(19)国家知识产权局

(12)发明专利申请

(10)申请公布号 CN 119338544 A
(43)申请公布日 2025.01.21

(21)申请号 202411316685.0
(22)申请日 2024.09.20
(71)申请人 北京航空航天大学
地址 100191 北京市海淀区学院路37号
(72)发明人 吴文峻 彭天豪 王政江 戴佩宏 赵鹏瑞 任健
(74)专利代理机构 北京永创新实专利事务所 11121
专利代理师 易卜
(51)Int.Cl.
G06Q 30/0601(2023.01)
G06Q 30/0251(2023.01)
G06F 16/9535(2019.01)
G06N 3/042(2023.01)
G06N 3/0895(2023.01)
G06N 3/084(2023.01)

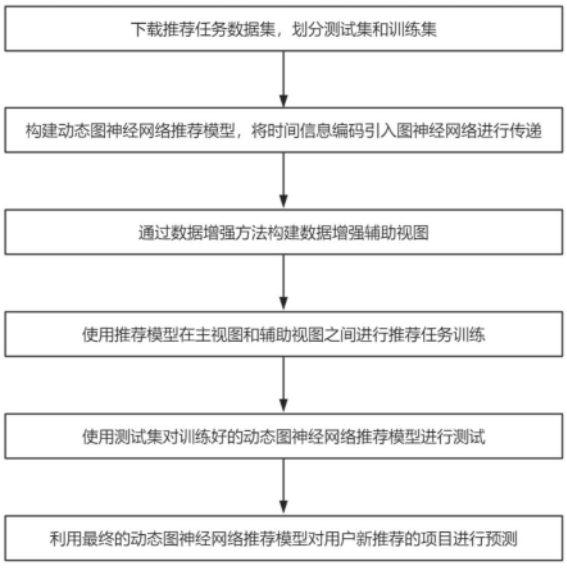
权利要求书2页 说明书10页 附图2页

(54)发明名称

一种对比学习增强的动态图神经网络推荐方法

(57)摘要

本发明公开了一种对比学习增强的动态图神经网络推荐方法,涉及推荐系统领域,具体为:首先,下载推荐任务数据集,并划分测试集和训练集;使用训练集对对比学习增强的动态图神经网络推荐模型进行训练,当输出的预测推荐结果与真实推荐结果的误差在给定阈值范围内,得到训练好的推荐模型的最优可学习参数;然后,使用测试集对训练好的动态图神经网络推荐模型进行测试,得到最终的动态图神经网络推荐模型。利用最终的动态图神经网络推荐模型对用户新推荐的项目进行预测,将预测结果返回给当前用户。本发明更好地挖掘和利用用户对项目资源的潜在兴趣,通过主视图和辅助视图上的跨视图对比学习,增强主视图上的动态图神经网络推荐模型性能。



CN 119338544 A

1.一种对比学习增强的动态图神经网络推荐方法,其特征在于,具体步骤如下:

步骤一、下载推荐任务数据集,并划分测试集和训练集;

步骤二、使用训练集对对比学习增强的动态图神经网络推荐模型进行训练,当输出的预测推荐结果与真实推荐结果的误差在给定阈值范围内,得到训练好的推荐模型的最优可学习参数;

通过计算动态图神经网络推荐模型输出的推荐任务与真实对比学习任务的总体损失,反向传播优化调增模型参数,最终得到训练好的推荐模型;

总体损失表示如下:

$Loss=Loss_{bpr}+\lambda_1 \cdot Loss_{view}+\lambda_2 \cdot Loss_{ssl}$

其中$Loss_{bpr}$为推荐损失,$Loss_{view}$为视图间的结构损失,$Loss_{ssl}$为对比损失,λ_1和λ_2为对应的权重系数;

其中,推荐损失计算如下:

$Loss_{bpr}=\sum(u,i,i',t)\in oT-\log\ \sigma(score(u,i,t)-score(u,i',t))+\lambda||\Theta||_2^2$

其中O_T代表训练集合,$\sigma(\cdot)$为Sigmoid激活函数,Θ为模型的可学习参数;(u,i,i′,t)表示训练集中用户u的交互记录随机采样的负样本;score(u,i,t)为推荐损失使用多层感知机对用户u的嵌入表征进行推荐得分,λ是正则化参数;i和i′是指在训练过程中生成的正负样本对;i表示一个正样本,即用户实际交互过的项目,而i′表示一个负样本,即用户未交互过的项目;

视图间的结构损失计算如下:

$Loss_{view}=SIM(f_e^1,f_e^2)$

其中f_e^1为辅助视图1上的各边丢弃概率,f_e^2为辅助视图2上的各边丢弃概率;

对比损失$Loss_{ssl}$计算公式如下:

$$Loss_{ssl}=\sum_{v_i\in V}-\log\frac{\exp(s(e_i',e_i'')/\tau)}{\sum_{v_j\in V\cap i\neq j}\exp(s(e_i',e_j'')/\tau)}$$

v_i为构造的节点,V为所有构造节点的集合;e_i',e_i''代表节点v_i在不同视图上的嵌入表征,$s(\cdot)$为相似度计算函数,τ为温度系数;

步骤三、使用测试集对训练好的动态图神经网络推荐模型进行测试,得到最终的动态图神经网络推荐模型;

步骤四、利用最终的动态图神经网络推荐模型对用户新推荐的项目进行预测,将预测结果返回给当前用户。

2.如权利要求1所述的一种对比学习增强的动态图神经网络推荐方法,其特征在于,所述步骤一中,数据包括:用户实体、项目资源实体、以及两实体的交互关系;其中交互关系包含交互时间信息。

3.如权利要求1所述的一种对比学习增强的动态图神经网络推荐方法,其特征在于,所述步骤二中,所述推荐得分的计算公式如下:

$score(u,i,t)=MLP(h_u^{(1)}(t)||h_i^{(1)}(t))$

MLP()为多层感知函数;$h_u^{(1)}(t)$为训练集中用户u的1层表征;$h_i^{(1)}(t)$为正样本的1层表征。

4.如权利要求1所述的一种对比学习增强的动态图神经网络推荐方法,其特征在于,所述步骤二中,视图间的结构损失中,构建可学习编码器,刻画用户—项目交互图中的交互边的重要性,生成每条交互边的丢弃概率,根据丢弃概率进行交互边的丢弃;

可学习编码器的公式如下:

$P_e = Encoder(\varepsilon)$

$f_e = GumbelSoftmax(P_e)$

$View_{drop} = AUG_{drop}(\varepsilon, f_e)$

其中,ε为训练集中各交互边的嵌入表征,Encoder为可学习编码器,将边的嵌入转换为概率分布,P_e为产生的各边的丢弃概率,通过GumbelSoftmax激活函数得到应丢弃边索引的独热向量f_e,并根据其生成辅助视图$View_{drop}$。

5.如权利要求1所述的一种对比学习增强的动态图神经网络推荐方法,其特征在于,所述步骤二中,在生成的辅助视图的基础上,进一步基于用户潜在兴趣发现进行数据增强,根据用户的嵌入表征,使用K-means聚类算法对用户群体进行分簇;对每一个分簇,根据训练集数据,构建该簇内所有用户的过往交互项目集合,随后计算用户与项目集合中项目实体间的得分,并根据得分的大小,进行Top-K项目与用户的加边,缓解数据稀疏性问题,公式如下:

$$Top_k(A_{u*}) = \left\{ i_1, i_2, \ldots, i_k \mid A_{ui_1} \geq \cdots A_{ui_j} \geq \cdots \geq A_{ui_{|I|}}, i_j \in \arg sort\,(A_{u*}) \right\}$$

$\varepsilon_{int} = \{(u,i,t) \mid i \in Top_k(A_{u*}) \text{ for all } u \in U\}$

其中A_{u*}表示用户u与所有待选定的项目i_*间的得分,$Top_k(A_{u*})$表示对A_{u*}进行排序并取前Top-K项目,最终生成潜在兴趣加边集合ε_{int},进行数据增强,生成最终的数据增强辅助视图。

一种对比学习增强的动态图神经网络推荐方法

技术领域

[0001] 本发明涉及推荐系统领域,具体涉及一种对比学习增强的动态图神经网络推荐方法。

背景技术

[0002] 推荐系统在社交媒体、流媒体和电子商务等领域扮演着重要角色,在信息爆炸的时代,它们能帮助用户在海量信息中找到感兴趣的内容,提高信息获取的效率,同时也实现了信息的最大化利用。对于企业,推荐系统能吸引和留住用户,提高活跃度和转化率,实现商业目标的持续增长。

[0003] 例如,电子商务的推荐系统可以根据用户的购买历史、浏览行为和个人喜好,推荐个性化的商品,从而提高购买转化率和用户满意度;这些都展示了推荐系统在日常生活中的重要性。除此之外,在社交媒体、在线购物网站和流媒体中,推荐系统利用用户和项目的历史交互序列来预测用户将来可能交互的项目。

[0004] 在现实世界中,用户兴趣和项目受欢迎程度可能会随着时间的推移而改变;使用动态推荐模型实时地捕捉用户和项目的动态变化,更新用户和项目的嵌入表示,做出准确的预测是至关重要的。此外,协同信息在推荐方面也被证明是强大的,有着共同交互项目的用户往往有相似的兴趣。因此,将用户和项目的动态变化与协同信息相结合是动态推荐系统的主要任务之一。

[0005] 图结构能够显式地整合协同信息,图模型将用户-物品交互作为一个二部图,利用用户和物品之间的高阶连通性,将协作信息编码到图结构中。然而,大部分图神经网络推荐模型无法处理动态推荐数据,只适用于静态场景,无法利用物品间的顺序依赖和时间信息。图神经网络推荐模型面临的另一个问题是数据稀疏性和数据噪声,许多用户只与少数物品进行交互,使得推荐模型难以预测用户的潜在兴趣,此外图神经网络推荐模型直接从用户-项目交互图的所有交互边聚集信息来更新用户和项目表示,不但会引入噪声,而且多跳嵌入传播会使噪声信息放大。

[0006] 因此,现有的基于图神经网络的协同过滤模型,可能无法准确捕获用户兴趣并生成准确的推荐结果。

发明内容

[0007] 本发明针对上述问题,提出一种对比学习增强的动态图神经网络推荐方法,实现了在特定领域的个性化任务推荐。

[0008] 所述对比学习增强的动态图神经网络推荐方法,具体步骤如下:

[0009] 步骤一、下载推荐任务数据集,并划分测试集和训练集;

[0010] 数据包括:用户实体、项目资源实体、以及两实体的交互关系;其中交互关系包含交互时间信息。

[0011] 步骤二、使用训练集对对比学习增强的动态图神经网络推荐模型进行训练,当输

出的预测推荐结果与真实推荐结果的误差在给定阈值范围内,得到训练好的推荐模型的最优可学习参数;

[0012] 通过计算动态图神经网络推荐模型输出的推荐任务与真实对比学习任务的总体损失,反向传播优化调增模型参数,最终得到训练好的推荐模型。

[0013] 总体损失表示如下:

[0014] $Loss = Loss_{bpr} + \lambda_1 \cdot Loss_{view} + \lambda_2 \cdot Loss_{ssl}$

[0015] 其中$Loss_{bpr}$为推荐损失,$Loss_{view}$为视图间的结构损失,$Loss_{ssl}$为对比损失,λ_1和λ_2为对应的权重系数。

[0016] 其中,推荐损失计算如下:

[0017] $Loss_{bpr} = \sum (u,i,i',t) \in O_T - \log \sigma(score(u,i,t) - score(u,i',t)) + \lambda ||\Theta||_2^2$

[0018] 其中O_T代表训练集合,$\sigma(\cdot)$为Sigmoid激活函数,Θ为模型的可学习参数;(u,i,i',t)表示训练集中用户u的交互记录随机采样的负样本;score(u,i,t)为推荐损失使用多层感知机对用户u的嵌入表征进行推荐得分,λ是正则化参数,用于控制模型复杂度,防止过拟合;i和i'是指在训练过程中生成的正负样本对。具体来说,i表示一个正样本,即用户实际交互过的项目,而i'表示一个负样本,即用户未交互过的项目。

[0019] 视图间的结构损失计算如下:

[0020] $Loss_{view} = SIM(f_e^1, f_e^2)$

[0021] 其中f_e^1为辅助视图1上的各边丢弃概率,f_e^2为辅助视图2上的各边丢弃概率;

[0022] 对比损失$Loss_{ssl}$计算公式如下:

[0023] $$Loss_{ssl} = \sum_{v_i \in V} -\log \frac{\exp(s(e_i', e_i'')/\tau)}{\sum_{v_j \in V \cap i \neq j} \exp(s(e_i', e_j'')/\tau)}$$

[0024] v_i为构造的节点,V为所有构造节点的集合;e_i',e_i''代表节点v_i在不同视图上的嵌入表征,$s(\cdot)$为相似度计算函数,τ为温度系数。

[0025] 步骤三、使用测试集对训练好的动态图神经网络推荐模型进行测试,得到最终的动态图神经网络推荐模型。

[0026] 步骤四、利用最终的动态图神经网络推荐模型对用户新推荐的项目进行预测,将预测结果返回给当前用户。

[0027] 本发明的优点在于:

[0028] 本发明一种对比学习增强的动态图神经网络推荐方法,通过将时序处理机制引入图神经网络推荐任务,动态学习用户和项目资源的实时嵌入以实现高质量的动态推荐。使用数据增强和对比学习方法来增强图神经网络推荐模型的能力,利用图数据增强模块缓解数据稀疏问题并进行冗余历史交互的去除,引入高质量的训练信息,更好地挖掘和利用用户对项目资源的潜在兴趣,通过主视图和辅助视图上的跨视图对比学习,增强主视图上的动态图神经网络推荐模型性能。

附图说明

[0029] 图1为一种对比学习增强的动态图神经网络推荐方法整体流程图;

[0030] 图2为本发明的模型框架图

[0031] 图3为基于可学习编码器的丢边数据增强流程图

[0032] 图4为基于用户分簇兴趣发现的加边数据增强流程图

具体实施方式

[0033] 为了便于本领域普通技术人员理解和实施本发明,下面结合附图和实施例对本发明作进一步的详细描述。显然,所描述的实施例仅仅是本发明部分的实施例,而不是全部的实施例,基于本发明中的实施例,本领域普通技术人员在没有做出创造性劳动前提下所获得的所有其他实施例,都应当属于本发明保护的范围。

[0034] 本发明公开了一种对比学习增强的动态图神经网络推荐方法,结合时序编码技术与对比学习机制来提高图神经网络推荐方法的推荐性能。本发明通过将位置编码和自注意力机制引入图神经网络表征更新过程,动态学习用户和项目资源的实时嵌入以实现高质量的动态推荐。使用数据增强和对比学习方法来增强图神经网络推荐模型的能力,提出了针对个性化推荐任务的图拓扑数据增强方法,缓解数据稀疏问题并进行冗余历史交互的去除,引入高质量的训练信息,生成辅助的用户-项目资源交互视图,以更好地挖掘和利用用户对项目资源的潜在兴趣,通过主视图和辅助视图的跨视图对比学习机制,提升主视图上的推荐模型性能,实现针对用户的个性化项目资源推荐。

[0035] 所述对比学习增强的动态图神经网络推荐方法,如图1所示,包括步骤如下:

[0036] 步骤一、下载推荐任务数据集,并划分测试集和训练集;

[0037] 数据集主要包括MOOC、MovieLens-100K、Amazon Office Products等,将其构建为二部图形式;数据包括:用户实体、项目资源实体、以及两实体的交互关系;其中交互关系包含交互时间信息,通常将交互行为作为目标行为;将目标行为中选出一部分数据作为测试集,其他数据作为训练集用于模型训练。

[0038] 步骤二、使用训练集对对比学习增强的动态图神经网络推荐模型进行训练,当输出的预测推荐结果接近真实推荐结果,进而对模型中的可学习参数进行调整优化,得到训练好的推荐模型的最优可学习参数;

[0039] 具体训练过程为:

[0040] 步骤2.1、构建动态图神经网络推荐模型;

[0041] 本发明提出的TGAR(Temporal Graph Augmentation Recommend)模型的整体架构如图2所示。该模型主要包含时序信息感知的图注意力层、信息增强辅助视图生成、视图间对比学习损失优化三个部分,对应动态图神经网络推荐模型、图数据增强与对比学习三个模块。

[0042] 原始图数据,经过数据增强模块增强后,与动态图神经网络模块进行对比学习,得到视图间对比学习损失,最后输入到推荐模型。

[0043] 首先,构造时间信息编码函数如下:

[0044] $$\Phi_{d_T}(t) := \sqrt{\frac{1}{d_T}}[cos(\omega_1 t), sin(\omega_1 t), \ldots, cos(\omega_d t), sin(\omega_d t)]$$

[0045] 其中$\Phi_{d_T}(t)$代表时间t的编码向量,ω_i是可训练参数,d_T为时间嵌入的维数。

[0046] 然后,将时间信息编码引入图神经网络信息传递过程,将用户与项目的交互时间信息通过时间编码器进行编码,与原始的用户、项目初始表征向量进行拼接,得到用户、项

目表征；

[0047] 之后，构造节点v_i的l-1层网络的邻居节点的带时序信息的表征，公式如下：

[0048] $$X_{N(v_i,t)}^{(l-1)}(t)=\left[\mathrm{h}_1^{(l-1)}(t_1)\parallel\Phi_{d_T}(t-t_1),\ldots,\mathrm{h}_N^{(l-1)}(t_N)\parallel\Phi_{d_T}(t-t_N)\right]^{\top}$$

[0049] 其中$\mathrm{h}_j^{(l-1)}(t_j)$代表$v_i$的邻居节点$v_j$的l-1层表征。

[0050] 将邻居节点表征与节点v_i的l-1层表征进行映射，以进行后续注意力计算，公式如下：

[0051] $$q(t)=[\mathrm{h}_i^{(l-1)}(t)\parallel\Phi_{d_T}(0)]^{\top}W_Q$$
$$K(t)=X_{N(v_i,t)}^{(l-1)}(t)W_K$$
$$V(t)=X_{N(v_i,t)}^{(l-1)}(t)W_V$$

[0052] 其中$W_Q,W_K,W_V\in\mathbb{R}^{(d+d_T)\times d_{hidden}}$是权重矩阵，用于捕获时间编码和节点特征之间的相互作用。

[0053] 注意力权值$\{\alpha_j(t)\}_{j=1}^{N}$计算公式如下：

[0054] $$\alpha_j(t)=exp\left(q(t)^{\top}K_j(t)\right)/\left(\sum_q exp\left(q(t)^{\top}K_q(t)\right)\right)$$

[0055] 将点积注意力权值与邻居表征矩阵V(t)对应行逐行求和作为邻居的总体表示，公式如下：

[0056] $$h_{N(v_i,t)}^{l}(t)=Attn\big(q(t),K(t),V(t)\big)=\sum_j\alpha_j(t)\cdot v_j(t)$$

[0057] 最终的第l层的节点v_i的嵌入表征，计算公式如下：

[0058] $$\mathrm{h}_i^{(l)}(t)=ReLU\left(\left[\mathrm{h}_{N(v_i,t)}^{l}(t)\parallel\mathrm{h}_i^{(l-1)}(t)\right]W_0^{(l)}+b_0^{(l)}\right)W_1^{(l)}+b_1^{(l)}$$

[0059] 其中$\mathrm{h}_i^{(l)}(t)$表示节点v_i在第l层的时刻t时的嵌入表征，$W_{0,1}^{(l)}$和$b_{0,1}^{(l)}$为l层共享的可学习参数。

[0060] 最后，应用自注意力机制进行时间信息编码的传递与聚合，得到最终用于推荐的用户和项目的嵌入表征；

[0061] 自注意力机制在处理序列数据时，每个元素都可以与序列中的其他元素建立关联，而不仅仅是依赖于相邻位置的元素。该机制通过计算元素之间的相对重要性来自适应地捕捉元素之间的长程依赖关系。

[0062] 推荐损失使用多层感知机(MLP)对用户的嵌入表征和项目的嵌入表征进行推荐得分的计算，公式如下：

[0063] $\mathrm{score}(u,i,t)=\mathrm{MLP}(\mathrm{h_u}^{(1)}(t)||\mathrm{h_i}^{(1)}(t))$

[0064] 其中u代表用户，i代表项目，t代表时刻。

[0065] 再通过采样技术对每个用户-资源真实交互的正样本对，采样获得负样本对，构建评分函数最大化正负样本对间的距离，作为推荐损失反向传播优化推荐模型。

[0066] 每个在训练集中的(u,i,t),即用户与项目资源交互的正样本,根据已知的训练集中用户u的交互记录随机采样一个负样本(u,i′,t),采用BPR损失来最大化正样本得分与负样本得分之间的距离,以此作为损失函数并进行反向传播,公式如下:

[0067] $Loss_{bpr}=\sum(u,i,i',t)\in O_T-\log\sigma(score(u,i,t)-score(u,i',t))+\lambda||\Theta||_2^2$

[0068] 其中O_T代表训练集合,其中包含了(u,i,t)交互正样本对和对应的负样本对(u,i′,t),σ(•)为Sigmoid激活函数,Θ为模型的可学习参数。

[0069] 步骤2.2、构建数据增强辅助视图。

[0070] 数据增强是通过对用户-项目交互图中的交互边进行加边和减边操作,生成辅助视图来优化模型性能。整体框架图如图3所示,原始图数据经过图编码器生成辅助视图,做图结构的对比损失,同时输入推荐模型,得到表征学习的对比损失。在辅助视图中进行新加边和删除边。

[0071] 具体方法如下:

[0072] 1)构建可学习编码器,刻画用户-项目交互图中的交互边的重要性,生成每条交互边的丢弃概率,根据丢弃概率进行交互边的丢弃;

[0073] 可学习编码器的公式如下:

[0074] $P_e=Encoder(\varepsilon)$

[0075] $f_e=GumbelSoftmax(P_e)$

[0076] $View_{drop}=AUG_{drop}(\varepsilon,f_e)$

[0077] 其中,ε为训练集中各交互边的嵌入表征,其可以随推荐任务进行学习更新。Encoder为可学习编码器,如MLP或线性层,将边的嵌入转换为概率分布。P_e为产生的各边的丢弃概率,通过GumbelSoftmax激活函数得到应丢弃边索引的独热向量f_e,并根据其生成辅助视图$View_{drop}$。

[0078] 2)对用户使用聚类算法根据其嵌入表征进行聚类分簇,对同一簇内的用户进行项目集合构建,利用簇内用户与项目集合中项目间的注意力得分,进行用户与得分最高的若干个项目间的加边连接;

[0079] 在生成的辅助视图的基础上,进一步基于用户潜在兴趣发现进行数据增强,根据用户的嵌入表征,使用K-means聚类算法对用户群体进行分簇。对每一个分簇,根据训练集数据,构建该簇内所有用户的过往交互项目集合,随后计算用户与项目集合中项目实体间的得分,并根据得分的大小,进行Top-K项目与用户的加边,缓解数据稀疏性问题,公式如下:

[0080] $$Top_k(A_{u*})=\left\{i_1,i_2,\ldots,i_k \mid A_{ui_1}\geq\cdots A_{ui_j}\geq\cdots\geq A_{ui_{|I|}},i_j\in \arg sort\,(A_{u*})\right\}$$

[0081] $\varepsilon_{int}=\{(u,i,t)|i\in Top_k(A_{u*})\ for\ allu\in U\}$

[0082] 其中A_{u*}表示用户u与所有待选定的项目i_*间的得分,$Top_k(A_{u*})$表示对A_{u*}进行排序并取前Top-K项目,最终生成潜在兴趣加边集合ε_{int},进行数据增强,生成最终的数据增强辅助视图。

[0083] 3)通过加边与剪边的操作对原始用户-项目交互数据进行数据增强,得到数据增强辅助视图,通过计算不同视图间结构的对比损失,最小化不同视图间的互信息,进行反向传播,优化可学习编码器;

[0084] 公式如下：

[0085] $Loss_{view} = SIM(f_e^1, f_e^2)$

[0086] 其中f_e^1为辅助视图1上的各边丢弃概率，f_e^2为辅助视图2上的各边丢弃概率，使用均方误差损失函数MSE进行损失计算，得到生成的辅助视图间的结构损失。

[0087] 步骤2.3、构建不同视图节点的对比学习任务。

[0088] 使用推荐模型在主视图和辅助视图进行推荐任务训练，通过对比学习约束不同条件下相同实体节点表征的一致性，从而优化推荐模型。使用推荐模型在主视图和辅助视图进行推荐任务训练，通过将不同视图下相同的实体节点嵌入表征作为正样本对，不同视图下不同的实体节点的嵌入表征作为负样本对，最小化正样本对的损失函数，最大化负样本对的损失函数，来约束用户和项目表征在不同视图下的一致性，从而优化推荐模型。

[0089] 不同视图间用户、项目嵌入的对比学习任务的损失函数公式如下：

[0090] $$Loss_{ssl} = \sum_{v_i \in V} -\log \frac{\exp(s(\mathbf{e}_i', \mathbf{e}_i'')/\tau)}{\sum_{v_j \in V \cap i \neq j} \exp\left(s(\mathbf{e}_i', \mathbf{e}_j''/\tau\right)}$$

[0091] 其中e'_i，e''_i代表节点i在不同视图上的嵌入表征，s(•)为相似度计算函数，τ为温度系数。

[0092] 步骤2.4、联合步骤2.1-2.3的训练损失，得到推荐任务与对比学习任务的总体损失，通过反向传播优化调增模型参数，在训练集数据上进行训练，得到训练好的推荐模型。

[0093] 模型的总体损失表示如下：

[0094] $Loss = Loss_{bpr} + \lambda_1 \cdot Loss_{view} + \lambda_2 \cdot Loss_{ssl}$

[0095] 其中$Loss_{bpr}$为推荐损失，$Loss_{view}$为视图间的结构损失，$Loss_{ssl}$为对比损失，λ_1和λ_2为权重系数。

[0096] 步骤三、使用测试集对训练好的动态图神经网络推荐模型进行测试，通过调整推荐模型中的超参数来进一步优化动态图神经网络推荐模型，提高模型的推荐评估指标，得到最终的动态图神经网络推荐模型。

[0097] 超参数的调整方式如下：

[0098] 1.测试与评估模型性能：

[0099] 使用测试集对训练好的对比学习增强的动态图神经网络推荐模型进行测试。评估模型性能时，使用了推荐系统中常用的指标：召回率(Recall)和归一化折扣累积增益(NDCG@K)。

[0100] 2.召回率(Recall)：

[0101] 召回率表示模型在推荐列表中找到的真实正样本的比例。公式如下：

[0102] $$Recall_u = \frac{R(u) \cap T(u)}{T(u)}$$

[0103] u表示用户，R(u)表示推荐模型为用户u生成的推荐列表，T(u)表示用户真实交互的项目集合，即真实标签。

[0104] 对所有用户计算上述公式并求均值，即得到推荐模型对于整个数据集的召回率。召回率越高，表示推荐结果越好。

[0105] 3.归一化折扣累积增益(NDCG@K)：

[0106] NDCG@K用于评估推荐结果的排序质量,考虑了推荐结果的顺序。公式如下:

[0107]
$$DCG@K=\sum_{i=i}^{K}\frac{2^{rel_i}-1}{\log_2(i+1)}$$
$$NDCG@K=\frac{DCG@K}{IDCG@K}$$

[0108] 其中,rel_i是第i个位置物品的相关性得分,i是物品的排名。DCG@K表示扣累积增益,结合了推荐列表中项目的相关性和排序质量。IDCG@K表示理想情况下的DCG@K。NDCG值越高,表示推荐结果越好。

[0109] 4.超参数调整:

[0110] 在测试过程中,通过调整推荐模型中的超参数来进一步优化模型性能。具体调整方法包括实验不同的超参数组合,以找到能使模型在召回率和NDCG等评估指标上表现最优的参数设置。

[0111] 步骤四、利用最终的动态图神经网络推荐模型对用户新推荐的项目进行预测,将预测结果返回给当前用户。

[0112] 实施例:

[0113] 参见图1、图2、图3和图4,将对比学习增强的动态图神经网络推荐方法应用到课程推荐任务,具体包含以下步骤:

[0114] 步骤1、下载并构建课程推荐任务数据集,以数据集MOOC为例。

[0115] 其中数据主要包括:学生用户实体、课程资源实体、用户对课程资源实体的注册学习关系,其中注册学习关系包含交互时间信息,将注册学习行为作为预测目标行为。从注册学习行为中选出一部分数据作为测试集,其他数据作为训练集用于模型训练。

[0116] 步骤2、使用训练数据对对比学习增强的动态图神经网络模型进行训练,通过训练使得推荐模型的预测推荐结果接近真实推荐结果,进而对模型中的可学习参数进行调整优化,得到训练好的对比学习增强的动态图神经网络推荐模型。

[0117] 步骤2.1、构建动态图神经网络推荐模型。

[0118] 将时间信息编码引入图神经网络信息传递过程,将学生用户与课程资源交互的时间信息通过时间编码器进行编码,与原始的学生用户、课程资源初始表征向量进行拼接,得到学生用户、课程资源表征;

[0119] 应用自注意力机制进行图上信息的传递与聚合,得到最终用于推荐的学生用户和课程资源的嵌入表征,再通过采样技术获得负样本对,构建评分函数最大化正负样本对间的距离,作为推荐损失反向传播优化推荐模型。

[0120] 步骤2.2通过堆叠动态信息传播与节点嵌入更新层搭建动态图神经网络推荐模型。

[0121] 下面以课程推荐任务实例进行说明模型流程。

[0122] 课程推荐数据是一个二部图,节点有两类分别为学生用户节点和课程资源节点,两类节点间具有连接边代表用户注册学习了该课程资源,边上带有注册学习时间信息。对于在时刻t的学生用户节点v_i,其过往交互的课程资源邻居节点集合为$N(v_i,t)=\{v_1,\cdots,v_N\}$,$v_i$所有的过往资源交互都在与邻居$v_j\in N(v_i,t)$之间进行,并分别发生在$t_j$时刻。

[0123] 动态信息传播与节点嵌入更新层的输入是课程资源邻居节点的嵌入$X_{N(v_i,t)}=$

$\left\{h_1^{(l-1)}(t_1),\ldots,h_N^{(l-1)}(t_N)\right\}$和目标用户节点$v_i$带时间戳的嵌入$h_i^{(l-1)}(t)$。当l＝1时，即对于第一层，输入是初始的节点特征。经过l层后，在时刻t的目标用户节点v_i的时间感知嵌入表示为$h_i^{(l)}(t)$，可将其迭代传递到下一层。由于刻画两个交互之间的相对时间更有意义，因此使用$t-t_1,\cdots,t-t_j$来代替实际交互时间戳来生成时间信息表征。

[0124] 结合图上注意力机制，可以得到邻居$X_{N(v_i,t)}$的实体时间信息表征矩阵为：

[0125] $$X_{N(v_i,t)}^{(l-1)}(t)=\left[h_1^{(l-1)}(t_1)\parallel\Phi_{d_T}(t-t_1),\ldots,h_N^{(l-1)}(t_N)\parallel\Phi_{d_T}(t-t_N)\right]^{\top}$$

[0126] 其中实体嵌入表征和时间信息表征进行拼接，随后将$X_{N(v_i,t)}^{(l-1)}(t)$与用户节点v_i的前一层表征$h_i^{(l-1)}(t)$前项传播给三个线性映射，以获得Query、Key和Value：

[0127] $$q(t)=[h_i^{(l-1)}(t)\parallel\Phi_{d_T}(0)]^{\top}W_Q$$
$$K(t)=X_{N(v_i,t)}^{(l-1)}(t)W_K$$
$$V(t)=X_{N(v_i,t)}^{(l-1)}(t)W_V$$

[0128] 其中$W_Q,W_K,W_V\in\mathbb{R}^{(d+d_T)\times d_{hidden}}$是权重矩阵，用于捕获时间编码和节点特征之间的相互作用。注意力权值$\{\alpha_j(t)\}_{j=1}^{N}$由下式计算得到：

[0129] $$\alpha_j(t)=exp\left(q(t)^{\top}K_j(t)\right)/\left(\sum_q exp\left(q(t)^{\top}K_q(t)\right)\right)$$

[0130] 然后将上述点积注意力权值与课程资源邻居表征矩阵V(t)对应行逐行求和作为课程资源邻居的总体表示：

[0131] $$h_{N(v_i,t)}^{l}(t)=Attn\big(q(t),K(t),V(t)\big)=\sum_j\alpha_j(t)\cdot v_j(t)$$

[0132] 为了将课程资源邻居表示与学生用户节点过往表示相结合，将邻居表示与上一层的学生用户节点表示拼接起来，然后将其传递给前馈神经网络，以生成最终的第l层学生用户节点v_i的嵌入表征：

[0133] $$h_i^{(l)}(t)=ReLU\left(\left[h_{N(v_i,t)}^{l}(t)\parallel h_i^{(l-1)}(t)\right]W_0^{(l)}+b_0^{(l)}\right)W_1^{(l)}+b_1^{(l)}$$

[0134] 其中$h_i^{(l)}(t)$表示学生用户节点v_i在第l层的时刻t时的嵌入表征，$W_{0,1}^{(l)}$和$b_{0,1}^{(l)}$为l层共享的可学习参数。

[0135] 以上示例从用户侧角度出发，介绍了学生用户嵌入表征的生成方式，课程资源实体的嵌入表征生成方法同上，只需将目标中心节点更改为课程资源实体，而邻居节点为相应的学生用户。

[0136] 通过堆叠多个信息传播与节点嵌入更新图层，可以得到不同深度的学习者用户的嵌入表征和课程资源实体的嵌入表征。根据最后一层输出得到的表征，进行推荐损失的更新和反向传播。

[0137] 在推荐部分,使用多层感知机MLP对学习者用户的嵌入表征和课程资源实体的嵌入表征进行推荐得分的计算,score越高,则用户对该课程资源的兴趣就越大,后续交互可能性就越大,得分计算公式如下:

[0138] $$score(u,i,t) = MLP(\mathrm{h}_u^{(l)}(t)||\mathrm{h}_i^{(l)}(t))$$

[0139] 为了在训练阶段计算损失并进行反向传播,为每个在训练集中的(u,i,t),即用户与课程资源交互的正样本,根据已知的训练集中用户u的交互记录随机采样一个负样本(u,i′,t),采用BPR损失来最大化正样本得分与负样本得分之间的距离,以此作为损失函数并进行反向传播,公式如下:

[0140] $$Loss_{\mathrm{bpr}} = \sum_{(u,i,i',t)\in O_T} -\log\,\sigma(score(u,i,t) - score(u,i',t)) + \lambda\|\Theta\|_2^2$$

[0141] 其中O_T代表训练集集合,其中包含了(u,i,t)交互正样本对和对应的负样本对(u,i′,t),σ(•)为Sigmoid激活函数,Θ为模型的可学习参数。

[0142] 步骤2.3、构建数据增强辅助视图。

[0143] 采用可学习编码器刻画学生用户-课程资源交互图中的交互边的重要性,生成每条交互边的丢弃概率,根据丢弃概率进行交互边的丢弃。对学生用户使用聚类算法根据其嵌入表征进行聚类分簇,对同一簇内的用户进行项目集合构建,利用簇内用户与课程资源集合中课程间的注意力得分,进行用户与得分最高的若干个课程资源间的加边连接。通过加边与剪边的操作对原始用户-课程资源交互数据进行数据增强,得到数据增强辅助视图,通过视图间的结构损失来优化可学习编码器。

[0144] 可学习编码器丢边数据增强,根据原有训练集数据,初始化学生-课程资源交互辅助视图,随后在推荐任务过程中,使用可学习的编码器对辅助视图进行学习与更新,根据训练数据中学生用户与课程资源交互边的嵌入表征,生成各交互边丢弃或保留的概率,更新辅助视图,公式所示如下:

[0145] P_e=Encoder(ε)

[0146] f_e=GumbelSoftmax(P_e)

[0147] $\mathrm{View}_{\mathrm{drop}}$=$\mathrm{AUG}_{\mathrm{drop}}$(ε,$f_e$)

[0148] 其中ε为训练集中各交互边的嵌入表征,其可以随推荐任务进行学习更新。Encoder为可学习编码器,如MLP或线性层,它将边的嵌入转换为概率分布,P_e为产生的各边的丢弃概率,通过GumbelSoftmax激活函数得到应丢弃边索引的独热向量f_e,并根据其生成辅助视图$\mathrm{View}_{\mathrm{drop}}$。

[0149] 对于视图间的相似度对比损失,通过计算不同视图间结构的对比损失,最小化不同视图间的互信息,进行反向传播,避免不同的辅助视图收敛为一个,从而生成和利用更丰富的信息。公式如下:

[0150] $$Loss_{view} = SIM(f_e^1, f_e^2)$$

[0151] 其中f_e^1为辅助视图1上的各边丢弃概率,f_e^2为辅助视图2上的各边丢弃概率,使用均方误差损失函数MSE进行损失计算,得到生成的辅助视图间的结构损失。

[0152] 聚类加边数据增强,根据学生用户的嵌入表征,使用K-means聚类算法对学生用户群体进行分簇。对每一个分簇,根据训练集数据,构建该簇内所有用户的过往交互课程资源

集合。计算用户与课程资源集合中课程资源实体间的得分，并根据得分的大小，进行Top-K课程资源与用户的加边，缓解数据稀疏性问题，由此实现基于用户分簇和潜在兴趣发现的图数据增强。公式如下：

[0153] $$\mathrm{Top_k}(A_{u*}) = \left\{ i_1, i_2, \ldots, i_k \mid A_{ui_1} \geq \cdots A_{ui_j} \geq \cdots \geq A_{ui_{|I|}}, i_j \in \arg\mathrm{sort}\,(A_{u*}) \right\}$$

[0154] $\varepsilon_{int} = \{(u,i,t) \mid i \in \mathrm{Top_k}(A_{u*}) \text{ for all } u \in U\}$

[0155] 其中A_{u*}表示用户u与所有待选定的课程资源i_*间的得分，$\mathrm{Top_k}(A_{u*})$表示对A_{u*}进行排序并取前Top-K课程资源，最终生成潜在兴趣加边集合ε_{int}。

[0156] 步骤2.4、构建不同视图节点的比学习任务。使用推荐模型在主视图和辅助视图进行推荐任务训练，通过将不同视图下相同的实体节点表征作为正对，不同视图下不同的实体节点表征作为负对，最小化正对的损失，最大化负对的损失，来约束用户和课程资源表征在不同视图下的一致性，从而优化推荐模型，公式如下：

[0157] $$Loss_{ssl} = \sum_{v_i \in V} -\log \frac{\exp(s(\mathbf{e}_i', \mathbf{e}_i'')/\tau)}{\sum_{v_j \in V \cap i \neq j} \exp\left(s(\mathbf{e}_i', \mathbf{e}_j''/\tau\right)}$$

[0158] 其中e'_i，e''_i代表节点i在不同视图上的嵌入表征，s(•)为相似度计算函数，τ为温度系数。

[0159] 步骤2.5、联合步骤2.2-2.4的训练损失，得到推荐任务与对比学习任务的总体损失，通过反向传播优化调增模型参数，在训练集数据上进行训练，得到训练好的推荐模型。

[0160] 总体的损失公式如下：

[0161] $\mathrm{Loss} = \mathrm{Loss}_{bpr} + \lambda_1 \cdot \mathrm{Loss}_{view} + \lambda_2 \cdot \mathrm{Loss}_{ssl}$

[0162] 其中Loss_{bpr}为推荐损失，Loss_{view}为视图间的结构损失，Loss_{ssl}为对比损失，λ_1和λ_2为权重系数。

[0163] 步骤3、使用测试集对经上述流程训练好的对比学习增强的动态图神经网络推荐模型进行测试，通过调整推荐模型中的超参数来进一步优化训练好的对比学习增强的动态图神经网络推荐模型，提高模型的推荐评估指标，得到最终的对比学习增强的动态图神经网络推荐模型。

[0164] 步骤4、利用最终的对比学习增强的动态图神经网络推荐模型对用户推荐课程项目进行预测，将预测结果返回给当前用户。使用训练好的模型生成用户与课程资源的表征，使用多层感知机模块MLP对学习者用户的嵌入表征和课程资源实体的嵌入表征进行推荐得分的计算，得分score越高，则用户对该课程资源的兴趣就越大，公式如下：

[0165] $$score(u,i,t) = MLP(\mathrm{h}_u^{(l)}(t) || \mathrm{h}_i^{(l)}(t))$$

[0166] 最后取名分数较大K个的课程资源作为当前用户的最终推荐项目，实现Top-K课程资源的推荐。

[0167] 本文中所描述的具体实施例仅仅是对本发明精神作举例说明。本发明所属技术领域的技术人员可以对所描述的具体实施例做各种各样的修改或补充或采用类似的方式替代，但并不会偏离本发明的精神或者超越所附权利要求书所定义的范围。

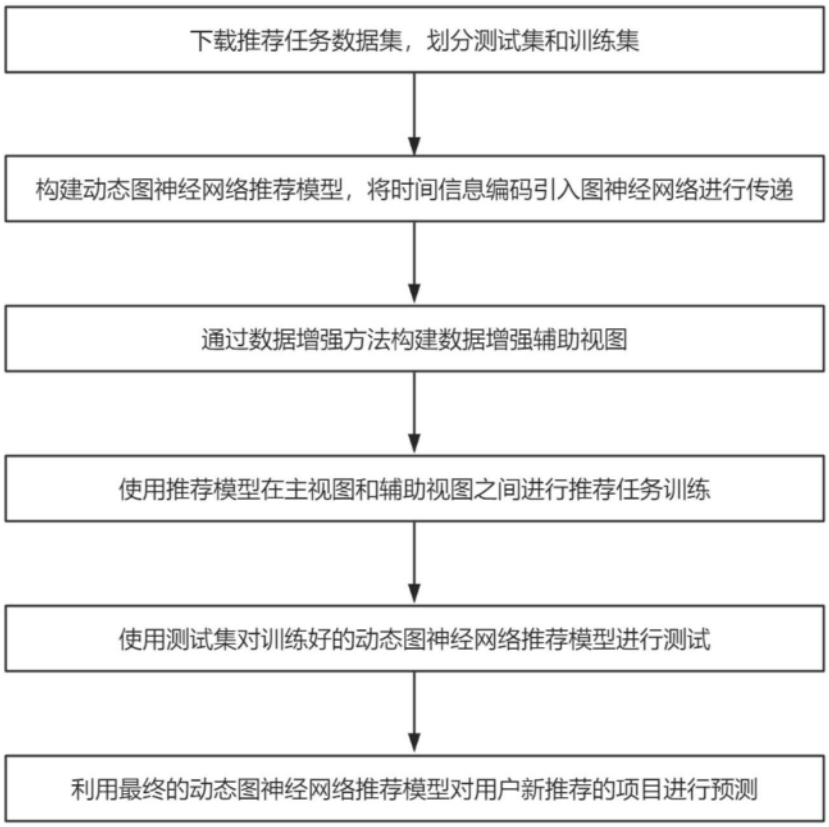

下载推荐任务数据集，划分测试集和训练集
构建动态图神经网络推荐模型，将时间信息编码引入图神经网络进行传递
通过数据增强方法构建数据增强辅助视图
使用推荐模型在主视图和辅助视图之间进行推荐任务训练
使用测试集对训练好的动态图神经网络推荐模型进行测试
利用最终的动态图神经网络推荐模型对用户新推荐的项目进行预测

图1

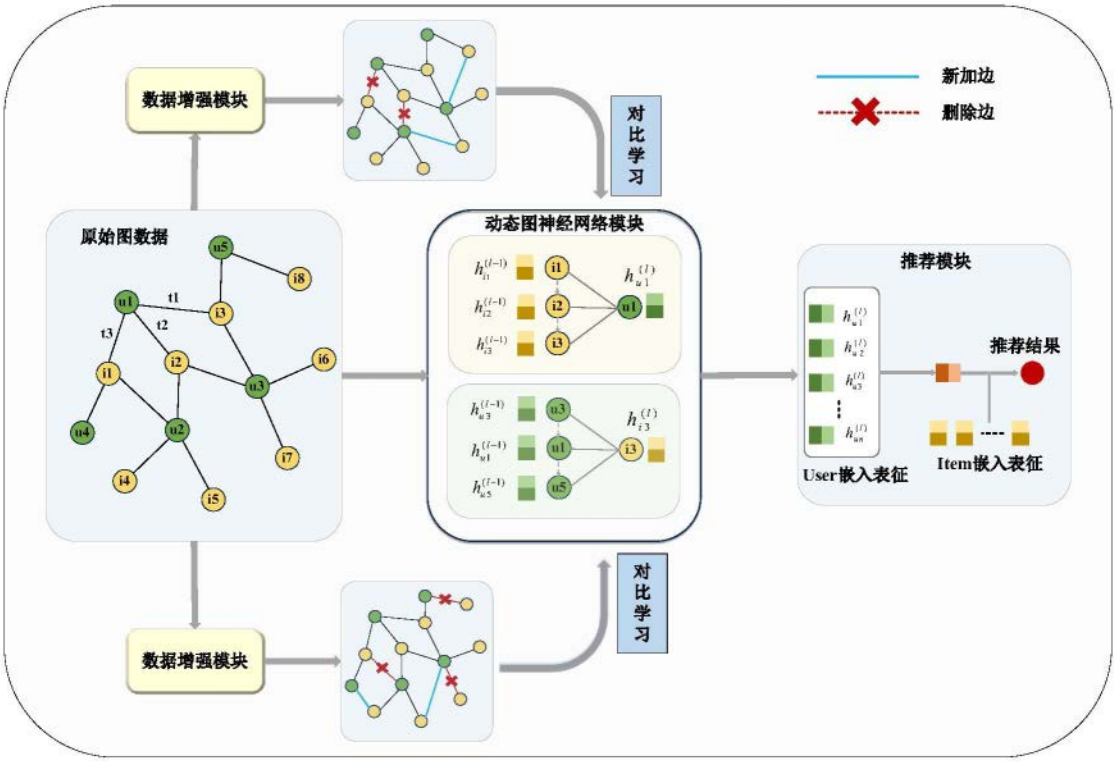

数据增强模块
对比学习
新加边
删除边
原始图数据
动态图神经网络模块
推荐模块
推荐结果
User嵌入表征
Item嵌入表征
数据增强模块
对比学习

图2

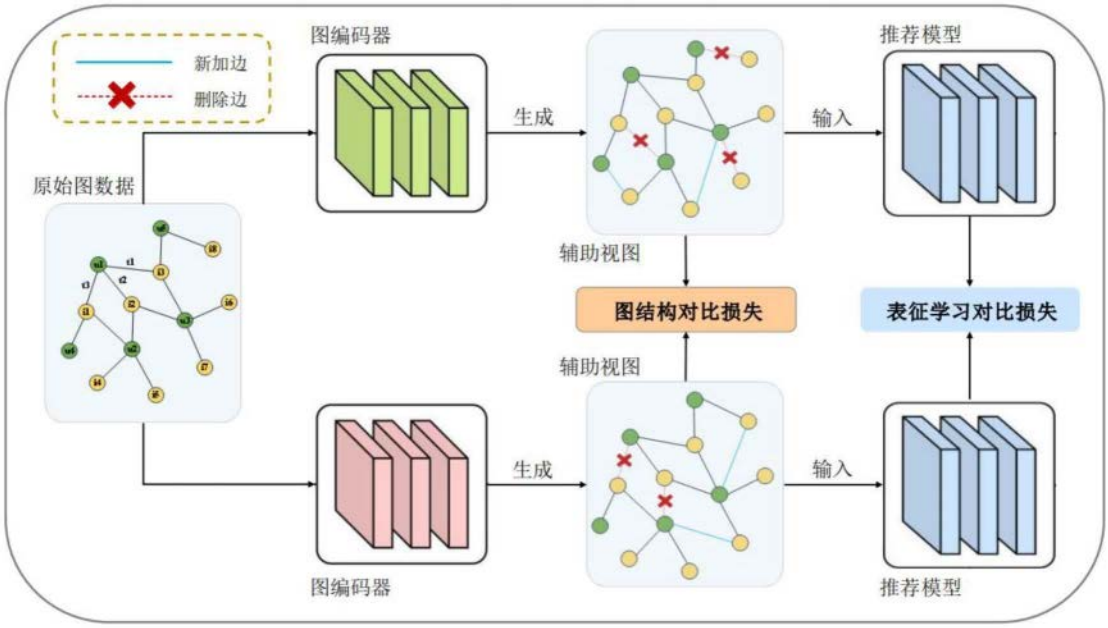

新加边
删除边
图编码器
生成
推荐模型
输入
原始图数据
辅助视图
图结构对比损失
表征学习对比损失
辅助视图
生成
输入
图编码器
推荐模型

图3

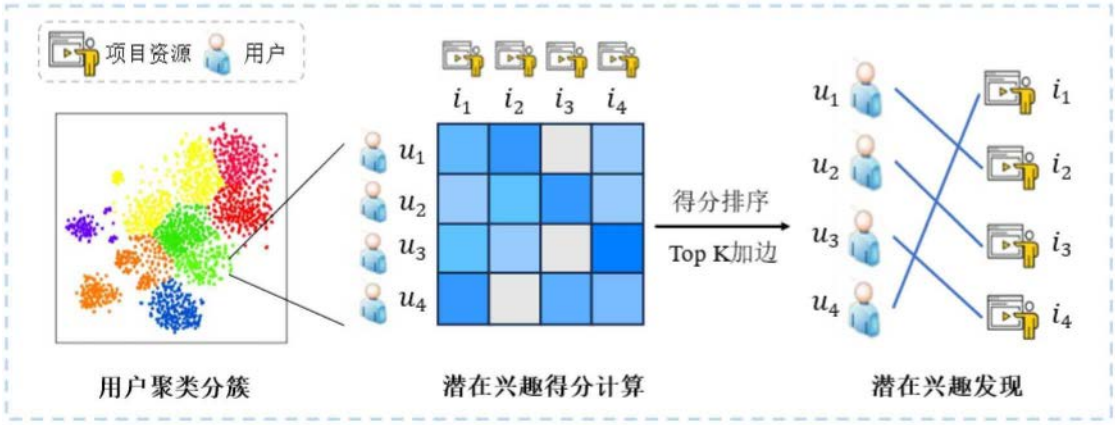

项目资源
用户
i_1 i_2 i_3 i_4
u_1
u_2
u_3
u_4
得分排序
Top K加边
用户聚类分簇
潜在兴趣得分计算
潜在兴趣发现

图4