

基于解耦图神经网络的可解释标签感知推荐算法*

杜晓宇, 陈正, 项欣光

(南京理工大学 计算机科学与工程学院, 江苏 南京 210094)

通信作者: 项欣光, E-mail: xgxiang@njust.edu.cn



摘要: 标签感知推荐算法利用标签标注数据提升推荐模型对用户偏好和项目属性的理解, 受到业界的广泛关注。但是, 现有方法常忽视了用户关注点、项目属性和标签含义的多样性, 干扰了三者关系推断, 从而影响推荐结果。因此, 提出一种基于解耦图神经网络的可解释标签感知推荐算法 (DETRec), 解构用户、项目和标签的关注角度, 并由此形成可解释的推荐依据。具体来讲, DETRec 构造关系图以建模用户、项目和标签的关系; 通过邻域路由机制和消息传播机制, 分离结点形成属性子图, 以描述不同属性下的结点关系; 最终根据属性子图形成推荐依据。实现了两种 DETRec 实例: 单图实例 (DETRec-S) 在单个关系图中描述全部结点关系; 多图实例 (DETRec-M) 使用 3 个二分图分别描述用户-项目、项目-标签、用户-标签关系。在 3 个公开数据集上进行的大量实验表明, DETRec 的两种实例均明显优于标签感知推荐的基准模型, 也为推荐结果生成了对应的推荐依据, 是有效的可解释标签感知推荐算法。

关键词: 多媒体推荐; 标签感知推荐; 可解释推荐; 特征解耦; 图神经网络

中图法分类号: TP18

中文引用格式: 杜晓宇, 陈正, 项欣光. 基于解耦图神经网络的可解释标签感知推荐算法. 软件学报, 2023, 34(12): 5670–5685. <http://www.jos.org.cn/1000-9825/6754.htm>

英文引用格式: Du XY, Chen Z, Xiang XG. Explainable Tag-aware Recommendation Based on Disentangled Graph Neural Network. Ruan Jian Xue Bao/Journal of Software, 2023, 34(12): 5670–5685 (in Chinese). <http://www.jos.org.cn/1000-9825/6754.htm>

Explainable Tag-aware Recommendation Based on Disentangled Graph Neural Network

DU Xiao-Yu, CHEN Zheng, XIANG Xin-Guang

(School of Computer Science and Engineering, Nanjing University of Science and Technology, Nanjing 210094, China)

Abstract: Tag-aware recommendation algorithms use tagged data to enhance the recommendation models' understanding of user preferences and item attributes, which attract extensive attention in the field. Most existing methods, however, neglect the diversities of user concerns, item attributes, and tag semantics and interfere with the correlation inference of the three, which affects the recommendation results. Therefore, this study introduces the disentangled graph neural network (DGNN) method into the tag-aware recommendation task and proposes a DGNN-based explainable tag-aware recommendation (DETRec) method. It disentangles the perspectives of users, items, and tags to provide explainable recommendation references. Specifically, DETRec utilizes a correlation graph construction module to model the user-item-tag correlations. Then, it employs a neighborhood routing mechanism and a message propagation mechanism to disentangle the nodes to form the sub-graphs of attributes and thereby describe the nodal correlations under different attributes. Finally, it generates recommendation references on the basis of these attribute sub-graphs. This study implements two types of DETRec instantiation: 1) DETRec based on a single graph (DETRec-S), which describes all correlations of user, item, and tag nodes in a single graph, and 2) DETRec based on multiple graphs (DETRec-M), which utilizes three bipartite graphs to describe the user-item, item-tag, and user-tag correlations separately. Extensive experiments on three public datasets demonstrate that the above two types of DETRec instantiation are significantly superior to the baseline model and generate the references corresponding to the recommendation results. Hence, DETRec is an effective explainable tag-aware recommendation algorithm.

* 基金项目: 国家自然科学基金 (62172226); 江苏省“双创博士”人才计划 (JSSCBS20210200)

收稿时间: 2022-01-21; 修改时间: 2022-06-11; 采用时间: 2022-07-25; jos 在线出版时间: 2023-02-15

CNKI 网络首发时间: 2023-02-16

Key words: multimedia recommendation; tag-aware recommendation; explainable recommendation; embedding disentanglement; graph neural network (GNN)

随着互联网和社交平台的普及, 微博、抖音、推特、问答社区等社交平台构成了丰富的信息传递纽带. 人们热衷于在平台上制作和分享包含图像、音频、视频、商品在内的各种项目. 为了方便用户管理和维护项目, 各社交平台加入了标签功能, 使用户能够为项目定义语义描述和分类. 标签通常为词语或短语, 是用户对项目的关注点, 也是项目某个角度的特性^[1]. 因此, 将用户标签引入到推荐系统中, 有助于提取用户偏好和项目特性. 由此形成了一类标签感知的推荐算法, 受到了广泛的关注^[2].

协同过滤是推荐系统中重要的解决方案^[3,4], 在标签感知推荐中发挥着重要的作用. 将标签作为用户和项目的一种特征, 引入到协同过滤方法中, 即可形成标签感知推荐模型. CFA^[5]将用户使用的标签集转变为输入向量, 然后通过自编码器进行降维, 作为用户的潜在嵌入表示; DSPR^[6]利用 MLP 提取标签集的抽象语义信息, 作为用户和项目的特征表示. 此类引入标签信息的方法, 虽然能够取得不错的效果, 却容易遭受引入标签导致的稀疏性、一词多义、多词同义等问题. 为了解决这些问题, TGCN^[7]将当前热门的图神经网络引入到该领域, 利用消息传播机制探索结点的高阶连接, 通过结点的上下文环境丰富结点信息, 取得了目前最好的性能.

但是, 这些方法简单的将用户、项目、标签汇聚在一起, 忽略了真实情况中三者具有的多重属性. 实践中, 不同的用户会从不同的角度关注项目, 由此构成了多样性. 以图 1 所示的电影标签为例, 用户 1 对电影“千与千寻”和“七武士”的关注源于导演, 而对“惊魂记”和“指环王 3”的关注是因为电影的类型; 用户 2 更关注电影质量. 由此可知, 在标签感知推荐中, 需要关注用户关注点、项目属性和标签含义的多样性. 特别是在图模型中, 如果不加以区分结点和边之间的关联, 以结点的整体特征为单位进行传播, 则会忽视用户关注项目的角度, 影响到消息传播效果.




图 1 用户关注点的差异性展示

针对上述问题, 本文在标签感知推荐中引入特征解耦方法, 提出一种基于解耦图神经网络的可解释标签感知推荐模型 (disentangled GNN-based explainable tag-aware recommendation model, DETRec), 通过区分关注角度, 细化标签感知推荐过程, 提升推荐效果的同时, 为模型推荐结果提供推荐依据. 该算法主要由关系图构建模块与消息传播模块构成. 关系图构建模块以关系图描述用户、项目和标签的关系, 其中图的结点表示 3 类实体, 边表示实体间的关系; 消息传播模块使用多块的嵌入表示描述结点, 以表示结点的多重属性信息, 在其上使用邻域路由机制和消息传播机制, 逐层优化结点的表示. 本文设计两种关系描述方式: 1) 将全部结点放到一个图中, 表示为单个复杂关系图; 2) 将结点按照用户-项目、项目-标签、用户-标签, 划分, 构造出 3 个二分图. 相应的调整消息传播模块的实现, 最终形成单图与多图两组实例. 在 3 个公开数据集上进行的大量对比实验显示, 提出的算法在多个 top-N 推荐性能指标上明显优于标签感知推荐的基准模型, 反映了算法的有效性. 同时, 实验中也展示了可解释推荐结果, 证明通过标签的语义信息, 能够为推荐结果提供可解释推荐依据.

综上, 本文的贡献如下.

(1) 针对标签感知推荐中广泛存在的用户关注多样性、项目属性多样性、标签语义多样性, 提出一种基于解耦图神经网络的可解释标签感知推荐算法, 通过解耦用户、项目和标签的特征, 实现精细化的标签感知推荐.

(2) 针对标签感知推荐结果的可解释性, 在特征解耦的基础上, 利用标签本身的语义信息, 描述模型的推荐结果, 实现可解释的推荐模型.

(3) 在 3 个公开数据集上设计大量对比实验, 验证了特征解耦对标签感知推荐的改进效果, 展示了模型结果的

推荐依据,证明了所提的可解释标签感知推荐算法的有效性.

本文第 1 节介绍标签感知推荐领域和图卷积推荐算法的研究现状,第 2 节提出基于解耦神经网络的可解释标签感知推荐算法,第 3 节通过对比实验验证所提模型的有效性和可解释性,第 4 节总结全文并提出展望.

1 相关工作

1.1 标签感知推荐

随着大众分类在各种社交网站平台的普及,大量用户为各种资源标注了大量的标签,致使大量研究者开始将这些标签应用到各个领域.如为了便于用户更好地为资源标注标签,标签推荐^[8,9]利用各种神经网络模型对用户-资源-标签三者的关系建模,实现为特定用户发布的资源推荐个性化的标签.另一方面,标签也可以作为一种额外资源,能够很好地描述用户或项目的信息.因此基于标签的项目推荐算法受到了大量的关注,这类算法大多将标签视为一种基本描述信息,利用基于标签的 multi-hot 向量表示用户或项目,然后通过诸如 MLP 等模型进行特征压缩后作为用户或项目的表示.如 HDLPR^[10]通过深度神经网络将基于标签的向量映射到抽象语义空间中,使得用户和与他交互过的项目的抽象语义尽可能相似.CFA^[5]利用抽象语义得到 k 个相似用户,以相似用户的偏好的加权求和作为用户的偏好.TNAM^[11]认为不同用户对项目有不同的兴趣,引入了注意力机制.随着图神经网络 (graph neural networks, GNN) 的兴起,大量研究者将各种图神经网络引入到了标签感知推荐领域中^[12,13].如 TGCN^[7]构建了基于用户-项目-标签的异质图,然后在图上进行图卷积以便获取高阶的邻域信息,使得推荐性能取得了较大提升.一定程度上解决了标签自身的稀疏性和重复性问题,但其忽略了用户、项目、标签都具有的多重属性问题,将多重信息耦合进整体表示中,无法为用户提供更细粒度的推荐,导致了性能无法达到最优.

1.2 基于图的推荐模型

用户与项目的交互历史是推荐模型极为重要的数据支撑^[14,15].由于交互历史天生具有图结构^[16],能够从图结构构建模型,因而大量图模型被引入到推荐算法中^[17],用以捕获结点连接和精炼特征.图模型利用结点间的消息传播机制,编码图的结构信息和结点的邻域信息,从而实现结点信息扩展和图结构信息提取.NGCF^[18]将用户项目交互间的信息称为协同信号,令其在用户与项目的交互图上进行消息传播,建模交互图中高阶连接信息.LightGCN^[19]提出图卷积中的特征变换和非线性激活函数会降低模型的推荐性能,因而改进卷积模块以消息其影响,获得了目前最好的性能.这也暗合了图卷积在更深更简单上的研究^[20,21].为了降低交互数据稀疏特性的影响,MMGCN^[22]用项目自身的多媒体信息特征替代自由嵌入表示.KGAT^[23]引入知识图谱补充项目属性信息,由此构成协同知识图,丰富结点间的连接.此外,交互图也可扩展为具有多种类型结点和关系的异质图卷积模型^[24].

考虑到真实世界的关系源于多种复杂的因素,DisenGCN^[25]提出了针对图的解耦算法,其基本思想着眼于邻域路由机制:1)由同一种因素导致的邻域结点集合,集合里的结点在此因素上彼此应该相似;2)中心结点与某一邻域结点在导致两者连接的因素上应该相似.然后利用迭代的方式交替执行邻域路由和消息传播,达到解耦的目的.显然,用户和项目在多个方面具有不同的信息特征,交互也是因为多重因素导致的.基于该理念,DGCF^[26]解耦交互图形成多个属性子图,每个子图反映一类属性关系,从而在属性级描述结点性质.DisenHAN^[27]对异质图中的各种关系进行了多方面的解耦,使模型能够自动识别各关系在各方面上消息传播的权重,得到具有语义信息的 meta-path.因此,考虑到标签感知推荐中天然存在的标签类别和其语义特性,本文将解耦思想引入到标签感知推荐算法中,设计可解释的标签感知推荐模型.

2 方法

2.1 问题定义

在标签感知推荐场景中,假设存在 N_u 个用户组成的用户集合 $U = \{u_1, u_2, \dots, u_{N_u}\}$, N_i 个项目组成的项目集合 $I = \{i_1, i_2, \dots, i_{N_i}\}$, N_t 个标签组成的标签集合 $T = \{t_1, t_2, \dots, t_{N_t}\}$, 则用户标签标注记录可表示为 $A = \{(u, i, t) | u \in U, i \in I, t \in T\}$, 其中每条记录 (u, i, t) , 表示用户 u 交互过项目 i 后给其标注了标签 t . 由此可以获得用户-项目的交互矩阵 $A_{UI} =$

$\mathbb{R}^{N_u \times N_i}$, 其中的元素含义为: 如果用户 u 交互过项目 i , 则 $A_{UI}(u, i) = 1$, 否则为 0. 类似的, 用户-标签关系矩阵表示为 $A_{UT} = \mathbb{R}^{N_u \times N_t}$, 项目-标签关系矩阵表示为 $A_{IT} = \mathbb{R}^{N_i \times N_t}$. 针对真实世界中用户偏好, 项目特征和标签含义的多样性, 模型有必要解耦结点的多重属性特征, 形成更准确的结点描述. 因此, 本文深度挖掘用户标签标注历史, 建模用户、项目、标签学习解耦的多重特征表示, 改良推荐结果并生成可解释推荐依据. 为了方便读者理解, 表 1 汇总了本文涉及的主要符号.

表 1 本文主要符号说明

符号	含义	符号	含义
u, i, t	用户, 项目, 标签	U, I, T	用户, 项目, 标签组成的集合
N_u, N_i, N_t	用户、项目、标签的数量	A_{UI}, A_{UT}, A_{IT}	UI, UT, IT 对应的交互矩阵
$G_{UIT}, G_{UI}, G_{UT}, G_{IT}$	UIT, UI, UT, IT 构成的关系图	l, j, k	当前的卷积层数、迭代次数、属性编号
$\psi(\cdot)$	包含结点的关系子图个数	L, T, K	总的卷积层数、迭代次数、属性个数
$e_{x,k}^{(l)}$	结点 x 在第 k 个属性, 第 l 层上的嵌入表示	$p^{(j)}(x,y)_k$	$\langle x, y \rangle$ 在第 j 次迭代第 k 个属性的权重

2.2 标签表征解耦模型

解耦神经网络在推荐领域已经发挥出巨大的能量^[26]. 受其启发, 本文提出了基于解耦图神经网络的可解释标签感知推荐模型 (DETRec), 以实现在标签感知推荐中, 精准的描述用户、项目、标签中的复杂关联. 该模型包含两个主要模块: 关系图构建模块与消息传播模块, 如图 2 所示. 关系图构建模块以用户标注集合 A 为输入, 将其转化为适合的图结构, 输入到消息传播模块中; 消息传播模块然后将关系图划分为属性相关的子图, 并利用消息传播机制扩展用户、项目和标签结点各属性方面的嵌入表示, 最终利用扩展的用户和项目的嵌入表示进行匹配预测, 并使用经典 BPR^[28]模型进行优化训练. 特别的, 通过设计不同的关系图构建方式, 本文实现两套推荐方案, 分别定义为单图模型 (DETRec on single-graph) 与多图模型 (DETRec on multi-graph), 分别简称为 DETRec-S 和 DETRec-M. 接下来, 本文将从关系图构建、消息传播模块、模型训练和可解释依据生成 4 方面对两个模型进行详细的介绍.

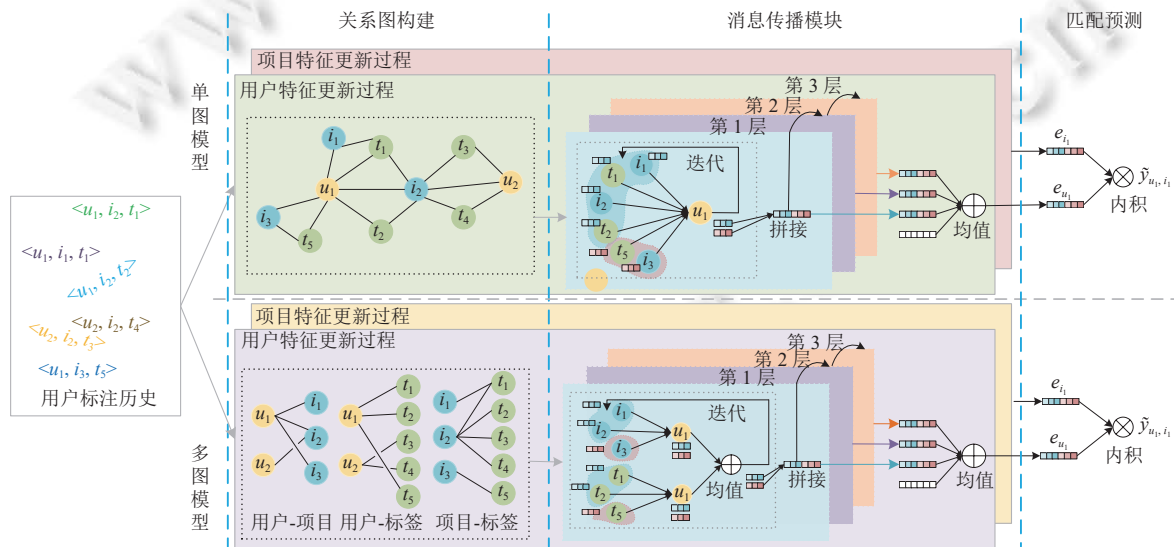


图 2 DETRec 模型结构

2.3 关系图构建

为了进行后续的图卷积操作, 需要根据用户标注数据构建好图结构. 在由 3 种关系构建图的过程中, 根据是否区分不同关系, 有以下两种操作.

1) 关系等价定义, 平等对待标注数据中的不同关系, 可构造出一个拥有多连接的单图, 如图 2 中的单图模型所示, 将所有关系置于一个图中, 结点的邻域能够包含更多数量的结点, 如用户 u_1 的邻域包含了其使用过的标签和交互过的项目, 其优点是能够减轻单关系中的稀疏性问题^[29], 但是混入了不同语义下的信息, 其邻接矩阵可表示为:

$$G_{UIT} = \begin{bmatrix} 0 & A_{UI} & A_{UT} \\ A_{UI}^T & 0 & A_{IT} \\ A_{UT}^T & A_{IT}^T & 0 \end{bmatrix} \quad (1)$$

2) 关系差异化定义, 将不同关系分开处理, 则可获得用户-项目、用户-标签、项目-标签 3 种关系子图, 如图 2 中的多图模型所示, 每种关系中, 结点的邻域结点单一, 数量较少, 分别进行图卷积可以获得比较干净的关系语义信息, 如用户 u_1 分别在用户-项目、用户-标签关系子图上进行图卷积后, 可获得用户 u_1 的项目偏好语义信息和标签表明的关注点语义信息, 这些不同关系的语义信息从不同方面刻画了用户的偏好, 缺点是容易遭受稀疏性问题. 三者的邻接矩阵可表示为:

$$G_{UI} = \begin{bmatrix} 0 & A_{UI} \\ A_{UI}^T & 0 \end{bmatrix}, G_{UT} = \begin{bmatrix} 0 & A_{UT} \\ A_{UT}^T & 0 \end{bmatrix}, G_{IT} = \begin{bmatrix} 0 & A_{IT} \\ A_{IT}^T & 0 \end{bmatrix} \quad (2)$$

2.4 消息传播模块

关系图构建好后, 为了充分挖掘结点的邻域信息, 可利用消息传播机制, 在关系图上传播结点间的信息, 从而将结点邻域信息编码进结点的特征信息中, 获得更丰富的特征信息. 除了扩展结点信息, 本文还需要解耦结点的多属性信息, 因此, 需要将关系图根据各边属性权重将其划分为属性相关的子图, 使得各属性特征在传播时不耦合进结点的整体特征中, 因此, 接下来依次从属性消息传播、属性权重计算、模型实例和高阶连接对模型进行详细地介绍.

2.4.1 属性消息传播

一般而言, 各种图卷积操作可用消息传播机制进行描述, 即假设存在一个图 G , 其中结点的特征表示为 $e \in \mathbb{R}^d$, 结点 y 到结点 x 的边特征信息为 $s(x, y) \in \mathbb{R}^b$. 则单层图卷积可表示为:

$$e_x^{(l+1)} = f(e_x^{(l)}, g(\{e_y^{(l)}, s(x, y) | y \in \mathbb{N}_x\})) \quad (3)$$

其中, \mathbb{N}_x 为结点 x 的邻域结点, l 为层数, $f(\cdot)$ 为聚合中心结点信息与邻域信息的函数, $g(\cdot)$ 为聚合邻域结点信息的函数, 两者都可以为简单函数或复杂的神经网络模型.

除通过图卷积增强结点特征以外, 本文将结点的嵌入表示划分为多个块, 以解耦用户、项目、标签三者相关的多属性特征. 每个块代表不同的属性特征, 可表示为:

$$e_x = (e_{x,1}, e_{x,2}, \dots, e_{x,K}) \quad (4)$$

其中, $e_{x,k} \in \mathbb{R}^{d/K}$, K 为解耦的属性个数. 由于边上各属性的贡献程度不同, 因此在消息传播时, 各属性信息应该依据边上各属性的权重确定属性信息传播的大小, 即将消息传播机制细化到属性层面. 假设各边上各属性的贡献分数可由某种方法计算得到:

$$p(x, y)_k = H(e_x, e_y, \dots | \Theta) \quad (5)$$

其中, $H(\cdot)$ 可为函数或各种神经网络模型, Θ 为其中的参数, e_x, e_y, \dots 为可以利用的各种特征. 为了突出主要各属性的差异, 可进行归一化获取各属性的权重分布:

$$\hat{p}(x, y)_k = \frac{\exp p(x, y)_k}{\sum_{k'=1}^K \exp p(x, y)_{k'}} \quad (6)$$

基于准确的权重, 可由每种属性上各边的权重, 重构属性相关的子图 G_k :

$$G_k(x, y) = \begin{cases} \hat{p}(x, y)_k, & (x, y) \in G \\ 0, & \text{else} \end{cases} \quad (7)$$

其中, $G_k(x, y)$ 为边 (x, y) 上的值, 表示该边在该属性下存在的可信度, 值越低表明在该属性方面, 该边极有可能为

噪声边. 获得属性相关的子图后, 则可进行属性层面的消息传播, 扩展结点属性特征. 属性消息传播可表示为:

$$e_{x,k}^{(l+1)} = f(e_{x,k}^{(l)}, g(\{e_{x,k}^{(l)}, e_{y,k}^{(l)}, \hat{p}(x,y)\} | y \in \mathbb{N}_x)) \quad (8)$$

为了更好地获取邻域信息以及考虑到目前流行的图卷积简化研究, 本文采用推荐领域中性能最好且结构简单的图卷积算法 LightGCN^[17]. 公式 (8) 可进一步细化为:

$$e_{x,k}^{(l+1)} = \sum_{y \in \mathbb{N}_x} \frac{\hat{p}(x,y)_k}{\sqrt{D_{x,k} \cdot D_{y,k}}} e_{y,k}^{(l)} \quad (9)$$

其中, $\hat{p}(x,y)_k$ 为属性 k 下边 (x,y) 上的权重, $D_{x,k} = \sum_{z \in \mathbb{N}_x} \hat{p}(x,z)_k$, $D_{y,k} = \sum_{z \in \mathbb{N}_y} \hat{p}(y,z)_k$ 分别为结点 x, y 在属性 k 下的度.

2.4.2 属性权重计算

为了获得边 (x,y) 上各属性的贡献分数 $p(x,y)$, 本文采用邻域路由机制^[25], 利用两端结点在属性上的相似度确定属性的贡献分数, 并通过交替执行属性子图划分和属性消息传播, 让其逼近真实分布. 该思想已经在多个场景下取得了成功^[25-27], 本文采用 DGCF^[26]中的实现方法.

首先假设边 (x,y) 上各属性的贡献相等, 即:

$$p^{(0)}(x,y) = (1, 1, \dots, 1) \quad (10)$$

根据公式 (6) 计算权重分布, 将图划分为 K 个属性相关的子图. 在属性子图上进行图卷积, 扩展结点的属性信息. 然后利用更新后的中心结点属性特征与邻域结点的原始属性特征更新贡献分数.

$$p^{(j+1)}(x,y)_k = p^{(j)}(x,y)_k + e_{x,k}^{(j+1)T} \cdot \tanh(e_{y,k}^{(0)}) \quad (11)$$

$\tanh(\cdot)$ 的作用是给模型一定的非线性能力, j 为迭代次数, 相比于 DisenGCN^[25]将属性权重差异隐式地存储在属性特征中, DGCF 通过累积的方式增大差异性, 具有更好的解耦效果. 下面对本文的两种实现进行详细的介绍.

2.4.3 模型实例

(1) 单图消息传播

单图模型基于 $G = G_{UII}$ 解决问题, 结点类型 $x, y \in U \cup I \cup T$, 算法流程如下.

1) 按公式 (10) 为 G_{UII} 中的每条边设置一个贡献分数向量 $p^{(0)}(x,y)$, 按公式 (4) 将用户、项目、标签的嵌入表示划分为 K 块, 表示各属性上的特征 $e_{x,k}^{(0)}$.

2) 由贡献分数向量按公式 (6) 计算各属性的权重 $\hat{p}^{(j)}(x,y)_k$, 根据公式 (7) 构建属性子图 $G_{UII,k}$.

3) 按公式 (9) 进行属性消息传播, 扩展结点的邻域属性特征 $e_{x,k}^{(j+1)}$. 按公式 (11) 更新各边的贡献分数 $p^{(j+1)}(x,y)_k$.

4) 重复步骤 2) 和 3) 多次, 则可获得用户、项目、标签的扩展属性特征和属性子图.

(2) 多图消息传播

对于多图, 前文中的 $G = \{G_{UI}, G_{UT}, G_{IT}\}$, 各图中的结点类型的取值范围分别为 $U \cup I, U \cup T, I \cup T$, 各关系图包含了结点的不同语义信息, 因此相比于单图模型, 需要添加多语义融合步骤, 该模型算法流程如下.

1) 按公式 (10) 为 G_{UI}, G_{UT}, G_{IT} 这 3 种图中的每条边设置一个贡献分数向量 $p^{(0)}(x,y)$, 按公式 (4) 将用户、项目、标签的嵌入表示划分为 K 块, 表示各属性上的特征 $e_{x,k}^{(0)}$.

2) 按公式 (6) 计算各属性的权重 $\hat{p}^{(j)}(x,y)_k$, 根据公式 (7) 构建各关系下的属性子图 $G_{UI,k}, G_{UT,k}, G_{IT,k}$.

3) 按公式 (9) 在各关系下的属性子图上进行消息传播, 获得结点在各关系下的属性特征 $e_{x,\varphi,k}^{(j+1)}$. 为了完整地表示结点的属性信息, 需要融合结点在该属性上的多关系语义信息. 融合方法有很多种, 比如拼接后再经过 MLP, 使用注意力机制等, 本文进行了实验比较, 最后使用最简单的均值操作, 可表示为:

$$e_{x,k}^{(j+1)} = \frac{1}{|\psi(x)|} \sum_{\varphi \in \psi(x)} e_{x,\varphi,k}^{(j+1)} \quad (12)$$

其中, $\psi(x)$ 为结点 x 拥有的关系集合, 比如对于用户结点, $\psi(\cdot)$ 包括用户-项目关系和用户-标签关系. 按公式 (11) 更

新各边的贡献分数 $p^{(j+1)}(x,y)_k$.

4) 重复步骤 2) 和 3) 多次, 则可获得用户、项目、标签的扩展属性特征和各关系下的属性子图.

2.4.4 高阶连接

经过上述解耦卷积层, 可以获得结点解耦的一阶邻域属性特征和属性子图的划分, 为了让结点的属性信息获取到更高阶的邻域信息, 可以堆叠多层的解耦图卷积层. 将上一层获得结点的属性信息和属性对边的贡献分数作为下一层的输入, 获取结点的高阶连接信息. 堆叠 L 层后, 将每层属性信息融合起来作为结点总的属性信息, 可表示为:

$$e_{x,k} = \frac{1}{L+1} \sum_{l=0}^L e_{x,k}^{(l)} \quad (13)$$

基于以上步骤, 最终可获得用户、项目、标签三者在各属性上的信息表示 $e_{u,k}, e_{i,k}, e_{t,k}$, 以及各层输出的属性子图.

2.5 模型训练

上述操作生成了用户、项目、标签三者优化后的嵌入表示. 以内积作为预测函数, 用户对项目的偏好程度, 可表示为:

$$\hat{y}_{ui} = e_u^T \cdot e_i \quad (14)$$

通过计算用户对所有项目的偏好分数, 以分数对项目排序, 选取排名靠前的 N 个项目作为推荐列表, 即完成推荐过程.

为了让各属性上的信息尽可能关注不同的邻域, 本文引入独立模块以约束属性独立性. 在此, 选用距离相关性^[24]设计独立性损失函数:

$$loss_{ind} = \frac{2}{K(K-1)} \sum_{k=1}^K \sum_{k'=k+1}^K \frac{dCov(E_k, E_{k'})}{\sqrt{dVar(E_k) \cdot dVar(E_{k'})}} \quad (15)$$

其中, $E_k = E_{U,k} \parallel E_{I,k} \parallel E_{T,k}$, 为所有用户、项目、标签在第 k 个属性上的嵌入表示拼接而成的矩阵, $dCov(\cdot)$ 为两个矩阵的协方差, $dVar(\cdot)$ 为每个矩阵的方差.

为了保障结果的有序性, 本文使用成对排序优化损失函数 BPR^[28], 旨在使得用户对于观测到的项目 (正样本) 的偏好高于未观测到的项目 (负样本或未观测到的正样本) 的偏好:

$$loss_{BPR} = \sum_{(u,i,j) \in Q} -\ln \sigma(\hat{y}_{ui} - \hat{y}_{uj}) \quad (16)$$

其中, 三元组 (u, i, j) 由用户 u 、其交互过的正样本项目 i 、以及其未交互过的负样本项目 j 组成的一条训练数据, Q 为多次随机采样获得的三元组训练数据集, σ 为非线性激活函数.

最后, 为了同时优化推荐参数并鼓励各属性子图独立, 训练过程的损失函数结合了 $loss_{ind}$ 与 $loss_{BPR}$, 即:

$$loss = loss_{BPR} + \lambda_1 loss_{ind} + \lambda_2 \|\Theta\|_2 \quad (17)$$

其中, Θ 为模型的参数; λ_1 为独立模块的权重; λ_2 为模型参数的正则项权重, 用于防止模型过拟合.

2.6 推荐依据生成

DETRec 不仅包含结点各属性上的嵌入表示, 还包含获得模型对历史交互的解耦情况, 为归纳总结结点各属性上的语义信息提供了线索. 生成推荐依据的过程可概括为如下几个步骤.

步骤 1. 邻域结点聚类, 按照邻域路由机制的思想, 两结点如果因为某种属性相连, 则两者在该属性上具有相似性, 由属性相关的邻域结点可推测出中心结点的属性语义信息. 因此, 根据边属性权重的大小, 将对应的邻域结点划分到权重最大的属性组中.

步骤 2. 归纳语义信息, 由各属性组邻域结点自身的多媒体信息归纳总结属性组的语义信息, 作为中心结点的属性语义信息.

步骤 3. 比较用户和项目各属性上的语义信息, 推测推荐的依据. 此外, 由于标签自身具有的语义含义, 可由用户和项目各属性上的标签直接作为推荐依据.

图3 以用户与项目的交互为例, 描述如何解耦用户-项目交互图并形成属性子图. 首先, 根据第一层解耦图卷积层, 可获得各属性下用户与项目之间的关系权重 $\hat{p}^{(1)}(u_i, i)$. 图3 右边图中描述了用户结点 u_1 在两种属性子图下的权重. 根据步骤1所述, 项目 i_1 与 i_2 在属性1上获得最大权重, 因此可以认为, 用户大概率因为属性1选择了 i_1 与 i_2 . 同理, 用户大概率因为属性2选择了 i_3, i_4, i_5 . 故此, 通过权重为用户-项目交互划分属性子图, 在图3中使用实线表示.




图3 根据属性权重生成属性子图示意图

根据上述方式获得的属性子图, 可描述用户-标签关系和项目-标签关系的解耦情况. 利用标签语义描述, 可得用户和项目的属性语义, 从而给出直观的推荐依据, 图4 描述了用户 u_1 与项目 i_1 在属性1子图中与标签的关联关系. 显然, 用户在属性1上的偏好语义可由标签 t_1, t_2, t_3 的语义代表, 项目 i_1 在属性1上的特性可由标签 t_1, t_2, t_6 代表. 由此可推测, 用户 u_1 交互项目 i_1 的一个重要原因是: 项目 i_1 在属性1方面的特征满足了用户 u_1 的偏好 (两者属性1方面的特征都可用标签 t_1 和 t_2 描述). 因此可认为, 属性1即为用户 u_1 关注 i_1 的重要角度, 而 t_1, t_2 为该推荐的具体依据.




图4 根据解耦属性子图形成推荐依据示意图

3 实验分析

3.1 数据集

为了验证提出方法的效果, 本文在 HetRec2011^[30] 公布的 3 个公开数据集上设计了丰富的对比实验.

- MovieLens 是 GroupLens 研究小组发布的电影推荐数据集, 包含用户为电影设置的标签.
- LastFM 是在线音乐网站 Last.FM 发布的数据集, 包含用户对艺术家设置的标签.
- Delicious 数据集是从 Del.icio.us 系统中整理出的网站书签类数据集, 包含用户为网站设置的标签.

参照 TGCN^[7] 模型的预处理方法, 本文删除 MovieLens 和 LastFM 中使用频率少于 5 的标签, 也删除 Delicious 中频率少于 15 的标签. 预处理后的 3 个数据集数据统计见表 2. 然后, 随机将每个数据集中每个用户的交互拆分为 80%, 10%, 10%, 分别作为训练集、验证集和测试集.

表 2 数据集统计

数据集	用户数	项目数	标签数	交互数	标注数
MovieLens	1 651	5 381	1 586	23 023	36 728
LastFM	1 808	12 212	2 305	68 271	175 641
Delicious	1 843	65 877	3 508	97 351	339 744

3.2 评价指标及基准模型

为评估模型的性能, 本文采用 top-N 推荐中 4 种常用评估指标: 精确率 (precision, Pre)、召回率 (recall, Rec)、命中率 (hit ratio, HR)、归一化折损累计增益 (normalized discounted cumulative gain, NDCG).

工作 TGCN^[7]中, 验证了图卷积模型相比基于特征的模型的优越性, 本文将不再考虑基于特征的基准模型. 在此选取主流的图卷积算法进行对比, 主要包括以下 3 种类别.

第 1 类使用推荐领域中经典的图卷积推荐模型 NGCF, 作为实验的基准.

- NGCF^[18]: 通过图卷积操作将用户和项目之间协同信号编码进用户和项目的嵌入表示中, 并通过堆叠多层图卷积层探索用户和项目的高阶连接信息.

第 2 类采用了两种考虑不同关系的图模型 KGAT 和 TGCN, 以验证关系差异化对模型性能的影响.

- KGAT^[23]: 为了获取项目间丰富的语义关系, 在交互图的基础上引入了知识图谱, 并设计了具有知识感知的注意力图卷积模型, 以便对高阶关系建模.

- TGCN^[7]: 利用关系图中结点的上下文语义信息解决标签的模糊性和冗余性问题, 并创造性地在图卷积中引入了卷积模块, 以便对不同类型邻域信息间的多尺度交互建模, 取得了目前标签感知推荐领域中最优的性能.

第 3 类对比了两种经典的解耦图卷积模型 DisenGCN 和 DisenHAN, 从而验证本文解耦模型的能力.

- DisenGCN^[25]: 为了解耦图中交互背后的多种潜在因素, 提出了邻域路由机制, 使其能够动态地识别边背后的潜在因素, 并将与各因素相关的邻域信息整合到不同的通道里, 得到解耦的结点嵌入表示.

- DisenHAN^[27]: 针对异质图中不同元关系在不同方面具有不同的侧重点, 提出了能够迭代地识别出结点对间的关系的主要方面, 从而实现元路径的自动提取. 和结点信息在不同方面上的解耦.

实验中将本文提出的模型命名为 DETRec, 并使用 DETRec-S 代表将用户、项目与标签的关系统一处理的模型, 即模型的单图实现; DETRec-M 代表将用户-项目、项目-标签、用户-标签关系区别对待的模型, 即模型的异质图实现.

3.3 实验设置

实验中所有模型均使用 PyTorch 实现并适配相应的关系图. KGAT 将标签视为实体, 每种关系视为知识图谱中的一种语义关系. NGCF 与 DisenGCN 不区分结点类型, 使用单张关系图描述全部关系, 并进行后续图操作. TGCN 和 DisenHAN 使用多张异质图描述关系. 参考主流方法的实验设置, 本文统一使用 3 层图模型, 设置结点嵌入维度为 $d=64$, 设置训练时数据批大小为 512. 参数使用 Xavier 初始化, 使用 Adam 作为优化器. DisenGCN、DisenHAN 与 DETRec 中的领域路由迭代次数均设为 2, 属性个数设置均为 4. TGCN 沿用其论文里的最佳配置. 对于各种方法, 均在验证集上使用网格化搜索确定最优超参, 并汇报测试集上运行结果. 其中, 学习率的搜索范围为 $\{0.05, 0.01, 0.005, 0.001, 0.0005, 0.0001\}$. 各模型损失函数中正则化权重 λ_1 与 λ_2 的搜索范围为: $\{0, 10^{-5}, 10^{-4}, 10^{-3}, 10^{-2}, 10^{-1}\}$. 各方法中均使用 3 种方式描述结点: 1) 使用图模型最后一层的输出; 2) 拼接图模型各层的输出; 3) 使用图模型各层输出的均值, 取三者最优结果作为模型结果. 训练过程中使用早停技术 (early-stop) 防止过拟合, 若 100 个 epoch 内模型的 NDCG@10 无法提升, 则停止训练. 每 5 个 epoch 在验证集上测试一次性能, 保留性能最好的一次作为最终训练模型, 然后测试其在测试集上的性能. 如无特殊说明, 文中汇报实验结果的正则化项参数如下: DETRec-S 在 MovieLens 数据集上 $\lambda_1 = 10^{-3}, \lambda_2 = 10^{-5}$, 在 LastFM 数据集上取 $\lambda_1 = 10^{-3}, \lambda_2 = 10^{-3}$, 在 Delicious 数据集上取 $\lambda_1 = 10^{-5}, \lambda_2 = 10^{-5}$. DETRec-M 在 MovieLens 和 LastFM 数据集上均为 $\lambda_1 = 10^{-3}, \lambda_2 = 10^{-3}$, 在 Delicious 上 $\lambda_1 = 10^{-4}, \lambda_2 = 10^{-5}$.

3.4 性能比较

表 3-表 5 分别列出了各模型在 MovieLens、LastFM、Delicious 这 3 个数据集上的性能比较. 由表 3-表 5 可知, 本文模型 DETRec 在 3 个数据集上都取得了最优的结果, 证明 DETRec 能够更好地捕获用户-项目-标签三者的复杂关系, 有效地改进了标签感知推荐. 相比于解耦模型 DisenGCN 和 DisenHAN, DETRec 去除了图卷积中的非线性激活函数和特征映射, 形成更契合推荐任务的图网络结构. 也因此 3 个数据集上都取得了更优秀的结果.

表3 MovieLens 数据集上不同模型间的性能对比

模型	Rec@10	Rec@20	Pre@10	Pre@20	HR@10	HR@20	NDCG@10	NDCG@20
NGCF	0.0672	0.1048	0.0187	0.0146	0.1409	0.2008	0.0489	0.0587
KGAT	0.0615	0.1074	0.0181	0.0163	0.1349	0.2143	0.0450	0.0584
TGCN	0.0802	0.1120	0.0229	0.0183	0.1574	0.2158	0.0605	0.0691
DisenGCN	0.0676	0.1064	0.0185	0.0147	0.1379	0.1979	0.0474	0.0579
DisenHAN	0.0587	0.0879	0.0155	0.0122	0.1229	0.1724	0.0471	0.0548
DETRec-S	0.1173	0.1645	0.0290	0.0214	0.2038	0.2728	0.0872	0.0990
DETRec-M	0.1190	0.1672	0.0298	0.0212	0.2053	0.2758	0.0885	0.0999

表4 LastFM 数据集上不同模型间的性能对比

模型	Rec@10	Rec@20	Pre@10	Pre@20	HR@10	HR@20	NDCG@10	NDCG@20
NGCF	0.1233	0.1882	0.0406	0.0320	0.2989	0.3968	0.0938	0.1105
KGAT	0.1115	0.1806	0.0390	0.0321	0.2793	0.3893	0.0825	0.1010
TGCN	0.1218	0.1909	0.0411	0.0331	0.2959	0.4103	0.0913	0.1097
DisenGCN	0.1316	0.1881	0.0402	0.0309	0.2959	0.3893	0.0904	0.1051
DisenHAN	0.1163	0.1764	0.0377	0.0297	0.0281	0.3832	0.0818	0.0974
DETRec-S	0.1453	0.2150	0.0463	0.0363	0.3313	0.4450	0.1104	0.1286
DETRec-M	0.1529	0.2146	0.0463	0.0354	0.3411	0.4375	0.1125	0.1284

表5 Delicious 数据集上不同模型间的性能对比

模型	Rec@10	Rec@20	Pre@10	Pre@20	HR@10	HR@20	NDCG@10	NDCG@20
NGCF	0.1267	0.1733	0.0734	0.0501	0.3359	0.3761	0.1118	0.1326
KGAT	0.1350	0.1915	0.0761	0.0535	0.3320	0.3756	0.1131	0.1377
TGCN	0.1408	0.1814	0.0810	0.0525	0.3465	0.3733	0.1192	0.1375
DisenGCN	0.1351	0.1889	0.0783	0.0539	0.3487	0.3935	0.1175	0.1409
DisenHAN	0.1350	0.1904	0.0807	0.0551	0.3426	0.3884	0.1167	0.1406
DETRec-S	0.1354	0.1856	0.0760	0.0524	0.3566	0.4002	0.1197	0.1420
DETRec-M	0.1512	0.2017	0.0860	0.0578	0.3750	0.4086	0.1333	0.1560

从表3-表5中还可以看出, DETRec-S与 DETRec-M在不同数据集上的表现不同,这是由于数据集的稀疏度导致.对3个数据集中每个用户的标注次数进行统计可知, MovieLens、LastFM、Delicious这3个数据集的稀疏度逐步递减.由于前两个数据集中大多数用户的交互较稀疏,使得在聚合不同类型结点信息时,区分关系类别的 DETRec-M相较于 DETRec-S并没有得到明显的性能提升.相比之下, Delicious数据集的稀疏度较低,因而 DETRec-M表现明显优于 DETRec-S,也反映了使用异质图区分结点和关系类别的重要性.

为了更进一步验证稀疏度对各模型的影响,本文根据用户的交互数将用户划分为多组,每组中交互数量保持基本一致.在各组上测试模型的性能如图5所示.总体来说,交互数较多的用户,通常能够获得较好的效果.特别的, Delicious数据集上,各模型在交互最多的用户组上出现了普遍的降低,说明用户交互数据增加后,也会引入一定量的噪声,影响到模型结果.而 DisenGCN与 DisenHAN在 MovieLens中交互最多的用户组上表示较差,也说明这两个方法的解耦模式受噪声影响较大.相比之下,本文提出的 DETRec在各数据集中均取得了稳定的优秀性能,是一种鲁棒性较高的算法.

3.5 模型可解释性

除了获得不错的性能提升外, DETRec可以提供一定的可解释性.以 MovieLens数据集为例,图6、图7分别展示了两个模型对第190号用户的兴趣的解耦情况,对于该用户的每条历史交互(一阶邻域),根据各交互的最大贡献分数(第1层卷积获取到的 $\hat{p}(x,y)$ 中的最大值)将其划分到对应的属性组中,图中,红色方框表示用户未来交

互的电影, 黑色实线表示用户的历史交互, 橙色实线表示原始数据集中该用户给电影标注过对应标签, 橙色虚线表示电影被其他人标注过该标签, 边上的分数即为此边在该属性上的贡献分数, 相同色块内的结点表示其被划分到同一个属性组, 通过分析有以下发现.

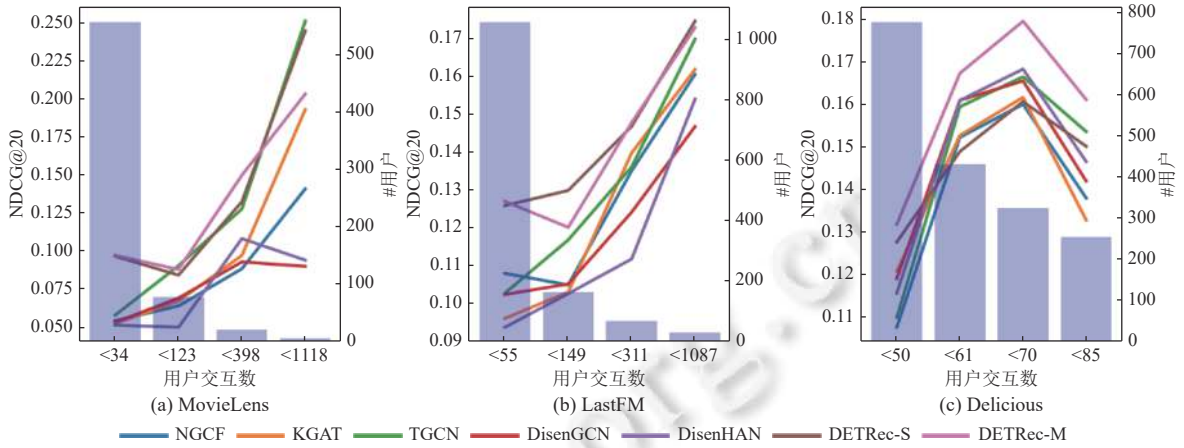


图 5 用户交互数对模型的影响.

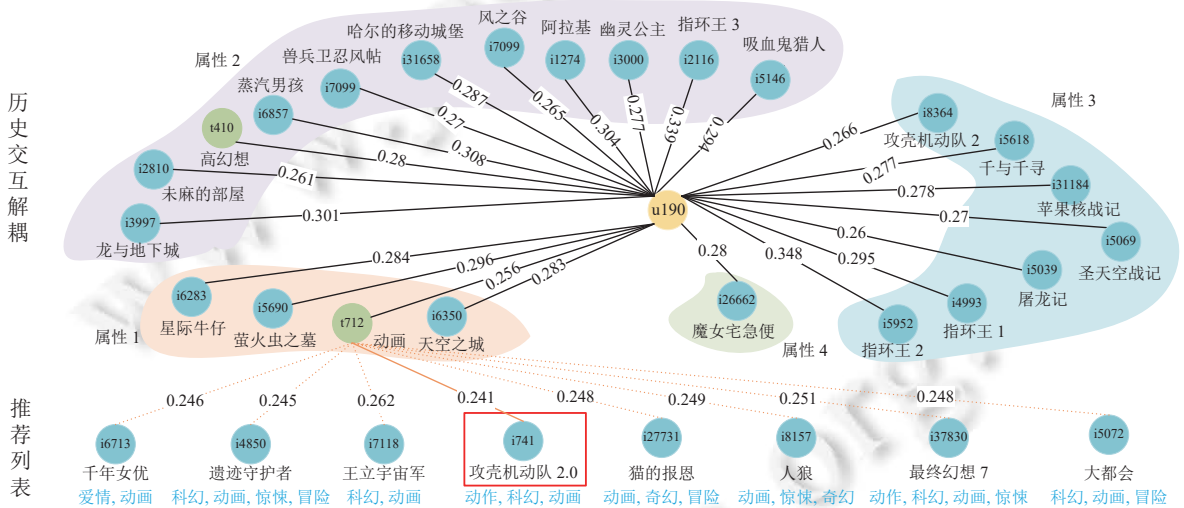


图 6 DETRec-S 解耦效果和推荐依据展示

1) 该用户通过自身的标签标注表明关注点有“高幻想 (high fantasy)”和“动画 (anime)”两个方面, 其观看的电影大多为动画类和奇幻类, DETRec-S 将这两个关注点主要划分到了第 1 和第 2 属性组, DETRec-M 则划分到了第 2 和第 3 属性组, 但两者对交互过的电影的聚类效果相差不大.

2) 除了上述两个关注点, 模型因为设置了 4 个属性维度, 进行了更细致的划分, 通过电影的多种信息, 可以归纳出各属性的主要特征, 以 DETRec-M 为例, 4 个属性特征可分别归纳为战争反思类动画、魔幻类电影、冒险成长类动画、奇幻类动画. 值得注意的是, 被划分到一个属性上的电影往往也具有其他属性上的特征, 例如大多数动画都具有高幻想的特点, 只是该特征在各属性上的权重不一样.

3) 推荐列表中大多数电影被标注过“动画”, 表明这些电影是因为满足了用户的动画属性 (对应 DETRec-S 的属性 1 与 DETRec-M 的属性 3) 上的需求而被推荐的. 值得注意的是: 这些边的权重都不是太高, 即被划分到该组的概率不高, 同时表明动画特征信息在其他属性组上也具有不小的权重. 表明了模型无法对不同属性特征进行彻

底的解耦, 这和 DGCF^[26]中取消最小贡献属性将导致模型性能严重降低的消融实验一致. 另外通过电影类别可以发现: 推荐列表中的大多数电影为奇幻类动画, 说明模型通过消息传播捕捉到了用户对于奇幻电影的偏好.




图 7 DETRec-M 解耦效果和推荐依据展示

图 8 展示了更多用户的推荐效果, 其中, 推荐项目列中的黑色文字表示电影名称, 蓝色表示电影对应的特征, 红色方框表示用户未来交互的电影. 标签列中的不同颜色代表标签被划分到的属性组, 其后的数字代表了其属性 ID. 根据用户使用的标签和其交互过的项目推测可能的缘由 (为了更好地展现推荐效果, 选择了推荐效果更好的 DETRec-M). 例如对于用户 u26624, 其使用过的标签和交互过的电影表明了用户的关注点: 俄罗斯电影 (属性 4) 和吉卜力工作室 (属性 1) 制作的动画 (属性 2), 因此, 电影“哈尔的移动城堡”正是因为满足了用户在属性 1、2 上的需求而被用户选中, 电影“飞向太空”和“小偷”则因为满足了用户在属性 4 的需求而被用户选择. 同理, 用户 u4856 则多偏好宫崎骏创作的关于冒险题材的动画和比较浪漫的电影; 用户 u21522 主要关注点则是电影的质量, 喜欢获奖的高质量的电影, 而不局限于特定的类别; 用户 u68637 则喜欢 007 系列电影, 有趣的是: 电影“征婚广告”因为被其他用户标注过“bond”, 而“bond”又与标签“詹姆斯邦德 (james bond)”经常一起出现在 007 系列电影中而被错误推荐.

用户	使用过的标签	推荐项目及推荐依据展示							
u26624	吉卜力工作室 (1)、动画 (2)、俄罗斯 (4)、...	哈尔的移动城堡	未麻的部屋	攻壳机动队 2.0	猫的报恩	飞向太空	千年女优	小偷	...
		吉卜力工作室动画	日本动画	动画	吉卜力工作室动画	俄罗斯电影	动画	俄罗斯电影	
u4856	宫崎骏 (1)、动画 (2)、冒险 (2)、浪漫 (3)	幽灵公主	萤火虫之墓	未麻的部屋	攻壳机动队 2.0	鲁邦三世	天使爱美丽	超级无敌掌门狗	...
		宫崎骏动画	宫崎骏动画	动画	动画	宫崎骏动画	爱情	动画	
u21522	最佳影片 (1)、经典 (2)、...	桂河大桥	阿甘正传	拯救大兵瑞恩	教父	雨人	勇敢的心	断背山	...
		经典电影	经典电影	经典电影	经典电影	经典电影	经典电影	经典电影	
u68637	詹姆斯邦德 (3)、汉尼拔 (3)	007 之黄金眼	007 之诺博士	007 别传之皇家夜总会	007 之霹雳弹	007 之杀人执照	征婚广告	夺宝奇兵 3	...
		007 系列	007 系列	007 系列	007 系列	007 系列	“bond”	冒险、动作	

图 8 更多的用户推荐结果展示 (DETRec-M)

3.6 消融实验

本节将详细探讨了图卷积层数、属性解耦个数和独立模块对模型性能的影响.

(1) 图卷积层数的影响

对于目前很多图卷积模型来说, 堆叠更多的层的可以获得高阶的连接信息, 但是这也意味着接收到了更多的

邻域信息, 将使得结点自身的信息所占比重越来越小, 导致图中结点的特征越来越接近, 即过平滑问题, 因此各模型需要选择好卷积层数, 以调和高阶连接信息与过平滑问题的矛盾. 因此, 本文在 3 个数据集上分别测试了卷积层数对 DETRec 的影响, 结果如图 9 所示. 可以发现, 在前两个数据集上, 模型的性能随着层数的增加先提升后降低, 其原因在于增加层数获取高阶连接信息的收益已经无法抵消过平滑导致的模型性能下降, 大致在 2, 3 层取得最佳效果. 而在第 3 个数据集上, 由于用户的交互分布相比前两个数据集有所缓解, 每个结点拥有一定数量的邻域, 使得其只使用一阶邻域信息就可以取得不错性能, 而当继续堆叠多层提高结点感受域时, 模型性能越来越差, 且单图模型 DETRec-S 受到的影响更大. 这可能是由于该数据集上的连接信息中包含比较多的噪声. 因此, 为了平衡过平滑和高阶连接的矛盾, 每个数据集应该参考自身的特点, 选择合适的层数, 以便模型性能达到最优.




图 9 卷积层数对模型性能的影响

(2) 解耦属性数的影响

图中各结点拥有的不同属性个数是不同的, 如用户的偏好个数因人而异, 而本模型中的属性个数是超参数, 一旦确定则必然会出现多个属性被划分到同一个块中的情况, 提高属性个数, 可以提供更细粒度的解释, 但是属性越多, 其嵌入表示的维度将越低, 所能够表达的信息越来越有限, 其图卷积时受到的瓶颈越来越大^[31]. 同时还可能导致结点因为交互少, 无法学到这么多的属性信息, 从而导致各属性上的信息冗余. 因此, 需要在两者之间取得平衡. 本文测试了属性个数在各数据集上对模型的性能影响. 测试了属性个数分别为 1, 2, 4, 8, 16 时, 模型性能的变化, 结果如图 10 所示. 前两个数据集上因为交互较少的用户占大多数, 使得模型无法从少量的数据中为结点学到多个属性方面的信息, 因此增加属性个数并不会带来性能提升, 反而有所下降, 而当拥有足够交互数据的用户越来越多时, 模型则可以为用户学习到多种属性特征, 如在 Delicious 数据集上, 属性个数的增加对于模型性能具有明显的提升, 其中 DETRec-S 的提升变化较大, 可能是因为 DETRec-S 解耦时考虑中心结点的所有邻域, 而 DETRec-M 则是将不同类型的邻域结点分开考虑的.




图 10 属性个数对模型性能的影响

(3) 独立模块的影响

其他图解耦模型为了使各属性信息彼此独立, 添加了独立模块. 本文对比了基于距离相关性的独立模块^[26], 实验结果如表 6 所示. 可以发现独立模块作为一个正则项有助于模型性能的提升, 也即让各属性尽可能独立, 使属

性特征尽可能的不同, 属性上的差异也可隐式地反馈到属性子图的划分上, 使得结点在各属性上关注不同的邻域. 值得注意的是, 该独立模块的性能提升并不是太大, 一方面可能是因为基于距离相关性的独立模块的相关性建模能力的不足, 另一方面则有可能是因为基于属性嵌入表示的独立性建模与让属性尽可能关注不同邻域的需求并不完全等价. 因此, 未来可以增加基于属性子图差异性的独立模块, 让结点不同属性关注不同的邻域, 进而直接导致结点属性上的差异性.

表 6 独立模块对模型性能的影响

模型	独立模块	MovieLens		LastFM		Delicious	
		Rec@20	NDCG@20	Rec@20	NDCG@20	Rec@20	NDCG@20
DETRec-S	不包含	0.1581	0.0969	0.2134	0.1260	0.1850	0.1409
	包含	0.1645	0.0990	0.2150	0.1286	0.1856	0.1420
DETRec-M	不包含	0.1573	0.0940	0.2072	0.1265	0.2007	0.1543
	包含	0.1672	0.0999	0.2146	0.1283	0.2017	0.1560

4 总结

本文针对标签感知推荐中用户、项目和标签的多样性, 提出基于解耦图神经网络的可解释标签感知推荐算法 DETRec, 采用解耦图神经网络建模用户、项目和标签的关系, 形成统一关系表示的综合图和区分关系的异质图两类实例, 并拆分结点的嵌入表示, 从多角度描述结点关系, 结合邻域路由机制和消息传播机制, 在使用图结构优化结点信息的同时, 实现结点特征解耦, 获得结点的解耦属性特征表示和属性子图, 优化模型结果的同时, 为结果赋予推荐依据, 实现模型的可解释性. 本文是解耦图神经网络在可解释标签感知中的一次重要尝试. 在未来的工作中, 还将深入探索语义引入机制, 尝试在训练过程中引入标签语义信息, 强化模型的过程可解释性. 更进一步, 借助多媒体推荐中的社交媒体信息, 打造强大的语义网络, 打造真正以人类感知驱动的可解释推荐平台.

References:

- [1] Xing QL, Liu L, Liu YQ, Zhang M, Ma SP. Study on user tags in Weibo. *Ruan Jian Xue Bao/Journal of Software*, 2015, 26(7): 1626–1637 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4655.htm> [doi: 10.13328/j.cnki.jos.004655]
- [2] Shoja BM, Tabrizi N. Tags-aware recommender systems: A systematic review. In: *Proc. of the IEEE Int'l Conf. on Big Data, Cloud Computing, Data Science & Engineering (BCD)*. Honolulu: IEEE, 2019. 11–18. [doi: 10.1109/BCD.2019.8884850]
- [3] Su XY, Khoshgoftaar TM. A survey of collaborative filtering techniques. *Advances in Artificial Intelligence*, 2009, 2009: 421425. [doi: 10.1155/2009/421425]
- [4] Wu L, He XN, Wang X, Zhang K, Wang M. A survey on accuracy-oriented neural recommendation: From collaborative filtering to information-rich recommendation. *IEEE Trans. on Knowledge and Data Engineering*, 2022: 1–20. [doi: 10.1109/TKDE.2022.3145690]
- [5] Zuo Y, Zeng JL, Gong MG, Jiao LC. Tag-aware recommender systems based on deep neural networks. *Neurocomputing*, 2016, 204: 51–60. [doi: 10.1016/j.neucom.2015.10.134]
- [6] Xu ZH, Chen C, Lukaszewicz T, Miao YS, Meng XW. Tag-aware personalized recommendation using a deep-semantic similarity model with negative sampling. In: *Proc. of the 25th ACM Int'l on Conf. on Information and Knowledge Management*. Indianapolis: ACM, 2016. 1921–1924. [doi: 10.1145/2983323.2983874]
- [7] Chen B, Guo W, Tang RM, Xin X, Ding Y, He XQ, Wang D. TGCN: Tag graph convolutional network for tag-aware recommendation. In: *Proc. of the 29th ACM Int'l Conf. on Information & Knowledge Management*. ACM, 2020. 155–164. [doi: 10.1145/3340531.3411927]
- [8] Zhang B, Zhang Y, Gao KN, Guo PW, Sun DM. Combining relation and content analysis for social tagging recommendation. *Ruan Jian Xue Bao/Journal of Software*, 2012, 23(3): 476–488 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/4001.htm> [doi: 10.3724/SP.J.1001.2012.04001]
- [9] Xu PY, Liu HF, Liu B, Jing LP, Yu J. Survey of tag recommendation methods. *Ruan Jian Xue Bao/Journal of Software*, 2022, 33(4): 1244–1266 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/6481.htm> [doi: 10.13328/j.cnki.jos.006481]


- [10] Xu ZH, Lukasiewicz T, Chen C, Miao YS, Meng XW. Tag-aware personalized recommendation using a hybrid deep model. In: Proc. of the 26th Int'l Joint Conf. on Artificial Intelligence. Melbourne: AAAI Press, 2017. 3196–3202. [doi: [10.24963/ijcai.2017/446](https://doi.org/10.24963/ijcai.2017/446)]
- [11] Huang RR, Wang N, Han CQ, Yu F, Cui L. TNAM: A tag-aware neural attention model for Top-N recommendation. Neurocomputing, 2020, 385: 1–12. [doi: [10.1016/j.neucom.2019.11.095](https://doi.org/10.1016/j.neucom.2019.11.095)]
- [12] Wang Y, Wu YJ, Wu JZ, Liu XY. Multi-Dimensional tag recommender model via heterogeneous networks. Ruan Jian Xue Bao/Journal of Software, 2017, 28(10): 2611–2624 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5132.htm> [doi: [10.13328/j.cnki.jos.005132](https://doi.org/10.13328/j.cnki.jos.005132)]
- [13] Ma HF, Zhang D, Zhao WZ, Shi ZZ. Microblog recommendation method based on hypergraph random walk tag extension. Ruan Jian Xue Bao/Journal of Software, 2019, 30(11): 3397–3412 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5545.htm> [doi: [10.13328/j.cnki.jos.005545](https://doi.org/10.13328/j.cnki.jos.005545)]
- [14] Du XY, He XN, Yuan FJ, Tang JH, Qin ZG, Chua TS. Modeling embedding dimension correlations via convolutional neural collaborative filtering. ACM Trans. on Information Systems, 2019, 37(4): 1–22. [doi: [10.1145/3357154](https://doi.org/10.1145/3357154)]
- [15] Du XY, Wu ZK, Feng FL, He XN, Tang JH. Invariant representation learning for multimedia recommendation. In: Proc. of the 30th ACM Int'l Conf. on Multimedia. Lisboa: ACM, 2022. 619–628. [doi: [10.1145/3503161.3548405](https://doi.org/10.1145/3503161.3548405)]
- [16] Ge Y, Chen SC. Graph convolutional network for recommender systems. Ruan Jian Xue Bao/Journal of Software, 2020, 31(4): 1101–1112 (in Chinese with English abstract). <http://www.jos.org.cn/1000-9825/5928.htm> [doi: [10.13328/j.cnki.jos.005928](https://doi.org/10.13328/j.cnki.jos.005928)]
- [17] Wu SW, Sun F, Zhang WT, Xie X, Cui B. Graph neural networks in recommender systems: A survey. ACM Computing Surveys, 2023, 55(5): 1–37. [doi: [10.1145/3535101](https://doi.org/10.1145/3535101)]
- [18] Wang X, He XN, Wang M, Feng FL, Chua TS. Neural graph collaborative filtering. In: Proc. of the 42nd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. Paris: ACM, 2019. 165–174. [doi: [10.1145/3331184.3331267](https://doi.org/10.1145/3331184.3331267)]
- [19] He XN, Deng K, Wang X, Li Y, Zhang YD, Wang M. LightGCN: Simplifying and powering graph convolution network for recommendation. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 2020. 639–648. [doi: [10.1145/3397271.3401063](https://doi.org/10.1145/3397271.3401063)]
- [20] Chen M, Wei ZW, Huang ZF, Ding BL, Li YL. Simple and deep graph convolutional networks. In: Proc. of the 37th Int'l Conf. on Machine Learning. PMLR, 2020, 119: 1725–1735.
- [21] Wu F, Souza AH Jr, Zhang TY, Fifty C, Yu T, Weinberger KQ. Simplifying graph convolutional networks. In: Proc. of the 36th Int'l Conf. on Machine Learning. Long Beach: PMLR, 2019. 6861–6871.
- [22] Wei YW, Wang X, Nie LQ, He XN, Hong RC, Chua TS. MMGCN: Multi-modal graph convolution network for personalized recommendation of micro-video. In: Proc. of the 27th ACM Int'l Conf. on Multimedia. Nice: ACM, 2019. 1437–1445. [doi: [10.1145/3343031.3351034](https://doi.org/10.1145/3343031.3351034)]
- [23] Wang X, He XN, Cao YX, Liu M, Chua TS. KGAT: Knowledge graph attention network for recommendation. In: Proc. of the 25th ACM SIGKDD Int'l Conf. on Knowledge Discovery & Data Mining. Anchorage: ACM, 2019. 950–958. [doi: [10.1145/3292500.3330989](https://doi.org/10.1145/3292500.3330989)]
- [24] Zhao ZY, Zhang XJ, Zhou H, Li C, Gong MG, Wang YQ. HetNERec: Heterogeneous network embedding based recommendation. Knowledge-based Systems, 2020, 204: 106218. [doi: [10.1016/j.knsys.2020.106218](https://doi.org/10.1016/j.knsys.2020.106218)]
- [25] Ma JX, Cui P, Kuang K, Wang X, Zhu WW. Disentangled graph convolutional networks. In: Proc. of the 36th Int'l Conf on Machine Learning. Long Beach: PMLR, 2019. 4212–4221.
- [26] Wang X, Jin HY, Zhang A, He XN, Xu T, Chua TS. Disentangled graph collaborative filtering. In: Proc. of the 43rd Int'l ACM SIGIR Conf. on Research and Development in Information Retrieval. ACM, 2020. 1001–1010. [doi: [10.1145/3397271.3401137](https://doi.org/10.1145/3397271.3401137)]
- [27] Wang YF, Tang SY, Lei YT, Song WP, Wang S, Zhang M. DisenHAN: Disentangled heterogeneous graph attention network for recommendation. In: Proc. of the 29th ACM Int'l Conf. on Information & Knowledge Management. ACM, 2020. 1605–1614. [doi: [10.1145/3340531.3411996](https://doi.org/10.1145/3340531.3411996)]
- [28] Rendle S, Freudenthaler C, Gantner Z, Schmidt-Thieme L. BPR: Bayesian personalized ranking from implicit feedback. In: Proc. of the 25th Conf. on Uncertainty in Artificial Intelligence. Montreal: AUAI Press, 2009. 452–461.
- [29] Du XY, Wang X, He XN, Li ZC, Tang JH, Chua TS. How to learn item representation for cold-start multimedia recommendation? In: Proc. of the 28th ACM Int'l Conf. on Multimedia. Seattle: ACM, 2020. 3469–3477. [doi: [10.1145/3394171.3413628](https://doi.org/10.1145/3394171.3413628)]
- [30] Cantador I, Brusilovsky P, Kuflik T. Second workshop on information heterogeneity and fusion in recommender systems (HetRec2011). In: Proc. of the 5th ACM Conf. on Recommender systems. Chicago: ACM, 2011. 387–388. [doi: [10.1145/2043932.2044016](https://doi.org/10.1145/2043932.2044016)]
- [31] Alon U, Yahav E. On the bottleneck of graph neural networks and its practical implications. In: Proc. of the 9th Int'l Conf. on Learning Representations. OpenReview.net, 2021. 1–16.

附中文参考文献:

- [1] 邢千里, 刘列, 刘奕群, 张敏, 马少平. 微博中用户标签的研究. 软件学报, 2015, 26(7): 1626–1637. <http://www.jos.org.cn/1000-9825/4655.htm> [doi: 10.13328/j.cnki.jos.004655]
- [8] 张斌, 张引, 高克宁, 郭朋伟, 孙达明. 融合关系与内容分析的社会标签推荐. 软件学报, 2012, 23(3): 476–488. <http://www.jos.org.cn/1000-9825/4001.htm> [doi: 10.3724/SP.J.1001.2012.04001]
- [9] 徐鹏宇, 刘华锋, 刘冰, 景丽萍, 于剑. 标签推荐方法研究综述. 软件学报, 2022, 33(4): 1244–1266. <http://www.jos.org.cn/1000-9825/6481.htm> [doi: 10.13328/j.cnki.jos.006481]
- [12] 王瑜, 武延军, 吴敬征, 刘晓燕. 基于异构网络面向多标签系统的推荐模型研究. 软件学报, 2017, 28(10): 2611–2624. <http://www.jos.org.cn/1000-9825/5132.htm> [doi: 10.13328/j.cnki.jos.005132]
- [13] 马慧芳, 张迪, 赵卫中, 史忠植. 基于超图随机游走标签扩充的微博推荐方法. 软件学报, 2019, 30(11): 3397–3412. <http://www.jos.org.cn/1000-9825/5545.htm> [doi: 10.13328/j.cnki.jos.005545]
- [16] 葛尧, 陈松灿. 面向推荐系统的图卷积网络. 软件学报, 2020, 31(4): 1101–1112. <http://www.jos.org.cn/1000-9825/5928.htm> [doi: 10.13328/j.cnki.jos.005928]



杜晓宇(1986—), 男, 博士, 副教授, CCF 专业会员, 主要研究领域为多媒体推荐, 机器学习.



项欣光(1982—), 男, 博士, 副教授, CCF 专业会员, 主要研究领域为图像处理, 计算机视觉, 多媒体技术.



陈正(1995—), 男, 硕士, 主要研究领域为推荐系统.