商品特征生成用户兴趣嵌入。其次,通过特征迁移策略将头部商品的语义特征映射至长尾商品,借助主题建模与偏好对齐技术建立用户-长尾商品的潜在关联。最后,利用推荐模型,预测用户与长尾物品的评分,从而增加了用户推荐列表的多样性和新颖性。

## 1 LoSidi方法

本文提出的LoSidi,对于每个用户,首先结合目标用户已交互的头部物品生成用户兴趣嵌

入,然后设计一个社会影响扩散层,来建模用户的兴趣嵌入随着社会影响的扩散而改变的过程。对于长尾物品,将头部物品作为目标用户兴趣偏好和长尾物品之间的桥梁,通过计算头部物品与长尾物品的相似性,得到长尾物品的特征向量。最终实现为目标用户进行长尾物品的推荐,提升推荐结果的新颖性和多样性。

### 1.1 推荐系统中的长尾问题

推荐系统普遍存在长尾分布现象,即约20%的高频交互物品占据80%的用户行为数据(如图1所示),这类物品被称为头部物品,剩余80%的低曝光商品则构成推荐长尾。这种数据分布偏斜导致两大技术挑战:其一,模型参数过度拟合头部商品特征,形成“马太效应”;其二,长尾商品因稀疏交互难以获得有效表征,直接影响推荐覆盖度。为解决此类问题,长尾推荐需实现双重目标:用户需求维度,通过挖掘具有潜在价值的非流行商品提升推荐新颖;平台价值维度,激活长尾商品经济价值以突破“信息茧房”效应。




图1 物品的长尾分布表示

Fig. 1 Representation of the long-tail distribution of items

实现高效长尾推荐需突破两个核心问题:首先构建动态用户画像,需融合多源异构数据(包括但不限于社交影响力传播路径、跨域行为日志);其次建立物品语义桥梁,将头部物品特征向量映射至长尾物品空间。本文创新性地设计双通道解决方案:(1)通过语义相似度计算建立头-尾物品关联;(2)采用图神经网络建模社交影响力的多阶传播效应,在用户表征中同步融合社交关系图谱与历史交互模式。值得强调的是,该方法通过对比学习策略实现用户偏好与商品特征的解耦式建模,有效缓解数据

稀疏性问题。

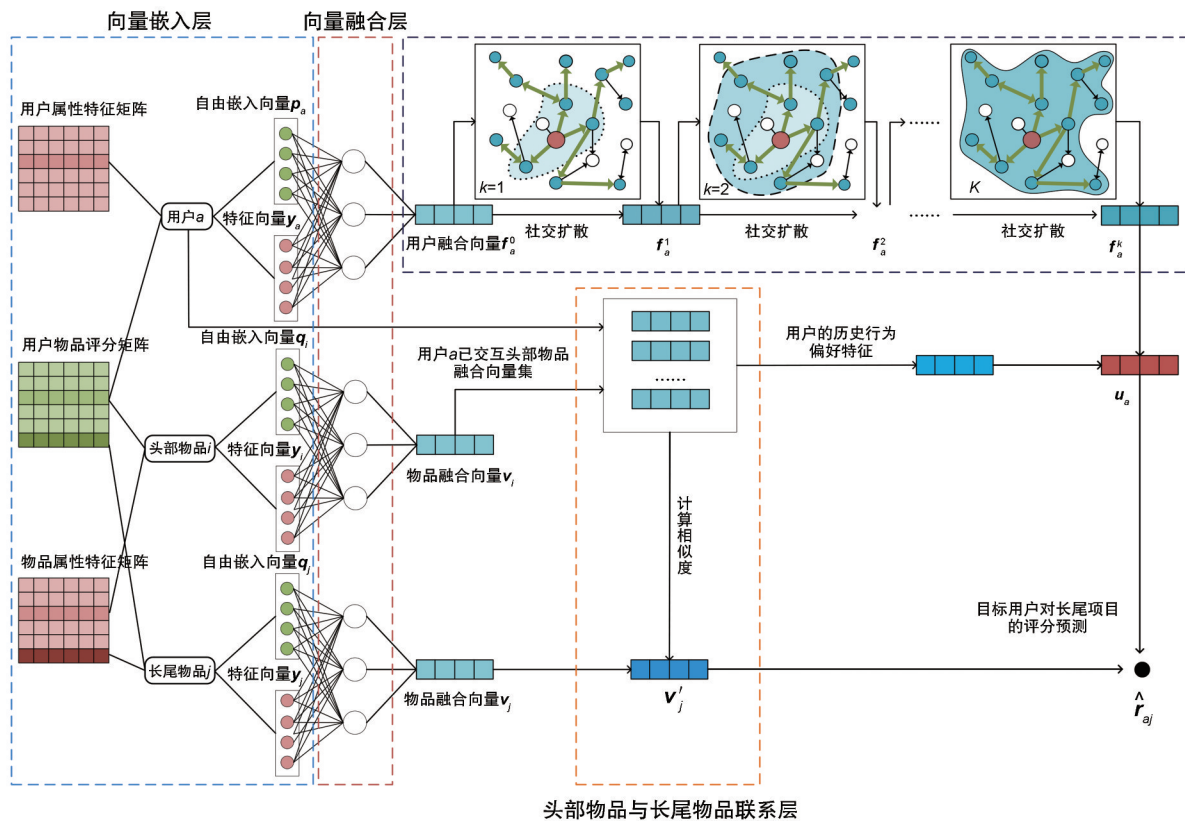
### 1.2 LoSidi 模型设计

LoSidi 框架创新性地融合社交影响力扩散过程与用户历史行为演化规律,通过异构数据融合机制实现两阶段建模:第一阶段构建用户动态兴趣图谱,整合用户社交关系传播路径与头部物品交互特征;第二阶段设计跨域特征迁移通道,基于语义相似性度量建立头-尾物品关联特征。如图 2 所示,基于长尾分布准则将物品划分为头部集(高频交互)与长尾集(低频交互),模型采用三元组输入架构(目标用户、头部商品、长尾商品),最终通过对比学习策略生成适配长尾场景的用户-物品推荐模型,提高推荐列表的新颖性和多样性。如图 2 所示,数据集根据交互频率划分为头部物品集和长尾物品集,LoSidi 模型将目标用户、头部物品和长尾物品作为输入,首先,利用向量嵌入层提取

出用户与商品的嵌入向量,实现嵌入向量的融合;对用户而言,将该融合向量输入社交影响扩散层,从而获得用户潜在向量;针对长尾物品,利用头部物品和长尾物品关联层,获得了该长尾物品的特征向量。最后,在预测层中,基于用户与长尾物品的特征向量,得到用户对长尾物品的预测评分。

#### 1.2.1 向量嵌入层设计

本框架的嵌入模块包含两部分:(1)自由嵌入:基于用户-商品评分矩阵,通过稀疏矩阵分解技术生成可训练的用户和物品的自由嵌入向量  $p_a, q_i$ ; (2)属性特征:针对用户人口统计学属性(年龄/性别/职业等)与商品品类语义特征(名称/类目等),采用多层感知机进行异构特征编码,输出属性增强向量  $y_a, y_i$ 。两部分构成正交互补的特征空间,为后续多模态融合提供异构特征基向量。



注:模型包括向量嵌入层、向量融合层、社会影响扩散层、头部物品与长尾物品联系层和预测层。用户部分通过社交影响扩散层提取潜在兴趣偏好,长尾物品部分通过头部物品的关联信息获得特征嵌入,最终在预测层计算用户对长尾物品的偏好评分,以提升推荐列表的新颖性和多样性。

图 2 LoSidi 模型框架图  
Fig. 2 Model framework diagram of the LoSidi

### 1.2.2 向量融合层设计

针对用户  $a$ , 通过嵌入层获取其自由嵌入表示  $p_a$  和特征向量  $y_a$ , 并将二者输入一个单层全连接网络进行融合。该网络的输出为维度  $D$  的用户融合向量  $f_a^0$ , 用于初步表征用户的兴趣偏好。具体计算如下:

$$f_a^0 = \ell(W^0 \times [p_a, y_a]), \quad (1)$$

其中  $W^0$  为可学习的权重矩阵,  $\ell(x)$  表示非线性激活函数。

对于物品  $i$  的表示学习采用类似的融合策略, 融合层提取物品的自由嵌入表示  $q_i$  与特征向量  $y_i$ , 随后通过一个单层神经网络进行特征融合。其计算过程可表示为:

$$v_i = \sigma(F \times [q_i, y_i]). \quad (2)$$

### 1.2.3 社会影响扩散层设计

本框架的社会影响扩散层采用三阶段图学习架构: 首先基于社交关系邻接矩阵构建用户社会化网络图(如图3), 通过多阶邻域采样和特征融合策略生成初始用户节点特征。

随后设计社交动态传播网络, 具体实现包含三个关键阶段: 首先将融合层输出的多维特征向量输入初始传播层; 随后构建多层特征传

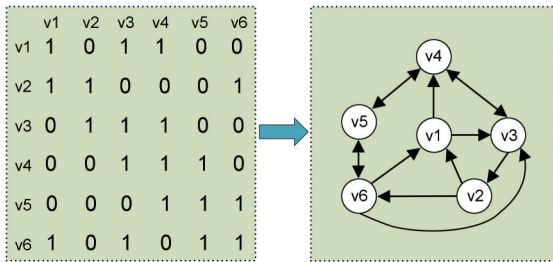


图3 用户社交矩阵转为社会化网络图

Fig. 3 User social matrix to social network diagram

播架构, 每层网络基于社交拓扑关系对上游特征进行非线性变换与邻域聚合, 生成具有社交感知能力的增强型用户特征; 最终通过迭代优化过程实现特征稳定传播, 整个过程如图4的社会影响扩散层所示。

在影响扩散过程中, 用户  $a$  在第  $k$  层的嵌入表示  $f_a^k$  会通过两个关键步骤更新到第  $k+1$  层, 其嵌入表示更新为  $f_a^{k+1}$ 。首先, 聚合(Aggregate, AGG)用户  $a$  所有可信邻居在当前第  $k$  层的影响力, 将所有社会可信邻居用户的影响整合为一个固定维度的聚合向量:

$$f_{S_a}^{k+1} = \text{Pool}(f_b^k | b \in S_a), \quad (3)$$

其中  $S_a$  表示用户  $a$  的可信用户集, Pool 函数通过聚合可信用户在第  $k$  层的潜在嵌入来实现信息整合, 既可采用平均池化计算所有嵌入的均值, 也可采用最大池化提取各维度的最大值作为聚合结果  $f_{S_a}^{k+1}$ 。

然后, 用户  $a$  的潜在嵌入  $f_a^{k+1}$  由两个核心组件构成: 继承自前序层级的本体偏好特征  $f_a^k$  以及来自社交信任邻居的影响力扩散特征  $f_{S_a}^{k+1}$ 。鉴于用户偏好与社交影响力的动态耦合关系难以显式量化, 因此采用非线性神经网络对该组合关系进行建模:

$$f_a^{k+1} = s^{k+1}(W^k \times [f_{S_a}^{k+1}, f_a^k]), \quad (4)$$

其中  $s^k(x)$  为非线性变换函数。

### 1.2.4 头部物品与长尾物品联系层设计

通过分析用户历史行为模式与长尾物品的潜在关联性, 构建适配长尾场景的特征表征。主要分为两步: 首先在嵌入模块中分别生成头部商品与长尾商品的语义向量; 随后基于向量

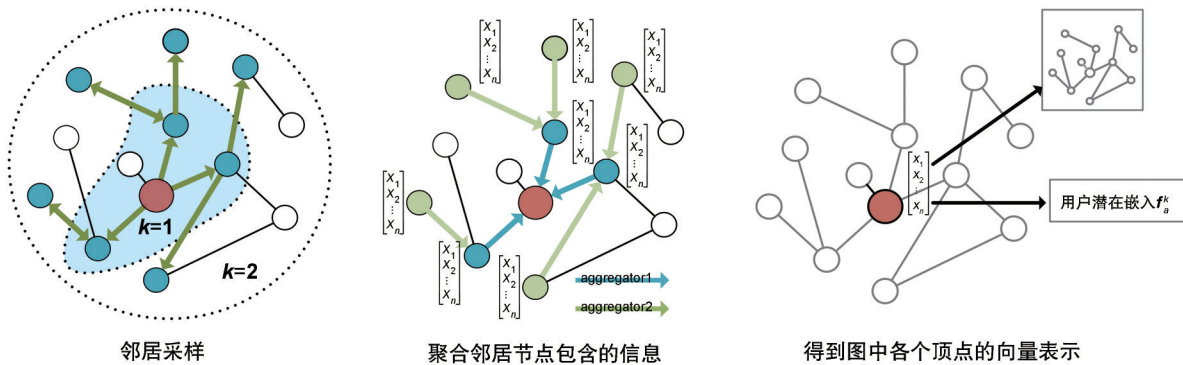


图4 用户社会影响扩散层示意图

Fig. 4 User schematic diagram of social influence diffusion layer

空间进行余弦相似性计算建立二者的跨域映射关系,计算关系式如下:

$$s(\mathbf{v}_x, \mathbf{v}_j) = \frac{\mathbf{v}_x \cdot \mathbf{v}_j}{\|\mathbf{v}_x\| \|\mathbf{v}_j\|}, x \in R_a \quad (5)$$

其中  $R_a$  表示用户  $a$  喜欢的物品集。

根据计算的相似度将长尾物品用头部物品表示,长尾物品的特征向量为  $\mathbf{v}'_j$ ,计算如下:

$$\mathbf{v}'_j = \frac{\sum_{x \in R_a} s(\mathbf{v}_x, \mathbf{v}_j) \mathbf{v}_x}{\sum_{x \in R_a} s(\mathbf{v}_x, \mathbf{v}_j)} \quad (6)$$

### 1.2.5 预测层

用户特征表示  $\mathbf{u}_a$  由双维度构成:其一是通过  $K$  层社交影响力传播网络捕获的多阶社交偏好特征  $\mathbf{f}_a^k$ ;其二是基于隐式反馈增强的历史行为特征  $\sum_{x \in R_a} \frac{\mathbf{v}_x}{|R_a|}$ ,继承经典 SVD++ 模型的协同过滤增强策略,通过用户历史交互序列缓解稀疏数据建模问题。具体而言,社交维度特征反映用户兴趣在社交网络中的多阶传播效应,而行为维度特征则聚焦用户个体行为模式的深度挖掘。最终用户特征通过特征融合模块动态整合两维度信息,形成兼具社交传播特性与个体行为特性的复合嵌入向量。计算方法如下:

$$\mathbf{u}_a = \mathbf{f}_a^k + \sum_{x \in R_a} \frac{\mathbf{v}_x}{|R_a|} \quad (7)$$

目标用户  $a$  对长尾项目  $j$  的预测偏好建模为:

$$\hat{r}_{aj} = \mathbf{v}'_j{}^T \mathbf{u}_a \quad (8)$$

### 1.3 模型训练

本文使用基于成对排名的损失函数对模型进行优化:

$$\min_{\Theta} L(\mathbf{R}, \hat{\mathbf{R}}) = \sum_{a=1}^M \sum_{(i,j) \in D_a} \sigma(\hat{r}_{ai} - \hat{r}_{aj}) + \lambda \|\Theta\|, \quad (9)$$

其中  $D_a = \{(i,j) | i \in R_a \wedge j \in V - R_a\}$  表示训练集中一对训练数据;  $\sigma(x)$  是 sigmoid 函数;  $\Theta = [\Theta_1, \Theta_2]$ , 用户和物品的自由嵌入为  $\Theta_1 = [P, Q]$ , 参数集为  $\Theta_2 = [F, [W^k]_{k=0}^{K-1}]$ ; 正则化系数  $\lambda$  用于调控用户和物品自由嵌入矩阵的稀疏性,平衡模型表达能力与泛化性能。

### 1.4 算法及复杂度分析

LoSidi 算法的主要步骤如算法 1 所示。假设用户总数为  $M$ 、扩散深度为  $K$ 、每个用户的平

均社会邻居数为  $L$ 、物品数为  $N$ 。步骤 1、2 均需提取用户和物品的相关嵌入向量,其时间复杂度均为  $O(M+N)$ 。步骤 3 将用户的嵌入向量与物品的特征向量融合,时间复杂度同样为  $O(M+N)$ 。步骤 4 社会影响扩散需遍历所有用户及其社会邻居,因此时间复杂度为  $O(MKL)$ 。步骤 7 基于步骤 6 生成的用户潜在特征表示和步骤 5 提取的长尾物品特征向量计算预测评分,时间复杂度为  $O(MN)$ 。实验结果显示 LoSidi 在  $K=2$  时达到最佳性能,综合分析后,算法的总时间复杂度为  $O(MKL) + O(MN)$ 。

#### 算法 1 LoSidi 算法

输入:用户-物品评分矩阵  $\mathbf{R}$ ; 用户属性特征矩阵  $\mathbf{U}$ ; 物品属性特征矩阵  $\mathbf{I}$ ; 用户社交矩阵  $\mathbf{T}$ ;

输出:用户对长尾物品的预测评分  $\hat{r}_{aj}$ 。

(1) 从矩阵  $\mathbf{R}$  中获取用户  $a$ 、头部物品  $i$  和长尾物品  $j$  的自由嵌入向量  $\mathbf{p}_a, \mathbf{q}_i, \mathbf{q}_j$ ;

(2) 从矩阵  $\mathbf{U}, \mathbf{I}$  中获得用户和物品的特征向量  $\mathbf{y}_a, \mathbf{y}_i, \mathbf{y}_j$ ;

(3) 根据式(1)和式(2)将嵌入向量与特征向量进行融合;

(4) 社会影响扩散:将社交矩阵  $\mathbf{T}$  转化为社会化网络图,通过采样、聚合得到用户潜在嵌入向量  $\mathbf{f}_a^k$ ;

(5) 根据式(6)得到长尾物品的特征向量  $\mathbf{v}'_j$ ;

(6) 由用户潜在嵌入向量  $\mathbf{f}_a^k$  和历史行为偏好根据式(7)得到用户的最终潜在特征表示  $\mathbf{u}_a$ ;

(7) 根据式(8)得到目标用户  $a$  对长尾物品  $j$  的预测评分  $\hat{r}_{aj}$ 。

## 2 实验结果与分析

### 2.1 实验数据集

实验数据集需包含评分数据和社交数据,因此本文选用社交推荐常用的数据集 Epinions、FilmTrust 以及 Flixster 的两个子集。数据集的基本信息如表 1 所示。

实验中,基于用户行为频次指标将物品库划分为两类:高频交互物品(Top-20% 用户行为覆盖度)界定为头部物品集,低频交互物品

(剩余 80%) 界定为长尾物品集。并采用标准的数据划分方案,将原始数据集按 9:1 的比例划分为训练集(90%)和测试集(10%),为优化模型参数,训练集中进一步划分出 10% 作为验证集。

表 1 数据集信息

Table 1 Information of datasets

| 数据集       | 用户数     | 物品数     | 评分数       | 社交数       |
|-----------|---------|---------|-----------|-----------|
| Epinions  | 40 163  | 139 738 | 664 824   | 487 183   |
| FilmTrust | 1 508   | 2 071   | 35 497    | 1 853     |
| Flixster1 | 787 213 | 48 794  | 8 196 077 | 7 058 819 |
| Flixster2 | 69 251  | 17 318  | 7 940 096 | 967 195   |

## 2.2 对比算法

为验证本文方法对长尾推荐的有效性,选择常用对比方法 SoRec<sup>[10]</sup>、SoReg<sup>[12]</sup>、TrustSVD<sup>[18]</sup>、RIITD (Recommendation Model Combining Implicit Influence of Trust with Trust Degree)<sup>[22]</sup>与本文方法进行比较。这些方法都利用了社交信息处理推荐问题,其特点如下。

**SoRec 模型:**通过双矩阵协同分解框架,创新性地将用户-商品交互矩阵与社交信任图谱进行联合矩阵分解。其核心在于构建共享潜在用户空间。

**SoReg 模型:**创新性地将社交信任关系转化为正则化项,要求活跃用户的特征向量与其可信邻居的平均特征保持接近,从而构建了新的矩阵分解框架。

**TrustSVD 模型:**扩展了 SVD++ 算法,将社交网络中的显式信任关系作为隐式反馈信息,直接整合到推荐模型的构建过程中。

**RIITD 模型:**融合了信任关系的显性和隐性影响,并引入信任度衡量不同用户对目标用户的影响。

## 2.3 评价指标

本文从推荐系统的新颖性、多样性和预测精度三个方面评测算法的性能。

**Novelty 指标 ( $N$ )**旨在评估推荐列表的未知物品发现能力,其量化标准为推荐物品与用户历史交互物品集的差异性,定义如下:

$$p(i|s) = \frac{|\{u \in U | i \in L_u\}|}{\sum_{j \in I} |\{u \in U | j \in L_u\}|},$$

$$N = - \sum_{i \in I} p(i|s) \log 2p(i|s), \quad (10)$$

其中  $L_u$  是为用户  $u$  提供的推荐列表。 $p(i|s)$  表示从推荐系统  $s$  生成的所有推荐列表中提取第  $i$  项的概率。

**Diversity** 是另一个重要的度量方法,用于评估推荐给用户的项目之间的差异程度。其定义如下:

$$D = \frac{\sum_{u=1}^{|U|} d_u}{|U|},$$

$$d_u = \frac{1}{|L_u|(|L_u| - 1)} \sum_{i \in L_u} \sum_{j \in L_u, j \neq i} [1 - s(i, j)], \quad (11)$$

其中  $L_u$  是为用户  $u$  提供的推荐列表,  $s(i, j)$  是推荐项目列表中两个项目之间的余弦相似度。

推荐精度用常用指标 MAE ( $M_{\text{mae}}$ )、RMSE ( $R_{\text{rmse}}$ )、Precision 和 Recall 评测。定义如下:

$$R_{\text{rmse}} = \sqrt{\frac{1}{|N|} \sum_{u,i} (\hat{r}_{u,i} - r_{u,i})^2}, \quad (12)$$

$$M_{\text{mae}} = \frac{1}{|N|} \sum_{u,i} |\hat{r}_{u,i} - r_{u,i}|, \quad (13)$$

其中  $N$  为测试集评级数量。 $RMSE$  和  $MAE$  数值越小表明预测精度越高。

**准确率 (Precision)** 指标量化推荐列表中正样本的占比,反映预测结果的精确程度; **Recall** 指标衡量实际相关物品被成功召回的比例,表征推荐覆盖的完备性。具体而言, Precision ( $P_{\text{pre}}$ ) 计算为正确推荐数占推荐总数的比值, Recall ( $R_{\text{rec}}$ ) 则计算为正确推荐数占实际相关物品总数的比值。具体公式如下。

$$P_{\text{pre}} = \frac{\sum_{i=1}^N |R(i) \cap T(i)|}{\sum_{i=1}^N |R(i)|}, \quad (14)$$

$$R_{\text{rec}} = \frac{\sum_{i=1}^N |R(i) \cap T(i)|}{\sum_{i=1}^N |T(i)|}. \quad (15)$$

## 2.4 实验结果与分析

实验在 LENOVO 台式机上进行,硬件配置包含 Intel Core i7-6700 处理器(基频 3.4 GHz,四核八线程架构)及 16 GB DDR4 2 400 MHz 内存配置,软件环境基于 Python 3.7 解释器搭建。

### 2.4.1 嵌入向量维数 $D$ 对算法性能的影响

为评估嵌入向量维数与模型效率的平衡关系,实验在固定传播深度( $K=3$ )条件下,比较不同嵌入维度( $D \in \{16, 32, 64\}$ )的性能表现。如表2所示,随着嵌入维度增加,模型在各评估指标上呈现渐进式提升趋势。实验结果表明,更高维度的特征空间能够有效捕获用户与商品间细粒度的语义关联,提升头尾商品相似度计算的准确性。然而,考虑到模型训练的计算复杂度与存储资源消耗,最终选定 $D=64$ 作为性能与效率的最优平衡点。

表2 不同嵌入向量维数对算法性能的影响

Table 2 The impact of different dimension sizes on the algorithm's performance

| 数据集       | 维数 $D$ | Novelty | Diversity | MAE   | RMSE  |
|-----------|--------|---------|-----------|-------|-------|
| FilmTrust | 16     | 6.023   | 0.169     | 0.669 | 0.864 |
|           | 32     | 6.867   | 0.234     | 0.660 | 0.856 |
|           | 64     | 7.004   | 0.302     | 0.651 | 0.843 |
| Epinions  | 16     | 8.569   | 0.385     | 0.882 | 1.131 |
|           | 32     | 8.783   | 0.441     | 0.869 | 1.125 |
|           | 64     | 8.896   | 0.489     | 0.859 | 1.119 |
| Flixster1 | 16     | 6.549   | 0.531     | 0.765 | 1.132 |
|           | 32     | 6.624   | 0.596     | 0.754 | 1.079 |
|           | 64     | 6.773   | 0.656     | 0.733 | 1.024 |
| Flixster2 | 16     | 6.591   | 0.259     | 0.771 | 1.145 |
|           | 32     | 6.630   | 0.296     | 0.759 | 1.086 |
|           | 64     | 6.779   | 0.386     | 0.787 | 1.108 |

### 2.4.2 扩散深度 $K$ 对算法性能的影响

社交影响力的扩散深度 $K$ 直接影响用户特征的学习过程。在固定 $D=64$ 条件下,实验对比分析不同扩散层级( $K \in \{1, 2, 3\}$ )的性能差异。如表3所示,当 $K=2$ 时模型达到最优性能状态,其核心机理在于:

(1)单层扩散( $K=1$ )仅能捕获直接社交关联,无法建模跨社群的信息扩散路径;

(2)深层扩散( $K \geq 3$ )会导致社交信号衰减效应,高阶邻居的语义贡献度显著降低;

(3)双层扩散( $K=2$ )在社交影响力覆盖范围与噪声控制间取得最优平衡。据此将传播深度设定为 $K=2$ 。

### 2.4.3 新颖性比较

新颖性 Novelty 指标对比结果如图5所示,这是长尾推荐最重要的指标之一。从图中可以看出本文的方法在新颖性指标上优于其他方法

且提升幅度很大。这是由于对比模型大多基于用户社交好友喜欢的物品或用户已交互的物品进行推荐,导致新颖性较差。而本文模型旨在挖掘长尾物品集合与用户已交互的头部物品的相似性,并将社交影响融入推荐系统,显著提高了推荐集的新颖性,给用户带来新鲜感。

表3 不同扩散深度对算法性能的影响

Table 3 The impact of different diffusion depths on the algorithm's performance

| 数据集       | 扩散深度 $K$ | Novelty | Diversity | MAE   | RMSE  |
|-----------|----------|---------|-----------|-------|-------|
| FilmTrust | 1        | 6.546   | 0.232     | 0.654 | 0.860 |
|           | 2        | 7.102   | 0.305     | 0.645 | 0.830 |
|           | 3        | 6.764   | 0.288     | 0.661 | 0.854 |
| Epinions  | 1        | 8.643   | 0.405     | 0.871 | 1.124 |
|           | 2        | 8.945   | 0.506     | 0.851 | 1.105 |
|           | 3        | 8.759   | 0.483     | 0.869 | 1.116 |
| Flixster1 | 1        | 6.597   | 0.685     | 0.801 | 1.112 |
|           | 2        | 6.874   | 0.732     | 0.721 | 0.985 |
|           | 3        | 6.769   | 0.709     | 0.787 | 1.103 |
| Flixster2 | 1        | 6.610   | 0.311     | 0.809 | 1.118 |
|           | 2        | 6.874   | 0.398     | 0.723 | 0.991 |
|           | 3        | 6.788   | 0.369     | 0.797 | 1.113 |

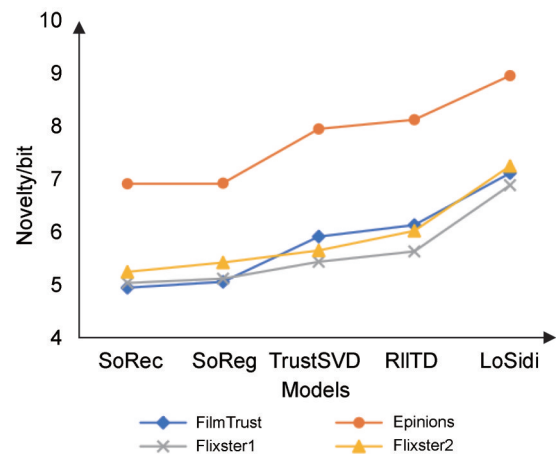


图5 LoSidi与其他模型在新颖性 Novelty 的表现

Fig. 5 The performance of LoSidi and other models on the Novelty

### 2.4.4 多样性比较

多样性 Diversity 指标对比结果如图6所示,从图中可以看出本文模型的多样性明显优于其他模式。通过提升推荐结果的多样性,系统能够在促进用户探索行为的同时,更有效地捕获其隐含的兴趣维度。其他模型在召回阶段仅考虑用户的兴趣标签导致多样性较差,本文模型考虑用户兴趣

标签、属性信息、热门物品、长尾物品、社交信息多路召回保证更多样的内容可以进入后续阶段,显著提高了推荐系统的多样性。

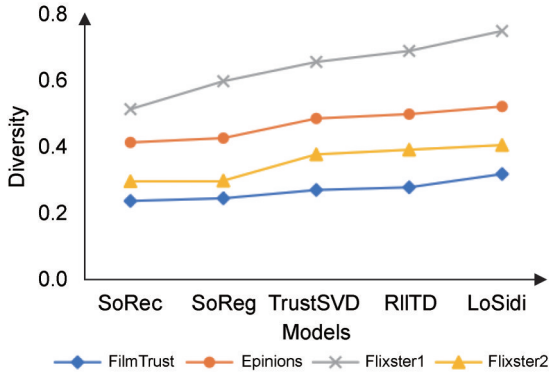


图6 LoSidi与其他模型在多样性Diversity的表现


Fig. 6 The performance of LoSidi and other models on the Diversity

2.4.5 推荐精度比较

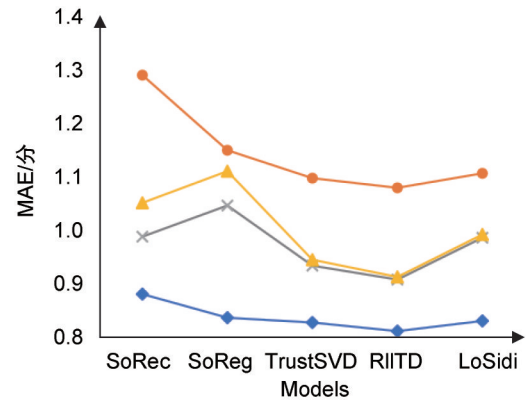
图7(a)和图7(b)的评估指标对比显示,本模型在MAE与RMSE指标上虽略逊于

TrustSVD和RIITD,但显著优于传统社交推荐方法SoRec与SoReg。具体而言,TrustSVD通过双向反馈机制(显式评分与隐式行为)及偏差修正项实现精准评分预测;RIITD进一步考虑双重反馈对评分预测的影响,在误差控制方面展现出理论优势。但本文主要聚焦长尾场景优化,由于长尾商品存在特征稀疏性,在绝对误差指标上存在固有挑战,但通过社交影响力的递归扩散机制,在用户特征学习方面优于传统推荐方。


图7(c)一图7(d)的Top-10推荐评估表明,本方法的推荐精度Precision与TrustSVD保持相当,在Epinions与Flixster数据集上的召回率Recall指标仅次于RIITD。这验证了本框架在长尾推荐场景下的双重优势:1)通过跨域特征迁移保持推荐有效性,缓解长尾商品曝光不足问题;2)融合社交网络的扩散影响与历史行为,避免传统社交推荐方法中常见的过度传播偏差。实验结果表明,在引入长



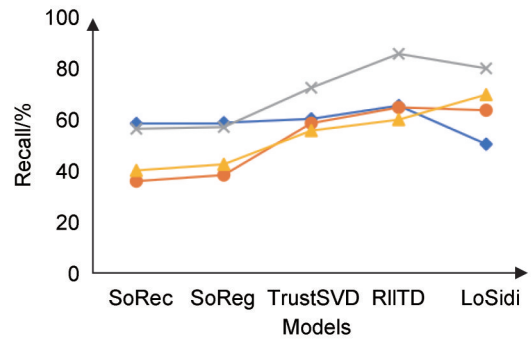
(a) Results of MAE



(b) Results of RMSE



(c) Results of Precision



(d) Results of Recall

图7 LoSidi与其他模型在四种评估指标上的实验结果比较

Fig. 7 The experimental results comparing LoSidi with other models across four evaluation metrics

尾优化策略的同时,模型未显著牺牲核心推荐指标的表现。

### 3 结论

本文提出融合社会影响扩散的长尾推荐模型,其核心创新在于:1)构建动态传播网络,建模社交影响力的多阶扩散过程,同步融合用户历史交互特征实现兴趣演化建模;2)设计跨域特征迁移策略,通过计算头部商品与长尾商品的语义相似度,建立特征映射通道以增强长尾表征。实验表明,该方法在保持推荐精度的同时,显著提升长尾商品曝光率,推荐列表的新颖性和多样性。

未来研究将深入探索用户兴趣的动态演化机制,重点建模评分行为扩散与社交网络传播的协同效应,拟通过时序图卷积网络捕捉多源信号的耦合关系,进一步提升长尾场景下的用户表征学习能力。

#### 参考文献:

- [1] BRYNJOLFSSON E, HU Y, SIMESTER D. Goodbye Pareto Principle, Hello Long Tail: The Effect of Search Costs on the Concentration of Product Sales[J]. *Management Science*, 2011, **57**(8): 1373–1386. DOI: 10.1287/mnsc.1110.1371.
- [2] 雷钦岚, 田萱. 基于流行的推荐研究综述[J]. *计算机科学与探索*, 2024, **18**(5): 1109–1134. DOI: 10.3778/j.issn.1673-9418.2309016.  
LEI Q L, TIAN X. Survey on Popularity Based Recommendation[J]. *J Front Comput Sci Technol*, 2024, **18**(5): 1109–1134. DOI: 10.3778/j.issn.1673-9418.2309016.
- [3] SHI Y, LARSON M, HANJALIC A. Collaborative Filtering beyond the User-item Matrix[J]. *ACM Comput Surv*, 2014, **47**(1): 1–45. DOI: 10.1145/2556270.
- [4] VALCARCE D, PARAPAR J, BARREIRO Á. Item-based Relevance Modelling of Recommendations for Getting Rid of Long Tail Products[J]. *Knowl Based Syst*, 2016, **103**: 41–51. DOI: 10.1016/j.knosys.2016.03.021.
- [5] OESTREICHER-SINGER G, SUNDARARAJAN A. Recommendation Networks and the Long Tail of Electronic Commerce[J]. *MIS Quarterly*, 2012, **36**(1): 65–83. DOI: 10.2139/ssrn.1324064.
- [6] HE H B, GARCIA E A. Learning from Imbalanced Data [J]. *IEEE Trans Knowl Data Eng*, 2009, **21**(9): 1263–1284. DOI: 10.1109/TKDE.2008.239.
- [7] CUI Y, JIA M L, LIN T Y, *et al.* Class-balanced Loss Based on Effective Number of Samples[C]//2019 IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR). New York: IEEE, 2019: 9260–9269. DOI: 10.1109/CVPR.2019.00949.
- [8] ZHANG Y, CHENG D Z, YAO T S, *et al.* A Model of Two Tales: Dual Transfer Learning Framework for Improved Long-tail Item Recommendation[C]//Proceedings of the Web Conference 2021. New York: ACM, 2021: 2220–2231. DOI: 10.1145/3442381.3450086.
- [9] YIN H Z, CUI B, LI J, *et al.* Challenging the Long Tail Recommendation[J]. *Proc VLDB Endow*, 2012, **5**(9): 896–907. DOI: 10.14778/2311906.2311916.
- [10] MA H, KING I, LYU M R. Learning to Recommend with Social Trust Ensemble[C]//Proceedings of the 32nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2009: 203–210. DOI: 10.1145/1571941.1571978.
- [11] MA H, KING I, LYU M R. Learning to Recommend with Social Trust Ensemble[C]//Proceedings of the 32nd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: Association for Computing Machinery, 2009: 203–210. DOI: 10.1145/1571941.1571978.
- [12] MA H, ZHOU D Y, LIU C, *et al.* Recommender Systems with Social Regularization[C]//Proceedings of the Fourth ACM International Conference on Web Search and Data Mining. New York: ACM, 2011: 287–296. DOI: 10.1145/1935826.1935877.
- [13] JAMALI M, ESTER M. A Matrix Factorization Technique with Trust Propagation for Recommendation in Social Networks[C]//Proceedings of the Fourth ACM Conference on Recommender Systems. New York: ACM, 2010: 135–142. DOI: 10.1145/1864708.1864736.
- [14] YANG B, LEI Y, LIU J M, *et al.* Social Collaborative Filtering by Trust[J]. *IEEE Trans Pattern Anal Mach Intell*, 2017, **39**(8): 1633–1647. DOI: 10.1109/TPAMI.2016.2605085.
- [15] TANG J L, HU X, GAO H J, *et al.* Exploiting Local and Global Social Context for Recommendation[C]// Proceedings of the Twenty-Third International Joint Conference on Artificial Intelligence. Beijing: AAAI Press, 2013: 2712–2718. DOI: 10.5555/2540128.2540519.
- [16] GUO G B, ZHANG J. TrustSVD: Collaborative Filtering with Both the Explicit and Implicit Influence of User Trust and of Item Ratings[C]//Proceedings of the Twenty-Ninth AAAI Conference on Artificial Intelligence. Menlo Park: Press, 2015, **29**(1): 123–129. DOI:

- 10.1609/aaai.v29i1.9153.
- [17] KOREN Y. Factorization Meets the Neighborhood: A Multifaceted Collaborative Filtering Model[C]//Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2008: 426–434. DOI: 10.1145/1401890.1401944.
- [18] YAO W L, HE J, HUANG G Y, *et al.* Modeling Dual Role Preferences for Trust-Aware Recommendation[C]//Proceedings of the 37th International ACM SIGIR Conference on Research & Development in Information Retrieval. New York, USA: Association for Computing Machinery, 2014: 975–978. DOI: 10.1145/2600428.2609488.
- [19] WU L, SUN P, FU Y, *et al.* A Neural Influence Diffusion Model for Social Recommendation[C]//Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. Paris, France: ACM, 2019: 235–244. DOI: 10.1145/3331184.3331214.
- [20] HAMILTON W, YING Z, LESKOVEC J. Inductive Representation Learning on Large Graphs[C]//Advances in Neural Information Processing Systems. Long Beach, California, USA: Curran Associates, Inc., 2017: 1024–1034. DOI: 10.48550/arXiv.1706.02216.
- [21] FAN W, MA Y, LI Q, *et al.* Temporal Graph Neural Networks for Social Recommendation[C]//Proceedings of the 2020 IEEE International Conference on Big Data (Big Data). Atlanta, GA, USA: IEEE, 2020: 437–446. DOI: 10.1109/BigData50022.2020.9378444.
- [22] 张滨淇, 任丽芳, 王文剑. 融合信任隐性影响和信任度的推荐模型[J]. 模式识别与人工智能. 2022, **35**(4): 374–385. DOI: 10.16451/j.cnki.issn1003-6059.202204007.
- ZHANG B Q, REN L F, WANG W J. Recommendation Model Combining Implicit Influence of Trust with Trust Degree[J]. *Pattern Recognit Artif Intell.* 2022, **35**(4): 374–385. DOI: 10.16451/j.cnki.issn1003-6059.202204007.