

融合知识图卷积网络的双端邻居推荐算法

胡婷婷, 黄刚*, 吴长旺

(南京邮电大学 计算机学院、软件学院、网络空间安全学院, 江苏 南京 210023)

摘要:针对现有的基于知识图谱的推荐对于用户信息的考虑少于对物品信息的考虑,提出一种融合知识图卷积网络的双端邻居推荐算法,在用户端及物品端同时进行特征提取。对于用户特征的提取,是通过用户偏好在知识图谱中的扩散过程实现。对于物品特征的提取,是将邻居信息聚合到物品节点生成嵌入向量,因各个邻居的权重与用户点击物品的邻居节点紧密联系,因此基于 KGCN 模型来实现。最后让用户兴趣传播与物品特征聚合交替进行。在两个数据集上进行对比实验,在 MovieLens-1M 数据集上,与基线方法相比,AUC 和 F1 分别提升了 1.5% 和 2.0%,在 Book-Crossing 数据集上,AUC 和 F1 分别提升了 5.3% 和 1.9%,算法有效性得到显著提升。

关键词:知识图谱;KGCN;推荐系统;用户偏好;准确性

中图分类号:TP309

文献标识码:A

文章编号:1673-629X(2022)10-0034-07

doi:10.3969/j.issn.1673-629X.2022.10.006

A Two-endian Neighbor Recommendation Algorithm for Convolutional Networks Fused with Knowledge Graph

HU Ting-ting, HUANG Gang*, WU Chang-wang

(School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210023, China)

Abstract: Aiming at the fact that the existing recommendation based on knowledge graph pays less attention to user information than item information, a two-end neighbor recommendation algorithm based on knowledge graph convolution network is proposed to extract features at both user and item sides. The extraction of user personalized features is carried out through the diffusion process of user preferences in the knowledge graph. For item feature extraction, neighbor information is aggregated to item node to generate embedding vector. Since the weight of each neighbor is closely related to the neighbor node of the item clicked by the user, the vector of item feature is extracted based on KGCN model. Finally, user interest dissemination and item feature aggregation are carried out in turn. Comparison experiments were conducted on two data sets. Compared with baseline method, AUC and F1 improved by 1.5% and 2.0% respectively on Movielens-1M data set, while AUC and F1 improved by 5.3% and 1.9% respectively on Book-Crossing data set. The effectiveness of the proposed algorithm has been significantly improved.

Key words: knowledge graph; KGCN; recommendation system; user preference; accuracy

0 引言

信息技术以及互联网环境的不断发展使得信息过载问题亟待解决,个性化推荐作为大数据时代的产物,发挥的作用越来越重要。为了帮助用户在海量数据中挑选出自己感兴趣的内容,提高用户体验,推荐系统^[1]在电影^[2]、广告^[3]、新闻^[4]等推荐场景中得到了广泛应用。虽然关于推荐系统的研究以及应用已取得极大的进展,但还是面临着诸多挑战,比如常见的数据稀疏性以及冷启动^[5]问题。传统的推荐算法主要分为基于协同过滤^[6]的推荐算法、基于内容的推荐算法以及混合推荐算法,这些算法更加侧重于挖掘用户与物品之

间的静态相关性,但忽略了随着时间的推进而导致的用户兴趣的衰减以及偏好的动态变化。

随着技术的不断发展,互联网上越来越多的数据能够被感知获取,比如用户评论的文本、社交信息、图像以及项目属性,研究者通过加入这些辅助信息来提高推荐性能。知识图谱旨在描述真实世界中客观存在的各种实体及其关系,构成了一张巨大的语义网络图,将各种辅助信息融入推荐算法中,包含丰富的物品信息,便于缓解推荐的数据稀疏以及冷启动问题。同时知识图谱^[7]具有以下特征:(1)精确性:知识图谱中物品之间丰富的语义相关信息有助于探索各物品之间的

收稿日期:2021-11-02

修回日期:2022-03-09

基金项目:江苏省教育基金资助项目(17JS010);中国电信公司江苏分公司基金资助项目(DGJ02)

作者简介:胡婷婷(1996-),女,硕士,研究方向为推荐系统、知识图谱;通讯作者:黄刚(1961-),男,教授,研究方向为数据挖掘。

潜在联系从而提高推荐准确性;(2)多样性:知识图谱中各个类别的关系可以挖掘用户潜在兴趣,合理地发散推荐结果,提高推荐结果的多样性;(3)可解释性:知识图谱可以连接用户的历史点击记录和推荐记录,为推荐结果提供可解释性。虽然知识图谱有上述优点,但是知识图谱具有高维性以及异构性,如何高效地利用知识图谱进行推荐仍然是一个巨大的挑战。基于嵌入方法是一种可行的解决方案,通过将知识图谱中的实体或者关系映射到连续的低维向量空间中,得到实体或者关系的表征来扩充用户以及物品之间的语义信息。一些典型的知识图谱嵌入方法主要分为两类:基于翻译的模型,比如 TransE^[8]、TransR^[9]、TransH^[10]、TransD^[11]等;语义匹配模型,如 DistMult^[12]、CompLex^[13]等。但它们更适合知识图谱的补全等知识图内的应用,并不适用于推荐。为了更加充分利用知识图内的有效信息,提出了用图神经网络来挖掘知识图谱中的潜在特征,以此来提取用户与项目之间不同的特征关系。Wang 等人提出了 KGAT^[14](Knowledge Graph Attention Network)方法,该方法将用户-物品二部图与知识图谱融合在一起,形成一种新的网络结构,并从该网络结构中递归邻居传播学习节点嵌入,并通过注意力机制区分各邻居嵌入的重要性。Wang 等人提出了 RippleNet^[15]与 KGCN^[16]方法,其中 RippleNet 在知识图谱中以用户交互过的物品为中心,逐层向外进行扩散,实现用户特征的提取。KGCN 旨在通过项目节点的邻居与项目节点的聚合得到项目的个性化特征。但是上述方法仅仅只能聚合一端邻居而无法有效确定目标物品与目标用户之间的关系。

基于上述研究,该文提出了一种融合知识图卷积网络与用户偏好的双端邻居推荐算法。在用户端及物品端同时进行特征向量的提取,从而进一步提升推荐的性能。此方法将知识图谱视作有权图,通过注意力机制将关系变为权重,此权重可以理解为该关系影响用户行为的偏好程度,之后从知识图谱的中心出发,迭代地向邻部扩张,之后通过邻居聚合或拼接聚合的方式得到物品的特征向量。其中对于用户特征的提取是通过用户偏好在知识图谱中的扩散过程实现,最后让用户兴趣传播与物品特征聚合交替进行,共享当前已知信息,从而优化推荐结果。

1 相关工作

1.1 KGCN 模型

KGCN(KnowledgeGraph Convolutional Networks)模型是知识图谱与图神经网络结合的典型示例。其中中心思想就是利用图神经网络的消息传递机制与基本推

荐思想相结合进行训练,从而得到知识图谱结构的数据特征。如图 1(a)所示,以目标物品为中心向外层进行扩散,向外扩散的过程可以视为在知识图谱中以目标物品作为起点进行广度优先遍历。因为每个扩散的路径只有关系存在不同,计算对应路径的权重时仅考虑关系对于用户的重要性,例如,一个用户可能看重电影的主演明星,而另一个用户可能更关注电影的类型。因此,路径的方向将不再重要,所以将知识图谱视为无向图。然后将扩散得到的节点再向内聚合,再将目标物品本身的嵌入向量与其周围的嵌入向量再进行一次消息聚合,以及走一次或者多次全连接层的操作得到物品的特征向量。KGCN^[16]模型如图 1(b)所示,整个模型以用户 id 以及物品 id 作为输入,第一次聚合选择遍历深度为 1 的实体,第二次聚合选择遍历深度为 2 的实体,在知识图谱上进行多层聚合得到物品特征向量,将其与嵌入向量表示的用户特征向量计算得到用户对物品的预测兴趣值。涉及的概念如下:

$N(v)$ 表示知识图谱中的实体 v 直接相连的实体集合。 r_{e_i, e_j} 表示知识图谱中实体 e_i 与 e_j 的关系向量。

$$w_{r_i}^u = g(u, r_i) \quad (1)$$

公式表示用户 u 对关系 r 的喜好程度,注意此处的 $u, r_i \in R^d$, $w_{r_i}^u \in R$ 。 g (如内积操作)表示降维操作,用来计算用户与实体关系的分数, d 表示维度。一般来说, $w_{r_i}^u$ 表示关系 r_i 对于用户 u 的重要性。比如,用户可能更注重电影的导演,而有的用户则更看重电影的主演明星。

之后对偏好程度 $w_{r_i}^u$ 通过 softmax 操作进行归一化处理,得到规范化的用户关系评分 $\tilde{w}_{r_i}^u$,具体为:

$$\tilde{w}_{r_i}^u = \text{softmax}(w_{r_i}^u) = \frac{\exp(w_{r_i}^u)}{\sum_{j \in N(v)} \exp(w_{r_j}^u)} \quad (2)$$

其中, $N(v)$ 表示物品 v 的一阶邻居集,然后再进一步进行加权求和操作得到特征向量 \tilde{v} ;具体的,通过计算规范化的用户关系评分与物品 v 直接连接的节点 e_i 的线性组合,也就是物品 v 的特征向量 \tilde{v} :

$$\tilde{v} = \sum_{j \in N(v)} \tilde{w}_{r_j}^u e_j \quad (3)$$

通过聚合函数 $\text{agg}(\tilde{v}, e)$ 进行聚合,并计算得到代表物品 v 的物品个性化特征 v^u ,具体的,聚合过程中进行一次或多次全连接层的操作,具体表达式为:

$$v^u = \sigma(w \cdot \text{agg}(\tilde{v}, e) + b) \quad (4)$$

其中, $\sigma(\cdot)$ 为非线性激活函数,例如 sigmoid、relu 等, W 为线性变换矩阵, b 为偏置项, $\text{agg}(\tilde{v}, e)$ 表示对物品 v 进行聚合, e 表示物品 v 在前一轮迭代更新产生的向量。

聚合函数 $\text{agg}(\tilde{v}, e)$ 可采取以下三种方法对物品 v

进行聚合:

(1) 聚合函数 $\text{agg}(\tilde{v}, e)$ 为求和聚合, 通过 $\tilde{v} + e$ 对应元素位相加, 然后进行非线性变换, 具体为:

$$\text{agg}_{\text{sum}}(\tilde{v}, e) = \tilde{v} + e \quad (5)$$

(2) 聚合函数 $\text{agg}(\tilde{v}, e)$ 为拼接聚合, 通过连接两个表示向量, 然后应用非线性变换, 具体为:

$$\text{agg}_{\text{concat}}(\tilde{v}, e) = \tilde{v} \parallel e \quad (6)$$

(3) 聚合函数 $\text{agg}(\tilde{v}, e)$ 为邻居聚合, 通过直接 \tilde{v} 用作本层输出向量, 具体为:

$$\text{agg}_{\text{neighbor}}(\tilde{v}, e) = \tilde{v} \quad (7)$$

根据公式(1)~公式(5), 如图 1(a)所示, 不断从外向内聚合, 将节点的信息聚合到物品节点。最终形成物品节点的向量表示 v^u 。

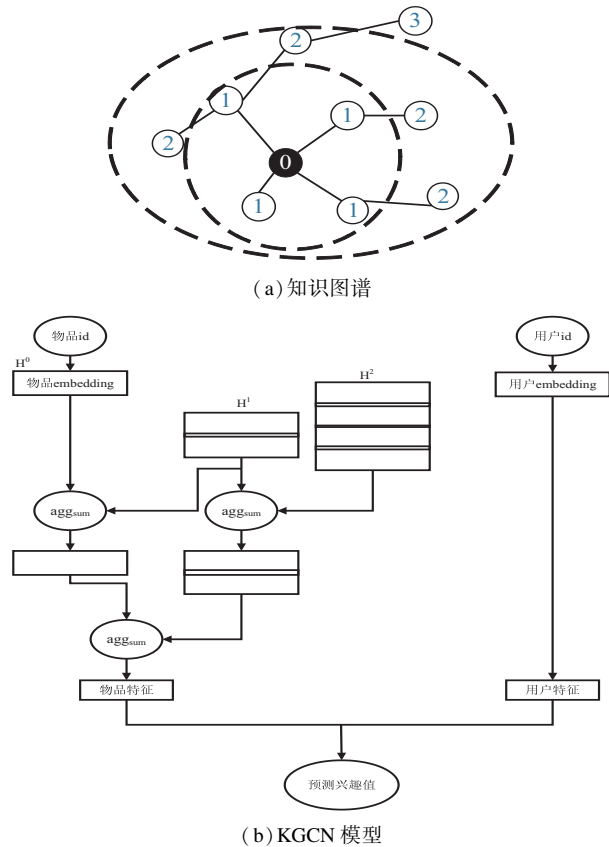


图 1 知识图谱与 KGCN 模型

1.2 RippleNet 模型

知识图谱中包含大量的实体间的相互关系, 通过对知识图谱中复杂的联系进行研究, 进而可得到用户潜在的兴趣与偏好。例如: 某个用户已经观看过《长津湖》这部电影, 他可能是主演吴京的粉丝, 又或者他喜欢导演陈凯歌的风格, 也可能是喜欢看战争片, 然而吴京还出演过其他更多优秀的作品, 导演陈凯歌也不只执导过这一部电影, 战争片也包含其他优秀的作品。在知识图谱中与电影《长津湖》相关的实体, 用户可能都感兴趣。而 RippleNet^[15] 的核心思想就是根据用户的历史记录来挖掘用户对于知识图谱实体中的潜在高

阶偏好。将用户点击过的实体作为“种子”, 沿着知识图谱的边在知识图进行扩散, 此扩散是一个逐渐衰减的过程, 类似于水中的涟漪, 进而扩散得到的节点与用户兴趣有关, 可用来加强用户兴趣的表征。如图 2 所示, 整个模型以用户 id 以及物品 id 作为输入, 首先在知识图谱上进行多层传播提取用户特征, 再通过计算得到的用户特征向量与嵌入的物品向量得出用户对物品的预测兴趣值。

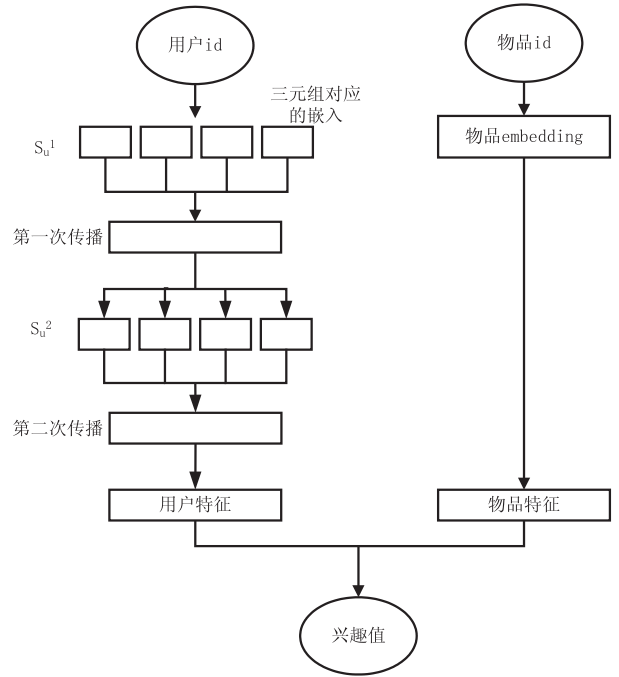


图 2 RippleNet 模型

模型通过输入用户 u 以及候选的物品 v , 得到用户 u 点击物品 v 的概率值。其中物品向量 v 随机初始化即可, 而用户向量 u 的计算方式如下:

$$u = o_u^1 + o_u^2 + \dots + o_u^H \quad (8)$$

其中, o_u^H 表示“第 H 波输出”, 即上图中长框代表的向量。图中第一个长矩阵表示的向量, 需要使用的是深度为 1 的 ripple set (第一层水波集, 图中表示为 Hop-1), 可以将物品嵌入向量 v 与这个三元组的头实体 h_i 和关系 r_i 以下的公式来分配一个关联概率:

$$p_i = \text{softmax}(v^T R_i h_i) = \frac{\exp(v^T R_i h_i)}{\sum_{(h_i, r_i, t_i) \in S_u^1} \exp(v^T R h_i)} \quad (9)$$

其中, S_u^1 表示 user 的第一层 ripple set, $R_i \in R^{d \times d}$ 和 $h_i, v \in R^d$ 分别是关系 r_i 和头实体 h_i 的嵌入向量。求得关联概率之后, 再取 S_u^1 的尾实体 t_i 通过对应的关联概率进行加权求和, 公式如下:

$$o_u^1 = \sum_{(h_i, r_i, t_i) \in S_u^1} p_i t_i \quad (10)$$

其中, $t_i \in R^d$, 而向量 o_u^1 则表示用户 u 的历史点击对物品 v 的一阶响应。之后将前一步得到的 o 向量作为下一层水波的头向量, 带入公式(8), 重复进行 H 次,

就可以得到 H 个 o 向量,再经过公式(8)就可得到用户向量。

2 算法描述

2.1 总体框架

该算法通过融合知识图卷积以及用户偏好同时在物品端以及用户端进行交替特征提取,最后基于二者向量内积衡量用户对物品的评分。总体框架如图 3 所示。

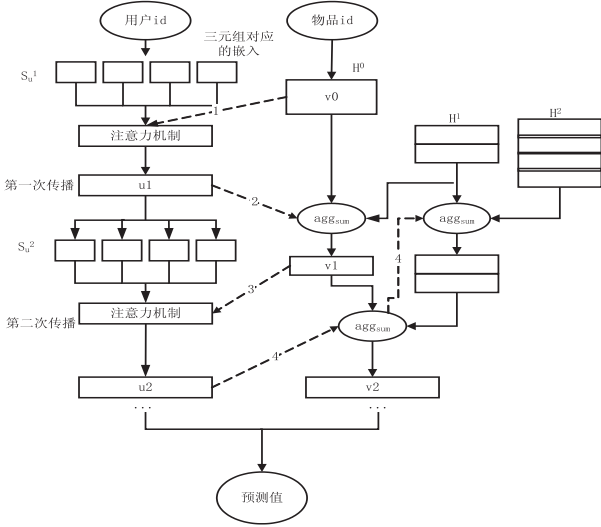


图 3 模型框架

2.2 算法思想

针对现有的 RippleNet 以及 KGCN 模型均未能充分使用用户特征向量或者物品特征向量,仅能聚合一端而无法有效确定用户与实体之间的问题,提出了融合知识图卷积的双端邻居推荐算法,通过用户交互矩阵以及知识图谱,在用户端以及物品端交替进行特征的提取。如图 3 所示,该算法按照图中虚线编号从小到大的顺序交替进行物品端以及用户端的向量聚合,共享当前已知信息,从而相互促进各自的特征提取过程。其中通过公式(8)提取得到的用户特征,对于 o_u^i ,随着在传播深度的不断增长,在知识图谱中节点离用户交互历史也越来越远,引入的噪声信息也越来越多,不同的路径对用户偏好的贡献也并不相同。因此,根据文献[14]提出的加权池化操作对公式(8)进行优化:

$$u = \ln \left(\sum_{k=1}^H \exp \left(\frac{u_u^k}{\gamma} \right) \right) \quad (11)$$

其中,超参数 β 用来控制在知识图谱中每一跳输出的权重,此池化操作可以用来区分每一跳对于用户偏好输出的重要性,因为:

$$\frac{\partial u}{\partial o_u^k} = \frac{\exp(o_u^k / \gamma)}{\gamma \sum_i \exp(o_u^i / \beta)} \quad (12)$$

当 β 为 0 时,表示最大池化;当 β 趋近于无穷时,表示平均池化。可以通过控制 β 的大小来调整在知识图谱中每一跳对于用户偏好的比重。

2.3 算法描述

该算法融合知识图卷积网络 and 用户偏好,通过在用户端以及物品端交替进行个性化特征的提取,算法流程如图 4 所示。

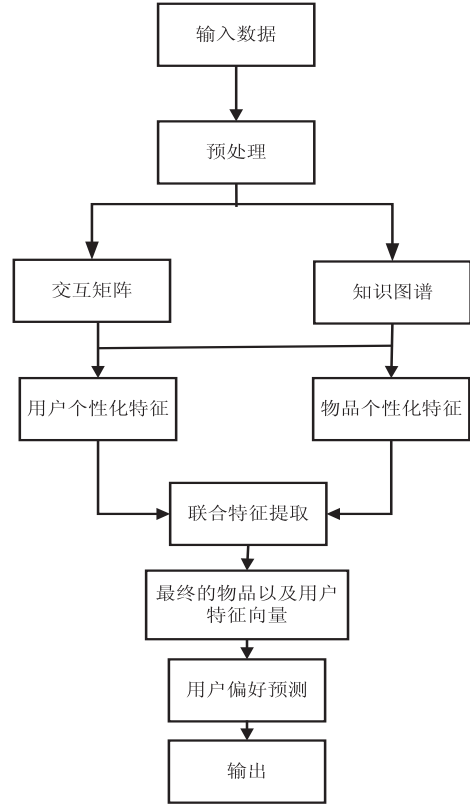


图 4 算法流程

具体实现步骤为:

(1) 获取输入数据并对输入数据进行预处理,以得到交互矩阵和知识图谱,交互矩阵中包括用户和用户的历史点击对象,知识图谱包括与历史点击对象对应的用户节点。

(2) 在知识图谱上对用户节点的邻居信息进行融合,以得到用户个性化特征。

(3) 知识图谱中包括物品节点的邻居信息,对物品节点的邻居信息进行聚合,以得到物品个性化特征。

(4) 对用户个性化特征和物品个性化特征进行交替特征提取,分别得到用户特征向量和物品特征向量。

交替进行步骤 2 和步骤 3,使得用户个性化特征的波形与物品个性化特征的波形可以进一步产生干涉效应,更深入地发掘用户的兴趣分布和物品特征的关系,得到用户特征向量和物品特征向量。

(5) 对用户特征向量和物品特征向量进行内积运算,并通过预测函数来预测用户的偏好,具体的,可通过以下两种预测函数中的一种来预测用户的偏好。

3 实验结果与分析

3.1 实验数据集

为了更好地评估提出的算法,一个包含用户交互信息以及用户辅助信息的数据集是十分必要的。采集的数据集是 MovieLens-1M 以及 Book-Crossing。MovieLens-1M 数据集中包含 6 040 名用户对 3 706 部电影的 100 万条评分,其中每个用户评分过的电影条目数均大于 20。Book-Crossing 数据集来自 Book-Crossing 市场,包含 100 万个书籍评分信息,并且包含书籍辅助信息 27 万多条。对应于数据集的知识图谱数据是从 KGCN^[16]公开的预处理知识图谱获得,该知识图谱信息来自 Microsoft Satori,两个数据集经过预处理后的统计数据如表 1 所示。

表 1 两个数据集的统计数据

数据集	MovieLens-1M	Book-Crossing
用户数	3 718	1 107
物品数	1 989	159 559
交互记录数	524 465	129 601
KG 三元组数	15 044	638 116
KG 实体数	7 366	231 584
KG 关系种类	5	4

3.2 实验设置与参数

为了验证提出的基于知识图谱的推荐模型的有效性,选取了一些目前最具有代表性的推荐模型进行比较:

MKR^[17]:通过一个交叉压缩单元交替学习目标物品与知识图谱中实体的共同潜在语义表示来进行推荐,丰富物品端的表示。在实验中,迭代次数设为 10。

KGCN^[16]:用图卷积网络的方法在知识图谱中聚合物品的辅助信息,丰富物品端的表示,得到用户对物品的偏好概率。

RippleNet^[15]:根据用户的历史记录,挖掘用户对于知识图谱实体中的潜在高阶偏好。

对于每个数据集,按照 6:2:2 的比例随机构成训练集、验证集和测试集,每个实验重复 3 次,取平均性能值。在实验中,本模型相对于每个数据集的超参数对照如表 2 所示。

表 2 超参数取值

超参数	MovieLens-1M	Book-Crossing
d	16	16
K-u	16	16
K-i	4	4
H-u	2	2
H-i	2	2
λ	1e-6	1e-6
batch	512	256
η	1e-2	1e-3

其中, d 表示嵌入维度;H-u 以及 K-u 分别表示

提取用户特征时在知识图谱上遍历的深度和邻居采样数;H-i 以及 K-i 分别表示提取物品特征时在知识图谱上遍历的深度和邻居采样数; λ 表示正则化的参数;batch 表示梯度下降时每批的数据量; η 表示训练速率。

3.3 评价指标

采用 AUC 和 F1 来评价模型的性能。其中 F1 为:

$$F1 = \frac{2 * \text{precision} * \text{recall}}{\text{precision} + \text{recall}} \quad (13)$$

其中,precision 为准确率,recall 为召回率。F1 是同时考虑了准确率与召回率的指标。AUC 的物理意义为任取一对正例和负例,其中正例得分大于负例得分的概率,AUC 越大,表明方法效果越好。AUC 可通过对 ROC 曲线下各部分的面积求和而得,当测试集中正负样本数量相差很大时,ROC 曲线仍然能保持不变,因此 AUC 可以有效地测试模型的效果。

3.4 结果及分析

将提出的模型与不同模型进行了对比,表 3 表示各模型在不同数据集下的 AUC 以及 F1 的指标结果。

表 3 指标对比实验

模型	MovieLens-1M		Book-Crossing	
	AUC	F1	AUC	F1
MKR	0.917 0	0.933 0	0.734 0	0.732 0
KGCN	0.913 0	0.931 0	0.691 7	0.632 8
RippleNet	0.921 0	0.912 0	0.724 9	0.662 0
文中模型	0.935 0	0.952 0	0.773 0	0.746 0

从实验结果中可以看出,文中模型的实验结果是普遍优于基准实验的,在 MovieLens-1M 以及 Book-Crossing 两个数据集上性能都有所提升。其中 MKR 模型仅仅使用知识图谱嵌入的思想而未能充分利用知识图谱路径信息来进行推荐,因此难以达到最佳性能。RippleNet 模型通过模拟用户偏好在知识图谱上进行广泛传播得到用户潜在兴趣,但未充分利用待推荐物品在知识图谱上的信息,从而导致物品特征的缺失。KGCN 模型通过知识图卷积网络来提取物品的特征向量,但未充分利用用户的历史点击项目来挖掘潜在的用户偏好,导致用户特征的丢失。相比于以上模型,文中模型有效利用了待推荐项目的图谱信息,并根据用户的历史交互对象在知识图谱中的传播得到准确的用户兴趣表示,物品端与用户端的在知识图谱中交替进行,共享当前已知信息。实验结果表明文中模型有较好的推荐性能。

3.5 参数分析

在超参数调节实验中,研究各个超参数的取值对文中模型的推荐结果的影响:

(1) 维度 d 的取值分别为 2、4、8、16、32、64,在

MovieLens-1M 上对应的 AUC 取值如图 5 所示。根据实验发现,在 MovieLens-1M 数据集上维度取值为 16 最佳,根据折线图可以看出,当维度小于 16 时,推荐质量会随着维度的增长而提升,这是因为维度过小所容纳的信息也会相对较少。当维度大于 16 之后,推荐质量开始逐渐降低,这是因为在维度过大的时候,会引入更多的噪音,导致训练的时候易出现过拟合,求出的解不够泛化。




图 5 维度 d 对推荐质量的影响

(2) 用户特征提取以及物品特征提取时遍历的深度分别取值 1、2、3、4 时,在 MovieLens-1M 数据集上用户端以及物品端对应的 AUC 值如图 6 和图 7 所示。根据折线图可以看出,随着遍历深度的增加,推荐效果首先呈现上升的趋势,到一定点之后呈现下降趋势。这是因为在提取相应特征时,若遍历深度过低,会使得推荐算法无法充分利用知识图谱中的信息,影响推荐效果;若遍历深度过高,离目标物品较远的实体的引入会造成噪音效果,不利于推荐模型的表现,从而影响推荐质量。还可以看出,用户特征提取深度 ($H-u$) 以及物品特征提取深度 ($H-i$) 都取值为 2 可使推荐效果达到最高。




图 6 遍历深度 $H-u$ 对推荐质量的影响




图 7 遍历深度 $H-i$ 对推荐质量的影响

(3) 对用户特征提取的实体采样数在取值为 2、4、8、16、32、64 以及物品特征提取的实体采样数在取值为 2、4、8、16 时,在 MovieLens-1M 数据集上用户端及物品端对应的 AUC 取值如图 8 和图 9 所示。由折线图可以看出实体采样数太小时,知识图谱中所能提供的有价值的信息无法被充分挖掘。而实体采样数过大时,则会引起更多噪音,从而降低推荐质量,不利于模型的表现。从实验数据可发现,在 MovieLens-1M 数据集上提取用户特征时的实体采样数 $K-u$ 取值为 16 且提取物品特征时的实体采样数 $K-i$ 取值为 16 时推荐质量达到最高。




图 8 采样数 $K-u$ 对推荐质量的影响




图 9 采样数 $K-i$ 对推荐质量的影响

4 结束语

提出了一种基于知识图卷积与用户偏好的双端邻居推荐算法。该算法将知识图谱作为辅助信息,利用知识图卷积网络模型提取出有个性的物品特征向量,通过 RippleNet 模型在知识图谱传播捕获用户偏好信息,找到用户的潜在兴趣,最终得到用户的个性化向量表示。考虑到上述两个推荐模型结构相似,因此联合用户兴趣传播与物品特征聚合的过程,在知识图谱上交替进行用户端与物品端的特征提取。这种新的结构使两侧的特征提取过程统一,使得用户端与物品端的波形进一步产生干涉效应,更深入挖掘知识图谱中用户的兴趣分布与物品特征之间的关系,提高推荐效果。通过实验证明了该模型的优越性。未来研究中还可以挖掘知识图谱中每个实体的属性,类似于物品标签,可进一步提升推荐算法的质量。

参考文献:

- [1] 黄立威,江碧涛,吕守业,等. 基于深度学习的推荐系统研究综述[J]. 计算机学报,2018,41(7):1619-1647.

- [2] HE M, WANG B, DU X. HI2Rec: exploring knowledge in heterogeneous information for movie recommendation [J]. IEEE Access, 2019, 7: 30276–30284.
- [3] 张玉洁, 董政, 孟祥武. 个性化广告推荐系统及其应用研究[J]. 计算机学报, 2021, 44(3): 531–563.
- [4] WANG H, ZHANG F, XIE X, et al. DKN: deep knowledge-aware network for news recommendation [C]//Proceedings of the 2018 world wide web conference. Lyon: [s. n.], 2018: 1835–1844.
- [5] 罗洋, 夏鸿斌, 刘渊. 融合注意力 LSTM 的协同过滤推荐算法[J]. 中文信息学报, 2019, 33(12): 110–118.
- [6] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems[J]. Computer, 2009, 42(8): 30–37.
- [7] WANG Q, MAO Z, WANG B, et al. Knowledge graph embedding: a survey of approaches and applications [J]. IEEE Transactions on Knowledge & Data Engineering, 2017, 29(12): 2724–2743.
- [8] BORDES A, USUNIER N, GARCIA – DURAN A, et al. Translating embeddings for modeling multi – relational data [C]//Advances in neural information processing systems. Lake Tahoe: [s. n.], 2013.
- [9] LIN H, LIU Y, WANG W, et al. TransR: learning entity and relation embeddings for knowledge resolution [J]. Procedia Computer Science, 2017, 108: 345–354.
- [10] WANG Z, ZHANG J, FENG J, et al. Knowledge graph embedding by translating on hyperplanes [C]//Proceedings of the AAAI conference on artificial intelligence. Palo Alto: AAAI, 2014.
- [11] JI G, HE S, XU L, et al. Knowledge graph embedding via dynamic mapping matrix [C]//Proceedings of the 53rd annual meeting of the association for computational linguistics and the 7th international joint conference on natural language processing (volume 1: long papers). Stroudsburg: ACL, 2015: 687–696.
- [12] YANG B, YIH W, HE X, et al. Embedding entities and relations for learning and inference in knowledge bases [J]. arXiv: 1412.6575, 2014.
- [13] TROUILLON T, WELBL J, RIEDEL S, et al. Complex embeddings for simple link prediction [C]//International conference on machine learning. New York: JMLR, 2016: 2071–2080.
- [14] WANG X, HE X, CAO Y, et al. KGAT: knowledge graph attention network for recommendation [C]//Proceedings of the 25th ACM SIGKDD international conference on knowledge discovery and data mining. Anchorage: Association for Computing Machinery, 2019: 950–958.
- [15] WANG H, ZHANG F, WANG J, et al. Ripplenet: propagating user preferences on the knowledge graph for recommender systems [C]//Proceedings of the 27th ACM international conference on information and knowledge management. Torino: ACM, 2018: 417–426.
- [16] WANG H, ZHAO M, XIE X, et al. Knowledge graph convolutional networks for recommender systems [C]//The world wide web conference. San Francisco: ACM, 2019: 3307–3313.
- [17] WANG H W, ZHANG F Z, ZHAO M, et al. Multi-Task feature learning for knowledge graph enhanced recommendation [C]//WWW'19: the web conference. association for computing machinery. New York: ACM 2019: 2000–2010.
- +++++
- (上接第 33 页)
- Multivariate Analysis, 2010, 101(10): 2297–2304.
- [20] 张继福, 李永红, 秦啸, 等. 基于 MapReduce 与相关子空间的局部离群数据挖掘算法 [J]. 软件学报, 2015, 26(5): 1079–1095.
- [21] ZHANG J, YU X, LI Y, et al. A relevant subspace based contextual outlier mining algorithm [J]. Knowledge – Based Systems, 2016, 99: 1–9.
- [22] 樊盼盼, 张继福. 高斯混合模型下的相关子空间与离群数据挖掘 [J]. 小型微型计算机系统, 2018, 39(11): 141–146.
- [23] TANG H, CHU S M, HASEGAWA – JOHNSON M, et al. Emotion recognition from speech via boosted Gaussian mixture models [C]//2009 IEEE international conference on multimedia and expo. New York: IEEE, 2009: 294–297.
- [24] BREUNIG M M, KRIEDEL H P, NG R T, et al. LOF: identifying density – based local outliers [C]//Proceedings of the 2000 ACM SIGMOD international conference on management of data. [s. l.]: ACM, 2000: 93–104.