

结合全局信息的深度图解耦协同过滤

郝敬宇, 文静轩, 刘华锋, 景丽萍, 于剑

引用本文

郝敬宇, 文静轩, 刘华锋, 景丽萍, 于剑 [结合全局信息的深度图解耦协同过滤](#) [J]. 计算机科学, 2023, 50(1): 41-51.

HAO Jingyu, WEN Jingxuan, LIU Huafeng, JING Liping, YU Jian. [Deep Disentangled Collaborative Filtering with Graph Global Information](#) [J]. Computer Science, 2023, 50(1): 41-51.

相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

Similar articles recommended (Please use Firefox or IE to view the article)

[利用异构图神经网络实现情绪-原因对的有效抽取](#)

Utilizing Heterogeneous Graph Neural Network to Extract Emotion-Cause Pairs Effectively
计算机科学, 2023, 50(1): 205-212. <https://doi.org/10.11896/jsjx.211100265>

[基于影响力剪枝的图神经网络快速计算图精简](#)

Fast Computation Graph Simplification via Influence-based Pruning for Graph Neural Network
计算机科学, 2023, 50(1): 52-58. <https://doi.org/10.11896/jsjx.220900032>

[基于图神经网络和依存句法分析的文本分类](#)

Text Classification Based on Graph Neural Networks and Dependency Parsing
计算机科学, 2022, 49(12): 293-300. <https://doi.org/10.11896/jsjx.220300195>

[用于协同过滤的序列解耦变分自编码器](#)

Disentangled Sequential Variational Autoencoder for Collaborative Filtering
计算机科学, 2022, 49(12): 163-169. <https://doi.org/10.11896/jsjx.211200080>

[融合多层次视觉信息的人物交互动作识别](#)

Human-Object Interaction Recognition Integrating Multi-level Visual Features
计算机科学, 2022, 49(11A): 220700012-8. <https://doi.org/10.11896/jsjx.220700012>

结合全局信息的深度图解耦协同过滤

郝敬宇 文静轩 刘华锋 景丽萍 于剑

北京交通大学交通数据分析与挖掘北京市重点实验室 北京 100044

北京交通大学计算机与信息技术学院 北京 100044

(jingyu@bjtu.edu.cn)

摘要 基于 GCN 的协同过滤模型通过用户物品交互二部图上的信息聚合过程生成用户节点和物品节点的表示,预测用户对物品的偏好。然而,这些模型大多没有考虑用户不同的交互意图,无法充分挖掘用户与物品之间的关系。已有的图解耦协同过滤模型建模了用户的交互意图,却忽略了图全局信息,没有考虑用户节点和物品节点的本质特征,造成表示语义不完整;并且由于受到模型迭代结构的影响,意图解耦学习的过程并不高效。针对上述问题,设计了结合全局信息的深度图解耦协同过滤模型 G2DCF(Global Graph Disentangled Collaborative Filtering)。该模型构建了图全局通道和图解耦通道,分别学习节点的本质特征和意图特征;通过引入正交约束和表示独立性约束,使用户-物品的交互意图尽可能唯一防止意图退化,同时提高不同意图下表示的独立性,提升模型的解耦效果。对比已有的图协同过滤模型,G2DCF 能更综合地刻画用户特征和物品特征。在 3 个公开数据集上进行了实验,结果表明 G2DCF 在多个评价指标上优于对比方法;分析了表示分布的表示独立性和表示均匀性,验证了模型的解耦效果;同时从收敛速度上进行了对比,验证了模型的有效性。

关键词: 推荐系统;协同过滤;解耦表示学习;图神经网络;全局信息

中图法分类号 TP181

Deep Disentangled Collaborative Filtering with Graph Global Information

HAO Jingyu, WEN Jingxuan, LIU Huafeng, JING Liping and YU Jian

Beijing Key Lab of Traffic Data Analysis and Mining, Beijing Jiaotong University, Beijing 100044, China

School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China

Abstract GCN-based collaborative filtering models generate the representation of user nodes and item nodes by aggregating information on user-item interaction bipartite graph, and then predict users' preferences on items. However, they neglect users' different interaction intents and cannot fully explore the relationship between users and items. Existing graph disentangled collaborative filtering models model users' interaction intents, but ignore the global information of interaction graph and the essential features of users and items, causing the incompleteness of representation semantics. Furthermore, disentangled representation learning is inefficient due to the iterative structure of model. To solve these problems, this paper devises a deep disentangled collaborative filtering model incorporating graph global information, which is named as global graph disentangled collaborative filtering(G2DCF). G2DCF builds graph global channel and graph disentangled channel, which learns essential features and intent features, respectively. Meanwhile, by introducing orthogonality constraint and representation independence constraint, G2DCF makes every user-item interaction intent as unique as possible to prevent intent degradation, and raises the independence of representations under different intents, so as to improve the disentanglement effect. Compared with the previous graph collaborative filtering models, G2DCF can more comprehensively describe features of users and items. A number of experiments are conducted on three public datasets, and results show that the proposed method outperforms the comparison methods on multiple metrics. Further, this paper analyzes the representation distributions from independence and uniformity, verifies the disentanglement effect. It also

到稿日期:2022-09-28 返修日期:2022-10-22

基金项目:国家自然科学基金(62176020);北京市自然科学基金(Z180006, L211016);国家科技研发计划(2020AAA0106800);中国人工智能学会-华为 MindSpore 学术奖励基金;中国科学院光电信息处理重点实验室开放课题基金(OEIP-O-202004)

This work was supported by the National Natural Science Foundation of China(62176020), Natural Science Foundation of Beijing, China(Z180006, L211016), National Key Research and Development Program(2020AAA0106800), CAAI-Huawei MindSpore Open Fund and Chinese Academy of Sciences(OEIP-O-202004).

通信作者:景丽萍(lpjing@bjtu.edu.cn)

compares the convergence speed to verify the effectiveness.

Keywords Recommender system, Collaborative filtering, Disentangled representation learning, Graph neural network, Global information

1 引言

随着互联网的快速发展以及数字信息的指数级增长,信息过载现象尤为明显,用户难以从海量的信息中找到自己感兴趣的内容,信息也很难被推荐给适合的用户,这一问题恰恰促进了个性化推荐技术的发展。平台/商家可以使用推荐系统在电商平台上向用户展示其可能感兴趣的物品,由此缓解信息过载带来的负面影响。协同过滤^[1]算法是推荐系统中最为人们熟知的一类算法,其主要利用用户和物品的历史交互信息来帮助用户快速地找寻感兴趣的物品。在协同过滤算法中,如何学习得到能够揭示用户真实偏好的用户表示和反映物品自身特性的物品表示至关重要。早期的协同推荐模型大多基于矩阵分解(Matrix Factorization, MF)^[2]的思想,这些模型从交互矩阵中推断用户和物品的表示,具有良好的可扩展性和较高的预测精度,从提出伊始就被广为使用。近年来,图卷积网络(Graph Convolutional Network, GCN)^[3-4]理论快速发展,它可以从图结构数据中提取丰富的信息,因此成为分析解决图问题的重要方法之一。在推荐任务中,用户-物品的交互历史数据本质上就是一个天然的二部图,图中的节点表示用户和物品,边表示用户和物品的交互。GC-MC^[5], NGCF^[6]和 LightGCN^[7]等图协同过滤模型,通过多层信息聚合函数挖掘二部图中的高阶交互信息,学习用户和物品的表示。

尽管 GCN 的引入在一定程度上提升了推荐性能,但这些模型在更新用户和物品表示时对全部邻居的信息进行聚合,没有考虑到用户交互物品的意图,比如用户 u 因为 i_1 当前热度较高而购买物品 i_1 , 因为社交好友的介绍购买物品 i_2 , i_4 和 i_5 , 因为价格优惠购买物品 i_3 , 如图 1 所示。由于用户与物品的交互意图是复杂且多样的,而不同的交互意图可以引起不同的用户行为^[8-11],因此我们可以通过交互历史信息挖掘用户的交互意图,并对不同意图对应的特定物品进行交互建模。

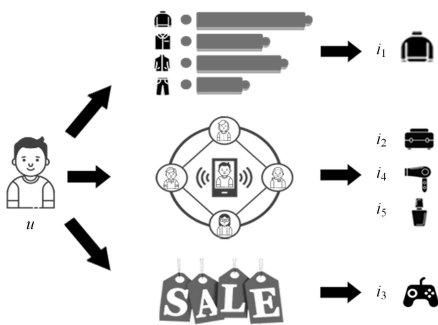


图 1 用户 u 意图特征示意图

Fig. 1 Intent features of user u

DGCF^[12]模型首次将解耦思想应用于图协同过滤任务中。模型为用户的每一个交互生成意图分布,并依据意图概率分布生成用户在不同意图下的向量表示,但是该方法在以下 3 方面有一定局限性。

(1)模型忽略了用户和物品的本质特征。本质特征描述了用户和物品的自身属性,如用户 u 的年龄、性别、地理位置,以及物品 i 的价格、颜色、类别等,如图 2 所示。DGCF 仅通过解耦过程生成意图特征,但没有为用户和物品的本质特征进行建模。




图 2 用户 u 和物品 i 本质特征示意图

Fig. 2 Essential features of user u and item i

(2)模型没有显式地保证不同意图之间的差异,可能会导致意图解耦的退化。

(3)模型通过迭代的过程优化更新节点表示,当面对大规模数据集以及高维特征时,效率差强人意。

为了解决上述问题,本文提出了结合全局信息的深度图解耦协同过滤模型 G2DCF。该模型同时建模了用户节点和物品节点的本质特征与意图特征,使节点能够获得不同角度的信息,从而提升节点的表示能力。G2DCF 包含两个独立的建模通道,图全局通道对节点的全部邻居进行信息聚合,以捕捉用户和物品节点的全局表示,并将其作为本质特征;图解耦通道对用户-物品的交互意图进行建模并生成意图概率分布,依据该意图概率分布对交互图进行划分生成意图子图,并在子图内进行信息聚合和更新,将生成的不同意图下的表示作为意图特征。为了保证用户-物品的交互意图唯一且不同意图下的交互数量相似,模型引入了正交约束来防止意图的退化;同时为了使不同意图下的表示相关性降低,减少表示之间的信息冗余,模型引入了表示独立性约束以提升表示间的独立性。

本文的主要贡献如下:

(1)设计了结合全局信息的深度图解耦协同过滤模型 G2DCF,能够同时建模用户和物品的本质特征与意图特征,提升用户节点和物品节点的表示能力。

(2)引入了正交约束和表示独立性约束,在约束交互意图尽可能唯一的同时提升不同意图表示间的独立性,从而提升模型的解耦效果。

(3)在不同数据集上进行了实验,结果表明 G2DCF 在多个评价指标上优于对比方法,验证了模型的有效性;进一步可视化不同通道生成的表示,并从表示独立性和表示均匀性的

角度对模型进行了解释。

2 相关工作

2.1 解耦表示学习

深度学习通过构建深度且复杂的模型自动地从数据中抽取特征,具有强大的表达能力。然而模型生成的特征往往是耦合的,其高度依赖于特定任务,而且解释性不够强^[13-14]。解耦表示学习旨在学习得到分离式表征,一方面,这样的分离式表征可以代表不同的解释性因子,语义性和解释性更强;另一方面,如果任务和某个解释性因子高度相关,而与其他解释性因子不相关时,分离式表征也能够更好地通过该因子对应地表征解决任务,适用性与迁移性更强。当前的深度解耦模型大多基于自动编码器结构,例如 VAE^[15] 设定潜在特征的分布为高斯分布; β -VAE^[16] 在 KL 散度项上添加超参数 β 对独立性约束和预测精度加以平衡。近年来出现了一些在图网络上做解耦表示学习的工作,如 DisenGCN^[9] 通过邻域路由机制对节点的邻居节点进行划分以表示节点与邻居节点不同的连接原因;IPGDN^[17] 加入了表示独立性的模块以降低表示之间的相关性。

2.2 协同过滤学习

协同过滤(Collaborative Filtering, CF)协同大家的反馈、评价和意见一起对海量的信息进行过滤,从中筛选出目标用户可能感兴趣的信息。协同过滤中的一种代表算法是 MF^[2],它将用户/物品 ID 投影到隐空间中,并根据隐向量预测用户的偏好,比如 CDL^[18] 结合用户交互数据与商品内容辅助信息来学习隐表示;NCL^[19] 模型使用非线性神经网络代替 MF 的内积来学习用户和物品之间的交互。然而上述模型将每个用户-物品交互视为一个单独的数据实例,并没有显式的基于它们的历史交互关系进行建模。之后的一些研究如 SVD++^[20],FISM^[21],NAIS^[22] 将用户的交互历史作为它们的特征,并通过平均聚合或注意力机制将历史交互物品特征整合为用户表示。

在推荐系统中,用户和物品之间的交互数据本质上是一个二部图,传统的协同过滤模型忽略了图中的结构信息,难以对不规则非欧空间中的图数据进行处理,而基于图的推荐模型能更好地捕获用户和物品之间的结构关系。PersonalRank^[23] 利用随机游走的思想生成物品节点的访问概率,并将其作为推荐列表中物品的权重;SpectralCF^[24] 算法引入了图谱理论,在用户-物品交互二部图上进行谱卷积操作,缓解了先前协同过滤遇到的冷启动问题;Hop-Rec^[25] 通过随机游走引入图中的高阶交互信息来平滑观测物品和未知物品之间的严格边界,而且适用于大规模的真实数据集。

近年来,图神经卷积网络(GCN)得到广泛研究与应用。图神经网络是一类基于深度学习的处理图结构数据的方法,它利用边的信息对节点信息进行聚合,生成新的

节点表示或图表示,在众多领域展现出卓越的性能。在推荐任务中,基于 GCN 的协同过滤可以看作是在二部图上的信息传递过程,模型通过图上的信息聚合生成用户和物品的表示,并通过用户和物品的交互得到它们的连接概率或评分。GCMC^[5] 提出了一种变体的图卷积编码器,将交互的每种评分 r 看作一种边类型,并为其分配单独的处理通道。在每个处理通道中,图卷积层执行消息传递任务,考虑节点的一阶交互邻居,将信息沿着图中的边传递聚合。NGCF^[6] 将交互图中的高阶连通信息嵌入到用户和物品的表示学习中,挖掘用户和物品交互过程中潜在的协同信息。LightGCN^[7] 移除了 NGCF 中的权重转换和非线性过程,对图卷积推荐模型进行了简化。最近的一些研究在图学习过程中引入了自监督学习方法,利用辅助任务从数据中挖掘自身的监督信息,通过自我判别增强节点的表示能力。SGL^[26] 通过图增强机制生成用户节点和物品节点的多个视图,最大化同一节点不同视图之间的一致性,为协同过滤提供辅助的监督信号;SimGCL^[14] 取消了图增强机制,通过对表示添加均匀噪声以创建对比视图。DGCF^[12] 受 DisenGCN^[9] 的启发将解耦思想应用于图推荐任务中,通过邻域路由机制生成节点的意图概率分布,并依据该分布对节点表示进行聚合更新。然而 DGCF 只建模了意图特征,没有为用户和物品的本质特征进行建模,忽略了用户和物品的本质特征对于交互预测的重要性;同时模型可能会生成相似的意图子图结构,引起意图解耦的退化;此外模型对节点表示和意图子图进行迭代更新,导致模型效率较低,收敛速度较慢。

3 模型

3.1 问题定义

本节对 G2DCF 模型进行了形式化定义,并给出相关符号的含义说明。

令 $\mathcal{U} = \{u\}$ 表示用户集合, $\mathcal{I} = \{i\}$ 表示物品集合, $\mathcal{R} = \{r_{u,i}\}$ 表示用户和物品间的交互集合,其中 $r_{u,i} = 1$ 表示用户 u 曾和物品 i 发生过交互,否则 $r_{u,i} = 0$ 。将每个用户和物品看作节点,形成节点集合 $\mathcal{V} = \{\mathcal{U}, \mathcal{I}\}$,并在 $r_{u,i} = 1$ 的用户节点和物品节点间构建边 $e_{u,i} = 1$,形成边集合 \mathcal{E} ,由此构建得到交互二部图 $\mathcal{G} = (\mathcal{V}, \mathcal{E})$ 。G2DCF 通过嵌入层将用户 ID u 和物品 ID i 转化为向量化表示。

$$\mathbf{e}_u = f(u), \mathbf{e}_i = f(i) \quad (1)$$

其中, $\mathbf{e}_u, \mathbf{e}_i \in \mathbb{R}^d$ 是用户 u 和物品 i 的向量化表示, $f(\cdot)$ 为嵌入函数, d 为嵌入维度。用户节点和物品节点的初始向量表示由全局表示和解耦表示两部分组成。

$$\mathbf{e}_u = [\mathbf{e}_{u, \text{global}}, \mathbf{e}_{u, \text{dis}}], \mathbf{e}_i = [\mathbf{e}_{i, \text{global}}, \mathbf{e}_{i, \text{dis}}] \quad (2)$$

其中, $\mathbf{e}_{u, \text{global}}, \mathbf{e}_{u, \text{dis}}, \mathbf{e}_{i, \text{global}}, \mathbf{e}_{i, \text{dis}} \in \mathbb{R}^{d/2}$ 。G2DCF 通过图全局通道和图解耦通道分别对用户和物品的全局表示和解耦表示进行建模,挖掘用户和物品的本质特征和意图特征。模型结构如图 3 所示。

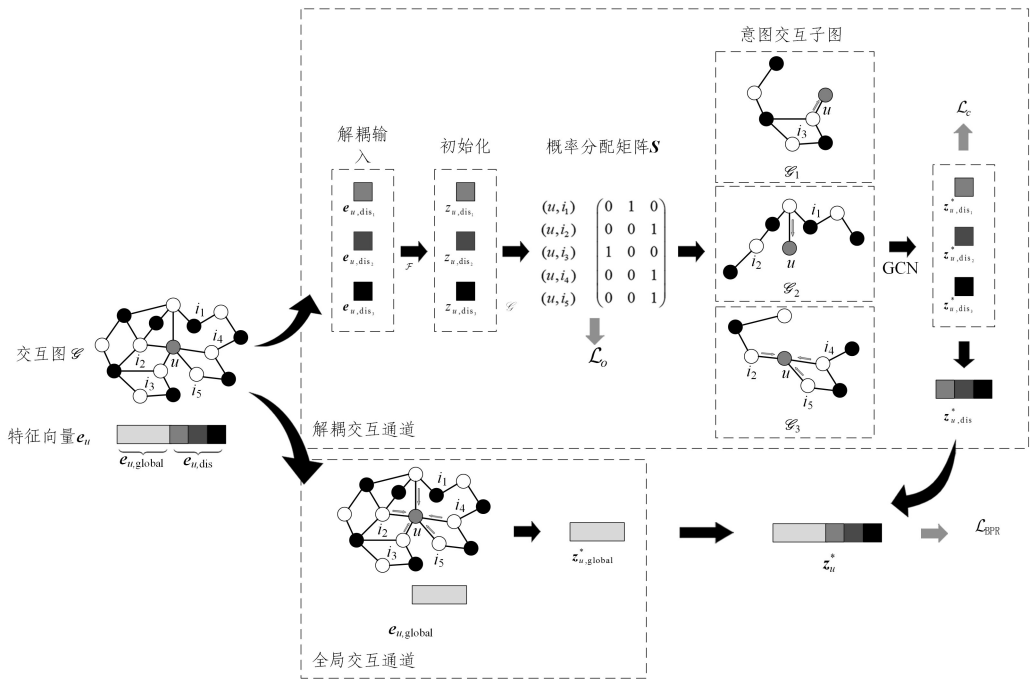


图3 结合全局信息的深度图解耦协同过滤模型图

Fig. 3 Architecture of deep disentangled collaborative filtering with graph global information

本文使用的主要符号定义如表 1 所列。

表 1 符号定义

Table 1 Symbol definition

符号	描述
\mathcal{U}, \mathcal{I}	用户和物品集合
\mathcal{R}	用户-物品交互历史集合
M, N	用户和物品数目
\mathcal{G}	用户物品交互图
\mathcal{V}	交互图节点集合
\mathcal{E}	交互图边集合
A	交互图邻接矩阵
D	交互图度矩阵
d	用户和物品表示嵌入维度
K	意图个数
L	图全局通道 GCN 层数
L'	图解耦通道 GCN 层数

3.2 图全局通道

真实世界中用户和物品都有属于其自身的本质特征,如用户 u 的年龄、性别、地理位置,以及物品 i 的价格、颜色、类别等。这些特征描述了用户和物品的本质属性,而不依赖于用户自身的偏好或意图,因此模型在为用户和物品节点的特征建模时,需考虑节点的全部邻居信息。G2DCF 通过图全局通道对用户 u 的所有交互进行建模,学习用户的本质特征。模型初始化第 0 层的用户表示和物品表示 $\mathbf{z}_{u,\text{global}}^{(0)} = \mathbf{e}_{u,\text{global}}$, $\mathbf{z}_{i,\text{global}}^{(0)} = \mathbf{e}_{i,\text{global}}$, 并依据图 \mathcal{G} 的拓扑结构对用户节点的全部邻居进行信息聚合,生成用户的全局表示。

$$\mathbf{z}_{u,\text{global}}^{(l+1)} = \text{AGG}(\mathbf{z}_{u,\text{global}}^{(l)}, \mathbf{z}_{i,\text{global}}^{(l)}; i \in \mathcal{N}_u) \quad (3)$$

其中, \mathcal{N}_u 表示用户 u 的邻居物品节点集合, $\text{AGG}(\cdot)$ 为聚合函数,该函数通过不同的聚合方式(如拼接、加权平均等),将第 l 层邻居节点的特征进行聚合,并作为第 $(l+1)$ 层的节点表示。基于同样的方法,我们可以得到物品的全局表示。

由于传统的图卷积网络结构中的特征变换与非线性激活函数会加大网络训练的难度^[7,27],导致网络收敛变慢、推荐精度下降,因此在图全局通道中,我们沿用 LightGCN 的聚合方式对节点信息进行聚合。

$$\mathbf{z}_{u,\text{global}}^{(l+1)} = \sum_{i \in \mathcal{N}_u} \frac{1}{\sqrt{|\mathcal{N}_u|} \sqrt{|\mathcal{N}_i|}} \mathbf{z}_{i,\text{global}}^{(l)} \quad (4)$$

$$\mathbf{z}_{i,\text{global}}^{(l+1)} = \sum_{u \in \mathcal{N}_i} \frac{1}{\sqrt{|\mathcal{N}_u|} \sqrt{|\mathcal{N}_i|}} \mathbf{z}_{u,\text{global}}^{(l)}$$

其中, $\frac{1}{\sqrt{|\mathcal{N}_u|} \sqrt{|\mathcal{N}_i|}}$ 为对称归一化项, \mathcal{N}_u 和 \mathcal{N}_i 表示用户 u 和物品 i 的结构邻居集合。G2DCF 使用 L 层 GCN 网络进行信息聚合,并使用加权和函数来组合所有层的表示。

$$\mathbf{z}_{u,\text{global}}^* = \sum_{l=1}^L \alpha_l \mathbf{z}_{u,\text{global}}^{(l)} \quad (5)$$

$$\mathbf{z}_{i,\text{global}}^* = \sum_{l=1}^L \alpha_l \mathbf{z}_{i,\text{global}}^{(l)}$$

其中,模型参照 LightGCN 模型的系数设置 $\alpha_l = 1/(l+1)$ 。经过模型的图全局通道后,我们得到了用户 u 和物品 i 的最终全局表示 $\mathbf{z}_{u,\text{global}}^*$ 和 $\mathbf{z}_{i,\text{global}}^*$ 。

3.3 图解耦通道

用户与物品的交互意图是复杂且多样的,比如用户 u 因为商品热度购买物品 i_1 ,因为社交好友的介绍购买物品 i_2 , i_4 和 i_5 ,因为价格优惠购买物品 i_3 ,如图 1 所示。图解耦通道建模不同意图下用户和物品的交互,将生成的不同意图下的表示作为意图特征。将用户的初始解耦表示 $\mathbf{e}_{u,\text{dis}}$ 拆分为 K 个块,每一块向量对应一个具体的意图特征。

$$\mathbf{e}_{u,\text{dis}} = (\mathbf{e}_{u,\text{dis}_1}, \mathbf{e}_{u,\text{dis}_2}, \dots, \mathbf{e}_{u,\text{dis}_K}) \quad (6)$$

其中 $\mathbf{e}_{u,\text{dis}_k} \in \mathbb{R}^{d/(2 \times K)}$ 表示用户第 k 个意图对应的表示, K 为设定的超参数,表示用户-物品交互的意图个数。DGCF 随机初始化每个块向量,以确保训练开始时意图表示之间的差异。

但在模型 G2DCF 中后续模型要对每一个交互进行建模,用户和物品的特征越相似,用户和物品节点交互的概率似然就越高,而 DGCf 的随机初始化方法无法使模型快速挖掘用户和物品间的相似关系。因此我们添加了一个初始化过程 \mathcal{F} , 以便后续模型生成意图概率分布。由于 GCN 的信息聚合操作会导致平滑现象^[28], 致使相邻节点表示逐渐相似, 因此我们可以使用 GCN 网络对节点进行初始化。

$$\mathbf{Z}_{\text{dis}} = \mathcal{F}(\mathbf{A}, \mathbf{E}_{\text{dis}}) = \text{GCN}(\mathbf{A}, \mathbf{E}_{\text{dis}}) \quad (7)$$

其中, $\mathbf{E}_{\text{dis}} \in \mathbb{R}^{(M+N) \times d/2}$ 为所有节点的初始解耦表示。接下来我们考虑如何定义用户 u 和物品 i 交互的潜在意图。我们定义一个概率函数 ϕ 以衡量用户 u 基于第 k 种意图和物品 i 交互的概率:

$$P(k | r_{u,i} = 1) = \phi(\mathbf{z}_{u, \text{dis}_k}, \mathbf{z}_{i, \text{dis}_k}) \quad (8)$$

其中, $\mathbf{z}_{u, \text{dis}_k}, \mathbf{z}_{i, \text{dis}_k}$ 别表示用户 u 和物品 i 第 k 个意图对应的解耦表示。在 G2DCF 中, 我们使用点积函数^[2,6-7] $\phi(\mathbf{a}, \mathbf{b}) = \mathbf{a}^T \mathbf{b}$ 建模用户和物品的交互, 并通过 softmax^[29] 函数得到用户 u 交互物品 i 的意图概率分布:

$$p_{u,i,k} = P(k | r_{u,i} = 1) = \frac{\exp(\mathbf{z}_{u, \text{dis}_k}^T \mathbf{z}_{i, \text{dis}_k} / \tau)}{\sum_{q=1}^K \exp(\mathbf{z}_{i, \text{dis}_q}^T \mathbf{z}_{i, \text{dis}_q} / \tau)} \quad (9)$$

其中, τ 为 softmax 温度系数。通过上述计算, 我们可以得到交互图 \mathcal{G} 的概率分配矩阵 $\mathbf{S} \in \mathbb{R}^{|\mathcal{E}| \times K}$, 其中 S_m 表示第 m 个交互的意图概率分布。在原始的交互图 \mathcal{G} 中, 边的权重均为 1, 但这样的设置无法区分用户-物品不同的交互意图与交互强度。G2DCF 构建了意图交互子图 $\mathcal{G}_k = (\mathcal{G}, \mathcal{E}_k)$, 其中 $e_{u,i,k} = p_{u,i,k}$ 表示意图交互子图 \mathcal{G}_k 中用户 u 和物品 i 两个节点所连边的权重。G2DCF 在 \mathcal{G}_k 内独立的使用 L' 层 GCN 进行信息聚合, 生成第 k 个意图下的表示。

$$\mathbf{Z}_{\text{dis}_k} = \text{GCN}(\mathbf{A}_k, \mathbf{Z}_{\text{dis}_k}) \quad (10)$$

其中, $\mathbf{Z}_{\text{dis}_k} = [\mathbf{z}_{u_1, \text{dis}_k}, \dots, \mathbf{z}_{u_M, \text{dis}_k}, \mathbf{z}_{i_1, \text{dis}_k}, \dots, \mathbf{z}_{i_N, \text{dis}_k}] \in \mathbb{R}^{(M+N) \times d/(2 \times K)}$, \mathbf{A}_k 表示 \mathcal{G}_k 的邻接矩阵。信息聚合过程完成后, G2DCF 将不同意图下的表示进行拼接, 并将其作为用户节点和物品节点的意图特征。

$$\mathbf{z}_{u, \text{dis}} = \parallel_{k=1}^K \mathbf{z}_{u, \text{dis}_k}^*, \mathbf{z}_{i, \text{dis}} = \parallel_{k=1}^K \mathbf{z}_{i, \text{dis}_k}^* \quad (11)$$

其中, $\mathbf{z}_{u, \text{dis}}^*$ 和 $\mathbf{z}_{i, \text{dis}}^*$ 表示图解耦通道生成用户节点的最终解耦表示和物品节点的最终解耦表示, \parallel 为向量拼接操作。

3.4 正交约束

解耦模型 DGCf 仅依靠初始表示的随机性来确保训练开始时意图之间的差异, 但随着训练过程的进行, 可能会出现交互意图数量不均衡的问题, 极端情况下还会出现所有交互落入同一意图的现象, 导致意图解耦退化。同时用户对物品的交互意图反映了用户的兴趣偏好, 而这样的交互意图应当是特定且唯一的。假如模型得到的意图概率分布趋于均匀分布, 那么模型就不能充分地挖掘出交互的真实意图, 从而影响模型的解耦效果。本文受文献^[30]的启发, 在 G2DCF 中加入了正交约束 \mathcal{L}_o :

$$\mathcal{L}_o = \left\| \frac{\mathbf{S}^T \mathbf{S}}{\mathbf{S}^T \mathbf{S}_F} - \frac{\mathbf{I}_K}{\sqrt{K}} \right\|_F \quad (12)$$

其中, $\|\cdot\|_F$ 为 Frobenius 范数。我们可以将 \mathbf{I}_K 看作 $\hat{\mathbf{S}}^T \hat{\mathbf{S}}$, 其中 $\hat{\mathbf{S}}$ 是目标分配矩阵, 用于约束每一个意图下有 $|\mathcal{E}|/K$ 个交互。该约束期望每一个交互仅属于某一个意图, 同时不同意图的交互数量相似。

3.5 独立性约束

G2DCF 通过图解耦通道生成解耦表示, 而这些解耦表示均来自于原始交互图的图结构 \mathbf{A} 。为了确保模型的解耦表示能够捕获不同的信息, 并减少表示之间的信息冗余, 本文采用了 HSIC^[31] (Hilbert-Schmidt) 独立准则约束表示之间的独立性。HSIC 将表示映射到再生核希伯特空间中以度量它们的相关性, 该相关性对应于原始分布之间的高阶联合矩, 因此可以建模更复杂(如非线性)的相关性; 同时, 该方法能够估计相关性而无须明确估计随机变量的联合分布。因此该准则是一种简单有效的独立性度量, 模型能够通过该准则约束增强两个表示间的差异。由于形式简单、理论简洁, HSIC 已被应用于多个机器学习任务^[32-33]中。对于解耦表示 $\mathbf{Z}_{\text{dis}_x}^*$ 和 $\mathbf{Z}_{\text{dis}_y}^*$, HSIC 约束定义为:

$$\text{HSIC}(\mathbf{Z}_{\text{dis}_x}^*, \mathbf{Z}_{\text{dis}_y}^*) = \frac{1}{(n-1)^2} \text{tr}(\mathbf{H}_X \mathbf{J} \mathbf{H}_Y \mathbf{J}) \quad (13)$$

其中, \mathbf{H}_X 表示 Gram 度量矩阵, $h_{x,i,j} = \kappa_x(\mathbf{z}_{i, \text{dis}_x}, \mathbf{z}_{j, \text{dis}_x})$ 表示节点 i 和节点 j 在 X 空间下的距离度量, 即节点 i 和节点 j 第 x 个意图下的解耦表示间的距离, 对于矩阵 \mathbf{H}_Y 的定义也是相同的。矩阵 $\mathbf{J} = \mathbf{I} - \mathbf{1}\mathbf{1}^T/n$, 其中 \mathbf{I} 为单位矩阵, $\mathbf{1}$ 为值全部为 1 的列向量, κ_x 和 κ_y 为核函数, 在该模型中, 我们简单地使用内积作为核函数。于是模型定义独立性约束 \mathcal{L}_c 如下:

$$\mathcal{L}_c = \sum_{k=1}^K \sum_{k'=k+1}^K \text{HSIC}(\mathbf{Z}_{\text{dis}_k}^*, \mathbf{Z}_{\text{dis}_{k'}}^*) \quad (14)$$

3.6 模型预测优化

G2DCF 将图全局通道和图解耦通道生成的用户表示进行聚合拼接并作为用户的最终表示。

$$\mathbf{z}_u^* = [\mathbf{z}_{u, \text{global}}^*, \mathbf{z}_{u, \text{dis}}^*] \quad (15)$$

同样, G2DCF 可以学习到物品的最终表示 \mathbf{z}_i^* 。接着模型对用户和物品交互建模以重建历史交互。G2DCF 简单地使用内积将预测任务转换为用户和物品之间的相似性估计。

$$\hat{y}_{ui} = \mathbf{z}_u^{*T} \mathbf{z}_i^* \quad (16)$$

模型用 BPR^[34] (Bayesian Personalized Ranking) 作为推荐损失。BPR 是一种成对损失, 它鼓励对观测到的交互的概率预测高于未观测到的交互概率。

$$\mathcal{L}_{\text{BPR}} = - \sum_{u=1}^M \sum_{i \in N_u} \sum_{j \notin N_u} \ln \sigma(\hat{y}_{ui} - \hat{y}_{uj}) + \lambda \|\mathbf{E}\|^2 \quad (17)$$

同时模型将正交约束与独立性约束加入到推荐任务中, 构成模型的推荐损失函数 $\mathcal{L}_{\text{total}}$:

$$\mathcal{L}_{\text{total}} = \mathcal{L}_{\text{BPR}} + \lambda_1 \mathcal{L}_o + \lambda_2 \mathcal{L}_c \quad (18)$$

其中, $\lambda, \lambda_1, \lambda_2$ 控制正则化项和不同损失的大小。

4 实验

4.1 数据集

实验使用 3 个公开的数据集 Filmtrust, Gowalla 和 Ama-

zon-book 对模型进行验证,它们的所属领域、用户物品数量以及稀疏性都不相同。随机选择每个用户 80% 的历史交互作为训练集,其余的作为测试集,从训练集中随机选择 10% 的交互作为验证集来调整超参数。表 2 列出了 3 个数据集的统计信息。

表 2 数据集统计

Table 2 Datasets statistics

Dataset	Users	Items	Interactions	Density
Filmtrust	1 119	1 693	23 366	0.01233
Gowalla	29 858	40 981	1 027 370	0.00084
Amazon book	52 643	91 599	2 984 108	0.00062

(1) Filmtrust 数据集^[35]:从整个 Filmtrust 电影推荐网站上抓取的一个小型数据集,数据集中包含用户 ID、电影 ID 以及对应的评分。将数据集中评分大于或等于 4 的交互作为数据集的交互历史记录,将其他评分的交互删去。为了保证数据集的稀疏性,我们对数据集进行筛选,保证每一个用户 ID 和电影 ID 都存在至少 5 个交互。

(2) Gowalla 数据集^[36]:一个签到数据集,在该数据集中,每条签到记录包括用户 ID、签到时间、签到地点的经纬度以及每个地点经纬度所对应的地点 ID。我们使用用户 ID 和地点 ID 作为数据集的交互历史记录,并保证每一个用户 ID 和地点 ID 都存在至少 10 个交互。

(3) Amazon-book 数据集^[37]:使用数据集中的用户 ID 和购买的书籍 ID 作为数据集的交互历史记录,并保证每一个用户 ID 和书籍 ID 都存在至少 10 个交互。

4.2 实验设置

4.2.1 对比模型

为了验证模型的性能,我们将 G2DCF 模型与以下方法进行比较:

(1) MF^[2],它将用户-物品的交互看作孤立的数据实例,学习用户和物品的嵌入向量,并使用 BPR 损失函数进行模型优化。

(2) NGCF^[6],它将交互二部图中的高阶连通信息嵌入到用户和物品的表示学习中,挖掘用户和物品交互过程中潜在的协同信息。

(3) LightGCN^[7],通过移除 NGCF 中的权重转换和非线性过程,对图卷积推荐模型进行了简化。

(4) SGL^[26],是结合自监督学习进行协同过滤的代表方法,通过数据增强进行对比学习,为协同过滤提供辅助的监督信号。

(5) DGCF^[12],将解耦思想应用于图推荐任务中,通过邻域路由机制生成用户和物品的意图分布,并依据该分布对用户和物品表示进行聚合更新。

4.2.2 评价指标

为了评估模型的 top-N 推荐性能,我们使用 $Recall@N$ 和 $NDCG@N$ ^[38] 计算数据集中每个用户的结果,对用户取平均,并将其作为模型的性能评价指标。 N 的取值为 [10, 20, 50]。

$$Recall_u@N = \frac{|\mathcal{R}(u) \cap \mathcal{T}(u)|}{|\mathcal{T}(u)|} \quad (19)$$

$$NDCG_u@N = \frac{DCG_u@N}{IDCG_u} \quad (20)$$

其中, $\mathcal{R}(u)$ 表示模型为用户 u 推荐的 top-N 物品集合, $\mathcal{T}(u)$ 表示测试集中为用户 u 推荐的物品集合。 $DCG_u@N$ 表示用户 u 的 top-N 推荐物品列表的相关性分数, $IDCG_u$ 表示用户 u 的理想推荐物品列表的相关性分数。

4.2.3 参数设置

本文通过 Tensorflow 实现 G2DCF。为了公平比较,我们设置所有模型的 $batchsize$ 为 4096;在 Filmtrust 以及 Gowalla 数据集中,对于所有的模型,我们将嵌入维度 d 设置为 256;由于 Amazon-book 数据集较大,为了控制模型大小以及收敛速度,我们将模型嵌入维度 d 设置为 128。所有模型使用 Adam^[39] 作为优化器,使用 Xavier^[40] 初始化模型参数,同时使用早停策略防止过拟合现象发生。如果模型在训练集上的 $Recall@10$ 指标上连续 40 轮都没有性能上的提升,模型便结束训练,停止参数更新。 λ, λ_1 和 λ_2 调整范围为 $\{0.0001, 0.001, 0.005, 0.01, 0.05, 0.1\}$, K 调整范围为 $[1, 16]$, L, L' 调整范围为 $[1, 4]$ 。由于 DGCF 模型体积较大且训练时间较长,因此我们使用单层 DGCF 参与对比实验,同时在 4.7 节中也会展示多层 DGCF 在收敛速度上的表现。

4.3 模型整体性能

表 3 列出了 G2DCF 与对比模型在 3 个数据集上的实验结果。通过表 3 我们得出以下几个结论:

(1) G2DCF 在 3 个数据集上与其他方法相比都有性能上的提升。其中,在 Amazon-book 数据集上 $NDCG@10$ 指标最高提升 6.3%。我们认为 G2DCF 性能提升的原因在于:1) 模型通过独立构建图全局通道和图解耦通道生成全局表示和解耦表示,在捕捉节点本质特征的同时能够刻画用户和物品不同的意图偏好;2) 图解耦通道加入了正交约束和表示独立性约束,保证了解耦过程的稳定;3) 图全局通道和图解耦通道均通过多层信息聚合捕捉高阶邻居信息,能够挖掘得到用户和物品的本质特征和高阶交互意图。

(2) DGCF 与 G2DCF 在 Filmtrust 数据集上都有较大的提升。由于 Filmtrust 数据集稀疏性低,数据集中的交互密度要远高于其他两个数据集。DGCF 与 G2DCF 都尝试为用户的交互意图建模,而该过程需要从足够的用户-物品交互中学习。因此我们猜想低稀疏性的数据集更有利于模型学习到用户的交互意图。

(3) G2DCF 在 Amazon-book 上相比 DGCF 性能有明显的提升,而文献^[12]也曾提出, DGCF 相比已有模型性能提升不大的原因可能是用户购买书是一个简单的交互场景,用户并没有复杂的交互意图,更依赖于用户和物品的本质特征。G2DCF 显式地为本质特征进行建模,实验结果验证了先前的猜想。

(4) SGL 模型利用了自监督学习的思想,使用图增强方法生成用户节点和物品节点的多个视图,使用对比学习为

协同过滤提供辅助的监督信号。因为在这个过程中没有涉及模型结构的改变,也没有为用户和物品的表示做解耦,所以与

我们的工作并行的。在未来的工作中我们也可以结合自监督学习的思想来提升模型的性能。

表3 不同模型在3个数据集上的性能对比

Table 3 Performance comparison of different models on three datasets

模型	评价指标	MF	NGCF	LightGCN	SGL	DGCF	G2DCF
Filmtrust	Recall@10	0.50826	0.50724	0.51313	0.51439	0.52250	0.52925
	NDCG@10	0.48579	0.49112	0.49841	0.49471	0.50700	0.51150
	Recall@20	0.72991	0.73460	0.74439	0.73310	0.74265	0.75319
	NDCG@20	0.50814	0.51320	0.51809	0.51451	0.52584	0.52955
	Recall@50	0.87299	0.87966	0.87964	0.88095	0.88137	0.88468
	NDCG@50	0.51245	0.51977	0.52415	0.52017	0.52953	0.53384
Gowalla	Recall@10	0.10860	0.11455	0.12938	0.12848	0.12574	0.13004
	NDCG@10	0.26022	0.28672	0.31724	0.31269	0.31243	0.32032
	Recall@20	0.15948	0.16328	0.18416	0.18375	0.17800	0.18561
	NDCG@20	0.28230	0.30495	0.33537	0.33089	0.33076	0.33859
	Recall@50	0.25806	0.25432	0.28477	0.28561	0.27857	0.28708
	NDCG@50	0.30291	0.32076	0.34880	0.34472	0.34501	0.35187
Amazon book	Recall@10	0.01980	0.02122	0.02412	0.02489	0.02280	0.02548
	NDCG@10	0.06515	0.06649	0.06906	0.07505	0.07414	0.07976
	Recall@20	0.03478	0.03614	0.04185	0.04366	0.04054	0.04476
	NDCG@20	0.08498	0.08645	0.09322	0.09716	0.09660	0.10280
	Recall@50	0.06875	0.07294	0.08002	0.08051	0.08043	0.08357
	NDCG@50	0.11449	0.11775	0.12413	0.12878	0.12915	0.13366

4.4 消融实验

4.4.1 不同通道对模型的影响

在本节中我们验证 G2DCF 仅使用单一通道对模型性能的影响。需要注意的是,验证某一通道的单独性能时需要将另一通道删去,并将嵌入维度由 $d/2$ 变为 d ,以保证 3 个模型的嵌入维度相同。当 G2DCF 仅使用图全局通道时模型等价于 LightGCN。实验结果如图 4 所示,可以看出,我们提出的 G2DCF 性能优于仅使用图全局通道和仅使用图解耦通道的模型,验证了该模型双通道结构对性能的提升。




图4 不同通道对模型性能的影响

Fig. 4 Influence of different channels on model performances

4.4.2 正交约束的影响

实验通过调整 λ_1 来验证正交约束对模型整体性能与图解耦通道性能的影响,实验结果如图 5 所示。可以看到,当 λ_1 较小时,G2DCF 的解耦性能和模型正交损失较低,这是因为当 λ_1 值较小时无法保证模型能得到唯一的交互意图,导致意图概率分布退化为均匀分布,进而使图解耦通道无法生成有效的表示,导致图解耦通道失效,只有图全局通道在起作用;当 λ_1 逐渐增大时,G2DCF 解耦性能明显提升,模型达到最佳性能;随着 λ_1 进一步增大,G2DCF 的正交损失变小,正交约束逐渐主导模型的优化方向,模型整体性能和图解耦通道性能均下降。

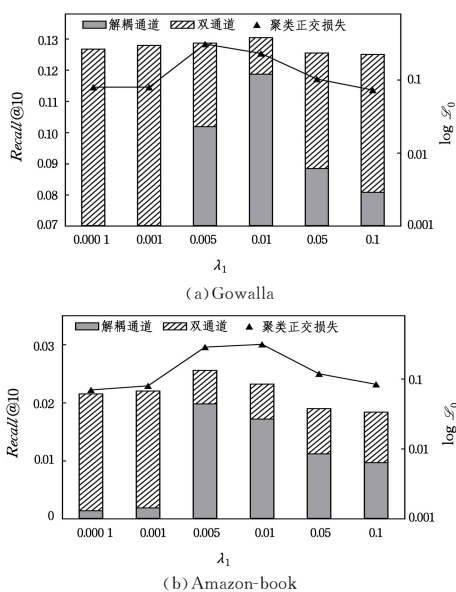


图5 正交约束对模型性能的影响

Fig. 5 Influence of orthogonality constraint on model performances

4.4.3 独立性约束的影响

实验通过调整 λ_2 来验证独立性约束对 G2DCF 整体性能的影响,实验结果如图 6 所示。




图6 独立性约束对模型性能的影响

Fig. 6 Influence of representation independence constraint on model performance

可以看到,独立性约束对模型整体性能影响不大,更多的是对表示分布以及解释性的影响,4.5.1节会对此做进一步的分析与解释。

4.5 表示分布分析

将 G2DCF 不同通道生成的节点表示进行可视化,并与 LightGCN 和 DGCF 对比,从解耦表示独立性和全局表示均匀性两个角度对模型进行解释。

4.5.1 解耦表示独立性

我们通过可视觉解耦表示分布和独立性量化指标来度量 G2DCF 的解耦表示独立性。首先将 DGCF 和 G2DCF 每个

节点不同意图下的表示看作标签不同的单独节点表示,并构建大小为 $K * (M + N)$ 的点集 Z 。LightGCN 按照相同的比例对其生成的节点表示进行切分,并将其作为不同的意图表示。我们将节点表示映射到 2 维空间,并使用 t-SNE^[41] 方法对点集 Z 进行可视化,结果如图 7 和图 8 所示。可以看到,相比 LightGCN, DGCF 和 G2DCF 都有明显的节点分簇现象,不同簇代表不同意图的表示集合,模型可以区分出不同的交互意图;同时,相比 DGCF, G2DCF 有更好的分簇边界,不同簇之间的节点重合更少,说明 G2DCF 的不同意图表示之间有更好的独立性。




图 7 不同模型在 Gowalla 数据集的解耦表示可视化

Fig. 7 Visualization of different models' disentangled representation on Gowalla




图 8 不同模型在 Amazon-book 数据集的解耦表示可视化

Fig. 8 Visualization of different models' disentangled representation on Amazon-book

独立性检验结果如表 4 所列。

表 4 不同模型的表示独立性检验

Table 4 Representation independence test of different models

	Gowalla	Amazon-book
LightGCN	148	1588
DGCF	64	1183
G2DCF	0.51	0.57

接着通过 HSIC 独立准则对不同模型的表示间独立性

进行了量化。 $HSIC(x, y)$ 越低,代表向量 x 与 y 的独立性越强, $HSIC(x, y) = 0$ 即向量 x 与 y 相互独立。可以看到,相比 LightGCN 和 DGCF,模型 G2DCF 生成的解耦表示具有更好的表示独立性。

4.5.2 全局表示均匀性

首先我们将 LightGCN, DGCF 和 G2DCF 的图全局通道生成的全局表示映射到 2 维空间。同样,我们使用 t-SNE 方法进行可视化,结果如图 9 和图 10 所示。




图 9 不同模型在 Amazon-book 数据集的全局表示可视化

Fig. 9 Visualization of different models' global representation on Amazon-book




图 10 不同模型在 Amazon-book 数据集的全局表示可视化

Fig. 10 Visualization of different models' global representation on Amazon-book

可以看到,对于 Gowalla 数据集,DGCF 和 LightGCN 生成的表示都有明显的节点分簇现象,不同簇代表相似节点的表示集合,而 G2DCF 生成的表示更趋近于均匀分布。模型旨在通过图全局通道生成全局表示,并将其作为用户和物品的本质特征。本质特征不依赖于用户自身的偏好或交互意图,而均匀分布更符合我们对本质特征的期望分布。同时,最近的研究^[14,42]指出,均匀分布的表示能够缓解流行度带来的影响,有一定的去偏效应。而在 Amazon-book 数据集中 3 个模型生成的表示都比较均匀,这也恰好验证了 4.3 节中提出的猜想:相较于明确的交互意图,购书行为可能更依赖于用户和物品的本质特征。

接着我们使用距离方差^[43] $dVar(\cdot)$ 来度量不同模型的表示均匀性,结果与可视化得出的结论相同。

$$dVar(\mathbf{X}) = \frac{1}{n^2} \sum_{i=1}^n \sum_{j=1}^n \mathbf{B}_{ij}^2 \quad (21)$$

其中, $n=M+N$ 表示用户节点和物品节点的总个数, \mathbf{B}_{ij} 表示节点 i 和节点 j 的去中心化距离。模型表示均匀性检验结果如表 5 所列。

表 5 不同模型的表示均匀性检验

Table 5 Representation uniformity test of different models

	Gowalla	Amazon-book
LightGCN	0.2571	0.3272
DGCF	0.2885	0.3316
G2DCF	0.2253	0.3261

4.6 参数灵敏度分析

4.6.1 GCN 层数对模型的影响

为了研究不同图全局通道的 GCN 层数 L 和图解耦通道的 GCN 层数 L' 对 G2DCF 性能的影响,我们分别改变 L 和 L' 进行实验,结果如图 11 所示。

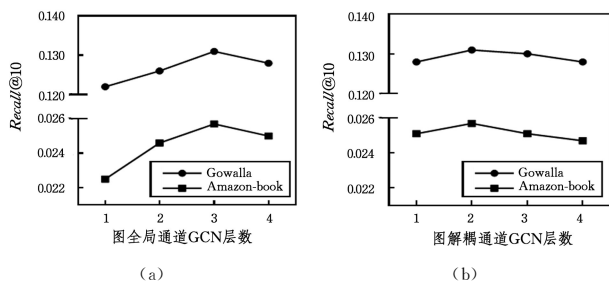


图 11 GCN 层数对模型性能的影响

Fig. 11 Influence of different GCN layer numbers on model performances

可以看到,图全局通道 GCN 层数对模型影响较大,模型达到最好的性能时图全局通道 GCN 层数 $L=3$ 。相较于图全局通道,图解耦通道 GCN 层数对模型影响较小,模型达到最好的性能时图解耦通道 GCN 层数 $L'=2$ 。图解耦通道建模用户和物品的交互意图,而低阶交互信息已经能够有效表示用户的交互意图,高阶交互意图无法提升模型整体性能。

4.6.2 意图个数对模型的影响

我们通过改变 G2DCF 的意图个数 K 来验证不同意图个数对模型的影响,实验结果如图 12 所示。意图个数从 1 增加至 4 的过程中,G2DCF 性能有所提升,这表明随着意图关系的增加模型能够更充分地挖掘用户和物品的交互意图;当意图数目增加时,推荐性能下降,这表明解耦意图数目过多会导致意图过于细粒化,同时每个意图下的表示维度较小,很难完整地描述用户和物品的意图信息。




图 12 意图个数对模型性能的影响

Fig. 12 Influence of different intent numbers on model performances

4.7 时间效率分析

我们对不同层数的 DGCF 与 G2DCF 在 Gowalla 数据集上的训练时间效率进行对比,实验结果如图 13 所示。




图 13 不同模型收敛速度对比

Fig. 13 Comparison of convergence speed of different models

可以看到,随着 DGCF 层数的增加,模型的收敛速度变慢,无法在可行的时间内得到文献^[12]中的实验结论,即在 3 层时 DGCF 达到最佳性能。由于 G2DCF 没有采用意图分布

与意图表示迭代更新的模型结构,而是通过添加初始化过程快速地挖掘用户和物品间的相似关系,生成用户的交互意图分布,因此收敛速度有了明显的提升。同时,随着层数的增加,DGCF模型尺寸逐渐变大,在高维度特征以及大数据集场景下无法进行有效的训练。因此在本文中采用收敛速度与模型尺寸可接受的DGCF-1作为对比模型。

结束语 本文提出了结合全局信息的深度图解耦协同过滤模型G2DCF,模型构建图全局通道和图解耦通道,分别学习节点的本质特征和意图特征;通过引入正交约束和表示独立性约束,驱使每个交互仅属于某一个意图,防止意图退化,同时减少了不同意图下表示间的信息冗余,提升了模型的解耦效果;另外模型避免了DGCF迭代的表示更新过程,提升了模型的训练效率。实验结果表明,相比其他图协同过滤算法,G2DCF在各个数据集上推荐精度都有所提升,并且可以从表示分布的角度对不同特征进行解释。

在未来的工作中,我们会尝试将用户和物品的辅助信息加入学习的过程中,比如用户的评论信息^[44]以及物品的属性信息^[45-46],更好地挖掘用户的交互意图并对模型进行解释。同时我们可以利用自监督思想^[14,26],为解耦表示和全局表示构建对比,更好地对本质特征和意图特征进行区分。此外我们可以参考多行为推荐方法^[47],对不同意图下的表示进行加权融合,更好地刻画用户的意图特征。

参 考 文 献

- [1] SU X, KHOSHGOFTAAR T M. A survey of collaborative filtering techniques[J]. *Advances in Artificial Intelligence*, 2009, 2009(4): 1-19.
- [2] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems[J]. *Computer*, 2009, 42(8): 30-37.
- [3] ZHANG S, TONG H, XU J, et al. Graph convolutional networks: a comprehensive review[J]. *Computational Social Networks*, 2019, 6(1): 1-23.
- [4] WU F, SOUZA A, ZHANG T, et al. Simplifying graph convolutional networks[C]// *International Conference on Machine Learning*. 2019: 6861-6871.
- [5] BERG R V, KIPF T N, WELING M. Graph convolutional matrix completion[C]// *KDD*. 2018.
- [6] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering[C]// *Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2019: 165-174.
- [7] HE X, DENG K, WANG X, et al. Lightgcn: Simplifying and powering graph convolution network for recommendation[C]// *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2020: 639-648.
- [8] CHEN T, YIN H, CHEN H, et al. Air: Attentional intention-aware recommender systems[C]// *2019 IEEE 35th International Conference on Data Engineering (ICDE)*. 2019: 304-315.
- [9] MA J, CUI P, KUANG K, et al. Disentangled graph convolutional networks[C]// *International Conference on Machine Learning*. 2019: 4212-4221.
- [10] MA J, ZHOU C, CUI P, et al. Learning disentangled representations for recommendation[C]// *Proceedings of the 33rd International Conference on Neural Information Processing Systems*. 2019: 5711-5722.
- [11] RAO N, YU H F, RAVIKUMAR P K, et al. Collaborative filtering with graph information: Consistency and scalable methods[C]// *Proceedings of the 28th International Conference on Neural Information Processing Systems*. 2015: 2107-2115.
- [12] WANG X, JIN H, ZHANG A, et al. Disentangled graph collaborative filtering[C]// *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. 2020: 1001-1010.
- [13] LOCATELLO F, BAUER S, LUCIC M, et al. Challenging common assumptions in the unsupervised learning of disentangled representations[C]// *International Conference on Machine Learning*. 2019: 4114-4124.
- [14] YU J, YIN H, XIA X, et al. Are Graph Augmentations Necessary? Simple Graph Contrastive Learning for Recommendation[J]. *arXiv*: 2112.08679, 2021.
- [15] KINGMA D P, WELING M. Auto-encoding variational bayes[C]// *Proceedings of the International Conference on Learning Representations*. 2014.
- [16] HIGGINS I, MATTHEY L, PAL A, et al. beta-vae: Learning basic visual concepts with a constrained variational framework[C]// *Proceedings of the International Conference on Learning Representations*. 2017.
- [17] LIU Y, WANG X, WU S, et al. Independence promoted graph disentangled networks[C]// *Proceedings of the AAAI Conference on Artificial Intelligence*. 2020: 4916-4923.
- [18] WANG H, WANG N, YEUNG D Y. Collaborative deep learning for recommender systems[C]// *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2015: 1235-1244.
- [19] HE X, LIAO L, ZHANG H, et al. Neural Collaborative Filtering[C]// *Proceedings of the 26th International Conference on World Wide Web*. 2017: 173-182.
- [20] 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*. 2008: 426-434.
- [21] KABBUR S, NING X, KARYPIS G. Fism: factored item similarity models for top-n recommender systems[C]// *Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. 2013: 659-667.
- [22] HE X, HE Z, SONG J, et al. Nais: Neural attentive item similarity model for recommendation[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2018, 30(12): 2354-2366.
- [23] HAVELIWALA T H. Topic-sensitive pagerank: A context-sensitive ranking algorithm for web search[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2003, 15(4): 784-96.
- [24] ZHENG L, LU C T, JIANG F, et al. Spectral collaborative filtering[C]// *Proceedings of the 12th ACM Conference on Recommender Systems*. 2018: 311-319.

- [25] YANG J H, CHEN C M, WANG C J, et al. HOP-rec: high-order proximity for implicit recommendation[C]// Proceedings of the 12th ACM Conference on Recommender Systems. 2018: 140-144.
- [26] WU J, WANG X, FENG F, et al. Self-supervised graph learning for recommendation[C]// Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2021: 726-735.
- [27] WU F, SOUZA A, ZHANG T, et al. Simplifying graph convolutional networks [C] // International Conference on Machine Learning. 2019: 6861-6871.
- [28] YU W, QIN Z. Graph convolutional network for recommendation with low-pass collaborative filters[C]// International Conference on Machine Learning. 2020: 10936-10945.
- [29] JANG E, GU S, POOLE B. Categorical reparameterization with gumbel-softmax[C] // Proceedings of the International Conference on Learning Representations. 2017.
- [30] BIANCHI F M, GRATTAIOLA D, ALIPPI C. Spectral clustering with graph neural networks for graph pooling[C]// International Conference on Machine Learning. 2020: 874-883.
- [31] SONG L, SMOLA A, GRETTON A, et al. Supervised feature selection via dependence estimation [C] // Proceedings of the 24th International Conference on Machine learning. 2007: 823-830.
- [32] GRETTON A, BOUSQUET O, SMOLA A, et al. Measuring statistical dependence with Hilbert-Schmidt norm[C]// International Conference on Algorithmic Learning Theory. 2005: 63-77.
- [33] NIU D, DY J G, JORDAN M I. Multiple non-redundant spectral clustering views [C] // International Conference on Machine Learning. 2010: 831-838.
- [34] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[C]// Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence. 2009: 452-461.
- [35] GOLBECK J, HENDLER J A. FilmTrust: movie recommendations using trust in web-based social networks[C]// Consumer Communications and Networking Conference. 2006: 282-286.
- [36] LIANG D, CHARLIN L, MCINERNEY J, et al. Modeling user exposure in recommendation[C]// Proceedings of the 25th International Conference on World Wide Web. 2016: 951-961.
- [37] HE R, MCAULEY J. Ups and downs: Modeling the visual evolution of fashion trends with one-class collaborative filtering [C]// Proceedings of the 25th International Conference on World Wide Web. 2016: 507-517.
- [38] HERLOCKER J L, KONSTAN J A, TERVEEN L G, et al. Evaluating collaborative filtering recommender systems [J]. ACM Transactions on Information Systems, 2004, 22(1): 5-53.
- [39] KINGMA D P, BA J. Adam: A method for stochastic optimization[C]// Proceedings of the International Conference on Learning Representations. 2015.
- [40] GLOROT X, BENGIO Y. Understanding the difficulty of training deep feedforward neural networks[C]// Proceedings of the Thirteenth International Conference on Artificial Intelligence and Statistics. 2010: 249-256.
- [41] VAN DER MAATEN L, HINTON G. Visualizing data using t-SNE[J]. Journal of machine learning research, 2008, 9: 2579-2605.
- [42] WANG T, ISOLA P. Understanding contrastive representation learning through alignment and uniformity on the hypersphere [C] // International Conference on Machine Learning. Virtual Event, USA, 2020: 9929-9939.
- [43] SZÉKELY G J, RIZZO M L, BAKIROV N K. Measuring and testing dependence by correlation of distances[J]. The Annals of Statistics, 2007, 35(6): 2769-2794.
- [44] CHENG Z, DING Y, ZHU L, et al. Aspect-aware latent factor model: Rating prediction with ratings and reviews[C]// Proceedings of the 2018 World Wide Web Conference. 2018: 639-648.
- [45] LI C, QUAN C, PENG L, et al. A capsule network for recommendation and explaining what you like and dislike[C]// Proceedings of the 42nd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2019: 275-284.
- [46] SUN C, LIU H, LIU M, et al. LARA: Attribute-to-feature adversarial learning for new-item recommendation[C]// Proceedings of the 13th International Conference on Web Search and Data. 2020: 582-590.
- [47] JIN B, GAO C, HE X, et al. Multi-behavior recommendation with graph convolutional networks[C]// Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2020: 659-668.



HAO Jingyu, born in 1998, master, is a member of China Computer Federation. His main research interests include graph representation learning and recommender system.



JING Liping, born in 1978, Ph.D, professor, is a member of China Computer Federation. Her main research interests include machine learning, high dimensional data representation and their applications in artificial intelligence.

(责任编辑:何杨)