

融合用户行为和评论文本的图神经网络推荐

胡一帆, 杨小健, 秦 岭

(南京工业大学 计算机科学与技术学院, 江苏 南京 210000)

摘要: 现有的基于图神经网络的推荐算法能够利用图结构信息使得推荐效果得到较好的提升, 但主要的图结构都是围绕着用户和项目的一种交互, 却忽略了用户的多种行为, 如点击、收藏、分享、加入购物车等都表达着用户不同的语义; 又如评论信息, 可能影响着该类型物品的下一次购买意图。为此提出一种基于用户行为和评论信息的图神经网络推荐算法, 算法通过图卷积网络学习用户行为的强度及语义, 再利用评论文本图表示学习评论中用户和商品的偏好, 最后进行融合提升推荐效果。实验结果表明, 该算法对于推荐效果有一定的提升。

关键词: 推荐系统; 图神经网络; 用户行为

中图分类号: TP391

文献标识码: A

DOI: 10.16157/j.issn.0258-7998.212165

中文引用格式: 胡一帆, 杨小健, 秦岭. 融合用户行为和评论文本的图神经网络推荐[J]. 电子技术应用, 2022, 48(9): 50-54.

英文引用格式: Hu Yifan, Yang Xiaojian, Qin Lin. Graph neural network recommendation combining user behavior and comment text[J]. Application of Electronic Technique, 2022, 48(9): 50-54.

Graph neural network recommendation combining user behavior and comment text

Hu Yifan, Yang Xiaojian, Qin Lin

(College of Computer Science and Technology, Nanjing Tech University, Nanjing 210000, China)

Abstract: The existing recommendation algorithm based on graph neural network can make use of graph structure information to improve the recommendation effect, but the main graph structure revolves around a kind of interaction between users and items, but ignores multiple behaviors of users. For example, click, bookmark, share, add to shopping cart, etc., all express different semantics of users, and comment information may affect the next purchase intention of this type of item. To this end, a graph neural network recommendation algorithm based on user behavior and comment information is proposed. The algorithm learns the strength and semantics of user behavior through the graph convolutional network, and then uses the comment text graph to represent the preferences of users and products in the learning reviews, and finally combines them to improve the recommendation effect. According to the experimental results, it is found that the algorithm can improve the recommendation effect to a certain extent.

Key words: recommended system; graph neural network; user behavior

0 引言

传统的 CF 模型^[1-2]只针对例如电商平台的购买行为这一单一的用户行为而设计, 但对于一些没有购买的新用户, 就很难做到很好的推荐。例如浏览记录、分享、收藏、加入购物车等行为平台也极易获得, 因此利用这些行为来辅助预测可使得推荐效果进一步提升。现有的研究^[3-6]也探讨过这一方面, 文献[3]假设不同的行为所代表的重要性不同, 通过用一种积极行为和另一种普通行为抽样扩展 BPR。文献[5-6]通过建立多任务学习的深度模型, 设定了用户不同行为之间的重要程度, 但此模型很简单地认为用户的辅助行为的作用就一定弱于目标行为, 但有时候分享可能比购买更能反映用户的偏好。文献[7]MBGCN 通过利用图神经网络从不同类型的边和图上的高阶连通性中学习, 但却忽略了目标行为之后的评论内容也很大程度上展示了用户对于该项目的

最终评价。

近年来对于评论信息的推荐算法主要以深度学习为主, 尽管深度学习发展迅速但深度学习可能会忽视词语之间的依赖关系, 图学习却可以解决上述问题。因此, 本文提出了一种改进的基于图神经网络的推荐算法, 对比同类的用户多种辅助行为的推荐方式同时融入用户评论对该项目的最终评价对用户进行推荐。实验结果表明, 该算法对推荐效果有一定的提升。

1 相关工作

1.1 基于图神经网络的推荐算法

图神经网络的中心思路是通过迭代聚合邻居的特征信息与中心节点的表示集成。图神经网络与图嵌入也有着很密切的关系, 图嵌入是指在图结构和图信息不变的情况下, 将图中的节点投影到低维向量空间, 最终用低维嵌入对数据进行分析。通过图神经网络推荐的实际

含义是学习用户和项目的隐含特征。

Kipf 等^[8]提出的 GCNs 模型利用节点属性和图结构学习节点表示,它的每个卷积层将中心节点的表示和其邻居节点的表示相结合作为新的节点表示。Fan 等^[9]分别建立用户-物品、物品-用户、用户-朋友 3 种图,结合起来推荐。Ying 等^[10]通过将随机游走和图卷积相结合的方式进行网页应用的推荐。Wang 等^[11]使用目标节点及其邻居节点点积更新。这些模型的成功说明了图神经网络对于推荐效果有着明显的提升。

1.2 评论文本的推荐算法

基于深度学习的推荐算法,很早就对用户评论信息的提取起到了很大的作用:在 ConvMF 中 K 利用 CNN 从用户的评论信息中学习用户和物品的偏好,相较于之前的矩阵分解算法,该算法的结果有着很明显的提升。随后,出现的 DeepCoNN^[12]并行 CNN 结构、LCPMF^[13]将 LDA 模型与 CNN 相结合、DIN^[14]提出注意力机制、MAGN^[15]在此之上增加新的注意力等都使得深度学习在推荐系统领域得到了很好的发展。

图神经网络的出现,因其可以学习到用户项目之间深度学习无法学习的关联关系,所以本文使用图的优势,将用户的评论表示成图,分析评论中的情感。

2 改进的基于图神经网络的推荐算法

2.1 基于图神经网络的推荐算法

设行为的数量为 T ,所有的行为矩阵可以表示为 $\{Y^1, Y^2, \dots, Y^{T-1}, Y^T\}$,其中 Y^T 为目标行为,矩阵中的每个值为 1 或 0。但每个行为之间并没有严格的时间先后顺序,每个行为对于用户偏好的影响强弱也不是一定的。整个模型的步骤分为 4 步:(1)初始化用户和项目的嵌入;(2)学习每个行为的强度,提取基于多行为的协同信号;(3)分析行为类型的行为语义;(4)联合预测。

本文使用无向图 $G=(V, E)$ 来表示,其中节点为 V ,由用户节点 $u \in U$ 和项目节点 $i \in I$ 组成, E 中的边包含不同行为的不同用户-项目交互边,即 $(u, i)_t, t \in N_r$,其中 N_r 是发生在用户和项目之间的所有行为类型的集合。当 $y_{ui}^t=1$ 时,将建立一个边 (u, i) 。使用不同种类的边来表示不同的行为。基于用户共同行为在项目之间建立元路径,如很多用户同时购买 iPhone 和 AirPods,在 iPhone 和 AirPods 节点之间会有物品-购买-用户-购买-物品元路径,元路径类型的数量等于行为类型的数量。

2.1.1 图嵌入

使用嵌入向量 $\mathbf{p}_i^{(0)} \in R^d$ 和 $\mathbf{q}_j^{(0)} \in R^d$ 来描述用户和项目,其中 d 是嵌入大小。用户嵌入向量和项目嵌入向量可以分别用嵌入矩阵 \mathbf{P} 和 \mathbf{Q} 表示:

$$\mathbf{P}=\{\mathbf{p}_{u_1}^{(0)}, \mathbf{p}_{u_2}^{(0)}, \dots, \mathbf{p}_{u_n}^{(0)}\} \quad (1)$$

$$\mathbf{Q}=\{\mathbf{q}_{i_1}^{(0)}, \mathbf{q}_{i_2}^{(0)}, \dots, \mathbf{q}_{i_m}^{(0)}\} \quad (2)$$

在这里使用矩阵乘法来获得具有一个热矢量的用

户(项目)的嵌入,如下所示:

$$\begin{cases} \mathbf{p}_{u_k}^{(0)} = \mathbf{P} \cdot \mathbf{ID}_k^U \\ \mathbf{q}_{i_j}^{(0)} = \mathbf{Q} \cdot \mathbf{ID}_j^V \end{cases} \quad (3)$$

其中, \mathbf{ID}_k^U 和 \mathbf{ID}_j^V 分别是用户 u_k 和项目 i_j 的热门向量。矩阵 \mathbf{P} 和 \mathbf{Q} 中的嵌入是图神经网络框架下每个用户和项目的输入特征。

2.1.2 用户嵌入的传播

要根据行为类型的不同的考虑项目对用户的偏好影响,对比与传统多行为算法,本文融入更多的辅助行为,且每个行为对目标行为的贡献不再通过人为地衡量,而是由模型本身来学习。此外,还应同时考虑数据稀疏性。

用户行为传播权重计算时,由于不同的行为对目标行为的贡献不同,因此为每个行为分配一个权重,即 w_t 。为了将行为重要性和行为稀疏性融合在一起,为用户 u 定义了特定行为 t 的传播权重,表示为 a_{ut} ,如下所示:

$$a_{ut} = \frac{w_t \cdot n_{ut}}{\sum_{m \in N_r} w_m \cdot n_{um}} \quad (4)$$

其中, n_{ut} 是由用户 u 操作的行为 t 的计数,该计数因用户而异。 $\sum_{t \in N_r} a_{ut}=1$ 。这里注意, w_t 是通过模型学习的,不需要为每个行为赋值。

对于用户不同行为对目标行为的贡献不同,但同一行为交互的项目反映了用户相似的偏好强度。将用户具有相同行为交互的项目聚集在一起,为每个行为获得一个嵌入即行为 t 下的用户 u 的嵌入,定义如下:

$$\mathbf{p}_{u,t}^{(l)} = \text{aggregate}(\mathbf{q}_i^{(l)} | i \in N_t^l(u)) \quad (5)$$

其中, l 指第 l 层, $N_t^l(u)$ 是用户 u 在行为 t 下交互的项目集合, $\mathbf{q}_i^{(l)}$ 是第 l 层上项目 i 的项目嵌入, $\mathbf{p}_{u,t}^{(l)}$ 是用户 u 在第 l 层上行为 t 下的项目聚合嵌入。聚合函数这里使用简单的均值函数。

根据权重 α 将邻居项集合嵌入在一起,然后通过一个编码矩阵,得到用户的最终邻居项集合。

$$\mathbf{p}_u^{(l+1)} = \mathbf{W}^{(l)} \cdot \left(\sum_{t \in N_r} a_{ut} \mathbf{p}_{u,t}^{(l)} \right) \quad (6)$$

其中, $\mathbf{p}_u^{(l+1)}$ 是用户 u 在第 $(l+1)$ 层中的嵌入, $\mathbf{W}^{(l)}$ 是第 l 层中信息聚合的编码矩阵。

2.1.3 项目嵌入的传播

用户到项目的传播与项目到用户不同,因为项目的特性是静态的。假设不同的用户对一个项目有相同的贡献。因此,下面示出了用户到项目的传播方法:

$$\mathbf{q}_i^{(l+1)} = \mathbf{W}^{(l)} \cdot \text{aggregate}(\mathbf{p}_j^{(l)} | j \in N^U(i)) \quad (7)$$

其中, $N^U(i)$ 是项目 i 与之交互的用户集合, $\mathbf{p}_j^{(l)}$ 是用户 j

在第 l 层上的嵌入, $\mathbf{W}^{(l)}$ 是 l 层上信息聚合的编码矩阵。

2.1.4 项目之间的传播

用户交互的项目可能有特殊的联系。将在行为 t 下共同行为的项目 j 的嵌入与项目 I 聚合, 以获得下一层嵌入 $\mathbf{s}_{it}^{(l+1)}$ 。通过这种机制, 与 I 项共同作用的项的特征将被聚合到 I 的嵌入中, 这有助于更好地嵌入学习和最终预测。

$$\mathbf{s}_{it}^{(l+1)} = \mathbf{W}_t^{(l)} \cdot \text{aggregate}(\mathbf{s}_{jt}^{(l)} | j \in N_t^l(i)) \quad (8)$$

其中, $N_t^l(i)$ 是用户在行为 t 下与项目 I 交互在一起的项目集合, 而 $\mathbf{W}_t^{(l)}$ 是行为 t 的编码矩阵, 可以帮助在第 l 层聚集信息。对于所有 $t \in N_r$, 有 $\mathbf{s}_{it}^{(0)} = \mathbf{q}_i^{(0)}$ 。这个过程后, 每个项目将有 $|N_r|$ 传播嵌入。

2.1.5 联合预测

通过 L 层传播后, 得到多个表示, 对于最终的预测, 来自不同邻居的信息都很重要。因此, 将它们连接在一起, 以获得用户和项目的最终嵌入:

$$\begin{cases} \mathbf{p}_u^* = \mathbf{p}_u^{(0)} || \cdots || \mathbf{p}_u^{(L)} \\ \mathbf{q}_i^* = \mathbf{q}_i^{(0)} || \cdots || \mathbf{q}_i^{(L)}, \quad t \in N_r \\ \mathbf{s}_u^* = \mathbf{s}_u^{(0)} || \cdots || \mathbf{s}_u^{(L)} \end{cases} \quad (9)$$

其中, $||$ 是串联运算。

传播层学习了用户嵌入和项目嵌入后, 就可以计算出基于用户的评分, 项目到项目的传播就可以获得项目相关性, 由此可以就算出基于项目的评分。

基于用户的 CF 评分。这里使用内部产品的简单交互函数, 以便基于用户项目传播来计算分数:

$$y_1(u, i) = \mathbf{p}_u^{* \top} \cdot \mathbf{q}_i^* \quad (10)$$

基于项目的 CF 评分。用户对两个项目的共同行为可能暗示这两个项目之间的相关性, 项目之间的相关性可能影响用户的行为, 将从不同行为计算的项目相关性分数相加以获得最终相关性分数:

$$y_2(u, i) = \sum_{t \in N_r} \sum_{j \in N_t^l(U)} \frac{\mathbf{s}_{jt}^{* \top} \cdot \mathbf{M}_t \cdot \mathbf{s}_{it}^*}{|N_t^l(u)|} \quad (11)$$

其中, $N_t^l(u)$ 是用户 u 在行为 t 下已经交互的项目集, 而 $\mathbf{M}_t \in R^{d' \times d'}$, $d' = d \times (L+1)$ 是一个可训练矩阵, 它基于行为 t 来度量两个项目嵌入之间的相关性。

综合评分:

$$y(u, i) = \lambda \cdot y_1(u, i) + (1 - \lambda) y_2(u, i) \quad (12)$$

2.2 评论信息偏好特征提取

对于评论信息的图学习分为用户模块和项目模块, 两个模块的结构相同, 因此下面只介绍用户模块。

对于用户 u_i 的评论集 S_{u_i} , 先通过文本预处理挑选出评论文本的关键词, 然后将所有关键词作为节点, 词与词间的关系作为边, 构建有向图。由于评论中词语间的

顺序可能会导致用户的不同情感, 因此要保留词序, 将先出现的关键词指向后出现的关键词的边记为 e_j , 同时生成反向的边 e_b , 此外每个节点还会生成一条自连接的边 e_s 以分析自身的信息。

评论信息中的每一个关键词间是相互联系的, 可以丰富彼此的含义, 对于输入的图 G , 节点用 \mathbf{x}_h 表示, \mathbf{x}_h 的邻接点用 $N_h = \{\mathbf{x}_l | (\mathbf{x}_h, r, \mathbf{x}_l) \in G\}$ 表示, N_h 包含 \mathbf{x}_h 。则 \mathbf{x}_h 的权重为:

$$\alpha^l(\mathbf{x}_h, r, \mathbf{x}_i) = \frac{e^{\tau^l(\mathbf{x}_h, r, \mathbf{x}_i)}}{\sum_{\tilde{\mathbf{x}}_i \in N_h} e^{\tau^l(\mathbf{x}_h, r, \tilde{\mathbf{x}}_i)}} \quad (13)$$

$$\tau^l(\mathbf{x}_h, r, \mathbf{x}_i) = \sigma[(\mathbf{x}_h^l \mathbf{W}_1^l) (\mathbf{x}_i^l \mathbf{W}_1^l + \mathbf{e}_r^l \mathbf{W}_2^l)] \quad (14)$$

其中, \mathbf{W}_1^l 、 \mathbf{W}_2^l 为转换权重矩阵, \mathbf{x}_h^l 、 \mathbf{x}_i^l 、 \mathbf{e}_r^l 为 \mathbf{x}_h 、 \mathbf{x}_i 、 r 在第 l 层的表示, σ 为激活函数。因此 \mathbf{x}_h 的表示为:

$$\mathbf{x}_h^{l+1} = \text{Tanh}(\sum_{\mathbf{x}_i \in N_h} \alpha^l(\mathbf{x}_h, r, \mathbf{x}_i) \mathbf{x}_i^l \mathbf{W}_1^l) \quad (15)$$

其中, Tanh 为激活函数。

接下来根据用户和项目信息, 计算出图中节点关于交互水平的权重, \mathbf{x}_h 的权重为:

$$\beta_h^l = \frac{e^{\nu^l(\mathbf{x}_h, u, i)}}{\sum_{\tilde{\mathbf{x}}_h \in N_u} e^{\nu^l(\tilde{\mathbf{x}}_h, u, i)}} \quad (16)$$

$$\nu^l(\mathbf{x}_h, u, i) = \sigma(\mathbf{x}_h^{l+1} (\text{Tanh}([e_u || e_i]) \mathbf{W}_3^l))^T \quad (17)$$

其中, \mathbf{W}_3^l 为转换权重矩阵。图的第 l 层表示为:

$$\mathbf{g}_u^{l+1} = \sum_{\mathbf{x}_h \in N_u} \beta_h^l \mathbf{x}_h^{l+1} \quad (18)$$

用户的最终表示为每一层的图表示拼接: $\mathbf{b}_u = \mathbf{g}_u || \mathbf{g}_u^{l+1} || \cdots || \mathbf{g}_u^{l+1}$, 同理可得项目的最终表示 \mathbf{b}_i 。

2.3 最终评分

由 2.1.5 节可知, 用户和项目的最终嵌入为 \mathbf{p}_u 和 \mathbf{q}_i , 本文采用 concat 方式将 2.1.5 节的最终嵌入与通过评论信息的一般偏好特征融合从而得到最终的特征:

$$\mathbf{U}_i = \mathbf{p}_u \oplus \mathbf{b}_{u_i} \quad (19)$$

$$\mathbf{I}_j = \mathbf{q}_i \oplus \mathbf{b}_{i_j} \quad (20)$$

基于用户 CF 的评分公式也更新为:

$$y_1(u, i) = \mathbf{U}_i \cdot \mathbf{I}_j \quad (21)$$

2.4 模型训练

采用了优化的带 BPR 损失的模型定义损失函数:

$$\text{Loss} = \sum_{(u, i, j)} -\ln \sigma(y(u, i) - y(u, j)) + \beta \cdot \|\Theta\|^2 \quad (22)$$

其中, $O = \{(u, i, j) | (u, i) \in R^+, (u, j) \in R^-\}$ 表示成对目标行为训练数据集, R^+ 表示观察到的目标行为, R 表示未观察到的目标行为; $\sigma(\cdot)$ 是 sigmoid 函数, Θ 表示所有可训练参数, β 是控制 L2 归一化强度的系数。

3 实验设计以及结果分析

3.1 数据集介绍

本文实验采用两个数据集(Tmall 数据集、Beibei 数据集)进行实验,这两个数据集为很大规模的真实的电商平台的数据集。在这些数据集中除了目标行为购买之外也都有各自不同的其他用户行为。

3.2 评价标准

为了评估本文模型的性能选取了召回率准确率和 NDCG 3 种指标来测试,计算公式如下:

NDCC:

$$\text{NDCC}@n = \sum_{u \in U} \frac{1}{|U|} \frac{\sum_{i=1}^n \frac{f(L_u \cap L_u^t)}{\log_2(i+1)}}{\sum_{i=1}^n \frac{f(L_u^t)}{\log_2(i+1)}} \quad (23)$$

准确率:

$$\text{precision}@n = \frac{1}{U} \sum_{u \in U} \frac{|L_u \cap L_u^t|}{n} \quad (24)$$

召回率:

$$\text{recall}@n = \frac{1}{U} \sum_{u \in U} \frac{|L_u \cap L_u^t|}{|L_u^t|} \quad (25)$$

NDCG 将较高的分数分配给在 top- K 排名列表中较高位置的点击。准确率和召回率分别指推荐正确的数量占推荐总数和占用户总共购买数量的比例。

3.3 对比算法

(1)NGCF:通过 GCN 模型使用目标行为来构建用户项二分图,是一种经典的图神经网络模型。

(2)GraphSAGE:通过嵌入传播和聚集,用邻居信息丰富节点嵌入,应用十分广泛。

(3)MC-BPR:融入多行为的推荐系统,将用户不同的行为反映出的不同偏好作为先验知识构建训练对。

(4)MBGCN:也是一种融入用户多行为的推荐模型,与此同时也使用图神经网络训练用户行为的重要性,有着很好的推荐效果。

3.4 参数的设置

将本文之前提到的所有模型的实验在 PyTorch 中实现。对于评论数据针对每个用户和物品选取 10 条评论信息。模型的嵌入大小为 32,超参数方面,学习率定为 5×10^{-5} ,最终使用的参数 λ 将基于用户的分数与基于项目的分数相结合,在数据集上进行了实验,结果如图 1 所示。当 λ 值为 0 时,模型只基于项目评分,推荐效果不理想; λ 的值在 0~1 之间变化时,推荐结果的变化不大;当 $\lambda=1$ 时,结果会有所下降。从图中看出,当 $\lambda=0.7$ 时,推荐效果最佳。

3.5 对比不同算法的实验分析

通过在两个数据集上的实验,统计出了各个算法分别在推荐数量 k 的值分别为 10、20、40 时的实验结果。

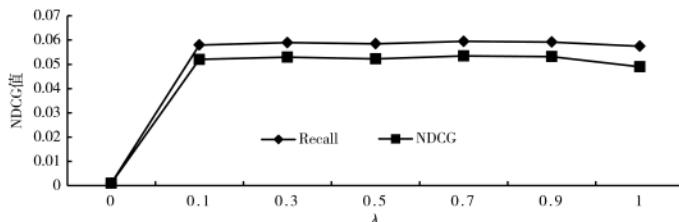


图 1 λ 值对推荐结果的影响

Tmall 的召回率、准确率和 NDCG 的结果如表 1~表 3 所示。

表 1 Tmall 数据集召回率对照

算法	$k=10$	$k=20$	$k=40$
GraphSAGE	0.019 93	0.025 21	0.033 68
NGCF	0.026 08	0.034 09	0.046 12
MC-BPR	0.022 99	0.031 78	0.043 60
MBGCN	0.040 06	0.057 97	0.083 48
本文算法	0.042 12	0.059 82	0.088 64

表 2 Tmall 数据集准确率对照

算法	$k=10$	$k=20$	$k=40$
GraphSAGE	0.015 68	0.010 74	0.005 66
NGCF	0.023 84	0.016 57	0.008 72
MC-BPR	0.020 52	0.014 62	0.007 38
MBGCN	0.037 65	0.024 83	0.012 62
本文算法	0.040 02	0.027 14	0.014 74

表 3 Tmall 数据集 NDCG 对照

算法	$k=10$	$k=20$	$k=40$
GraphSAGE	0.011 57	0.012 96	0.014 74
NGCF	0.015 49	0.017 57	0.020 10
MC-BPR	0.013 44	0.015 58	0.018 13
MBGCN	0.020 88	0.025 48	0.030 79
本文算法	0.022 64	0.028 03	0.032 56

Beibei 的召回率、准确率和 NDCG 的结果如表 4~表 6 所示。

表 4 Beibei 数据集召回率对照

算法	$k=10$	$k=20$	$k=40$
GraphSAGE	0.034 53	0.069 07	0.115 67
NGCF	0.041 12	0.063 36	0.110 51
MC-BPR	0.039 14	0.049 50	0.095 92
MBGCN	0.048 25	0.073 54	0.119 26
本文算法	0.050 14	0.075 48	0.121 34

从表 1~表 6 中可以看出,本文提出的算法在召回率、准确率和 NDCG 上都有一定的提升,证明了模型的有效性,对于前两个模型有着很不错的推荐效果,这说明图神经网络确实对于推荐系统有着很大的提升,对于稀疏数据集具有一定的缓解效果,但对于此类型的电商

表 5 Beibei 数据集准确率对照

算法	$k=10$	$k=20$	$k=40$
GraphSAGE	0.033 12	0.022 06	0.011 34
NGCF	0.039 86	0.026 98	0.013 83
MC-BPR	0.036 68	0.024 36	0.012 16
MBGCN	0.045 83	0.030 77	0.015 37
本文算法	0.048 27	0.033 52	0.016 41

表 6 Beibei 数据集 NDCC 对照

算法	$k=10$	$k=20$	$k=40$
GraphSAGE	0.017 28	0.025 94	0.035 47
NGCF	0.021 99	0.027 55	0.037 12
MC-BPR	0.022 64	0.025 25	0.034 67
MBGCN	0.024 46	0.030 77	0.040 05
本文算法	0.025 02	0.031 84	0.041 25

网站上的推荐用户行为的加入也是很必要的。在对于后两个模型的比较中可以发现,融入用户行为的方式对推荐效果确实有一定的提升,MC-BPR 假定用户不同行为反映不同用户偏好,不如 MBGCN 根据图信息的自学习,本文算法同时又融入了用户最终行为后的评论信息更进一步提升了 MBGCN 的推荐效果。

4 结论

为解决电商网站上的冷启动问题,本文将用户的多行为加入到用户-项目的关系图中,利用图卷积网络从复杂的图结构中学习各个节点的表示,又考虑到用户关键行为后的评论信息也可能很大程度地影响到用户的偏好,于是通过评论信息图表示学习评论中的用户和项目偏好与之前多行为相结合,提出了一种融合用户行为与评论信息的图神经网络推荐算法。在真实数据集上的实验结果证明该模型对推荐效果有一定的提升,也在一定程度上对冷启动问题进行了优化。

参考文献

- [1] JALILI M, AHMADIAN S, IZADI M, et al. Evaluating collaborative filtering recommender algorithms: a survey[J]. IEEE Access, 2018, 6: 74003–74024.
- [2] 姚金平. 个性化推荐系统综述[J]. 中国集体经济, 2020(25): 71–72.
- [3] Qiu Huihuai, Liu Yun, Guo Guibing, et al. BPRH: bayesian personalized ranking for heterogeneous implicit feedback[J]. Information Sciences, 2018, 453: 80–98.
- [4] Ding Jingtao, Yu Guanghui, Li Yong, et al. Improving implicit recommender systems with auxiliary data[J]. ACM Transactions on Information Systems(TOIS), 2020, 38: 1–27.
- [5] Gao Chen, Jin Depeng, He Xiangnan, et al. Learning to recommend with multiple cascading behaviors[J]. IEEE Transactions on Knowledge and Data Engineering, 2019, 33(6): 2588–2601.
- [6] Chen Chong, Zhang Min, Zhang Yongfeng, et al. Efficient heterogeneous collaborative filtering without negative sampling for recommendation[C]//Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34: 19–26.
- [7] Jin Bowen, Gao Chen, He Xiangnan, et al. Multi-behavior recommendation with graph convolutional networks[C]//Proceedings of the 43rd International ACM SIGIR Conference, 2020.
- [8] KIPF T N, WELLING M. Semi-supervised classification with graph convolutional networks[J]. arXiv preprint arXiv: 1609.02907, 2017.
- [9] FAN W Q, MA Y, LI Q, et al. Graph neural networks for social recommendation[C]//The World Wide Web Conference. San Francisco, CA, USA, 2019: 417–426.
- [10] YING R, HE R N, CHEN K F, et al. Graph convolutional neural networks for web-scale recommender systems[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. London, UK, 2018: 974–983.
- [11] WANG X, HE X, WANG M, et al. Neural graph collaborative filtering[J]. arXiv: 1905.08108, 2019.
- [12] Zheng Lei, NOROOZI V, YU P S. Joint deep modeling of users and items using reviews for recommendation[C]//Proceedings of the 10th ACM International Conference on Web Search and Data Mining. ACM, 2017: 425–434.
- [13] 田保军, 刘爽, 房建东. 融合主题信息和卷积神经网络的混合推荐算法[J]. 计算机应用, 2020, 40(7): 1901–1907.
- [14] Zhou Guorui, Zhu Xiaoqiang, Song Chenru, et al. Deep interest network for click-through rate prediction[C]//Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining, 2018: 1059–1068.
- [15] 邱叶, 邵雄凯, 高榕, 等. 基于注意力门控神经网络的社会化推荐算法[J]. 计算机工程与应用, 2022, 58(5): 112–118.

(收稿日期: 2021-09-17)

作者简介:

胡一帆(1996-), 男, 硕士研究生, 主要研究方向: 软件工程、工业信息化。

杨小健(1963-), 男, 教授, 主要研究方向: 工业信息化。

秦岭(1980-), 男, 讲师, 主要研究方向: 工业信息化。



扫码下载电子文档

版权声明

经作者授权，本论文版权和信息网络传播权归属于《电子技术应用》杂志，凡未经本刊书面同意任何机构、组织和个人不得擅自复印、汇编、翻译和进行信息网络传播。未经本刊书面同意，禁止一切互联网论文资源平台非法上传、收录本论文。

截至目前，本论文已经授权被中国期刊全文数据库（CNKI）、万方数据知识服务平台、中文科技期刊数据库（维普网）、DOAJ、美国《乌利希期刊指南》、JST 日本科技技术振兴机构数据库等数据库全文收录。

对于违反上述禁止行为并违法使用本论文的机构、组织和个人，本刊将采取一切必要法律行动来维护正当权益。

特此声明！

《电子技术应用》编辑部

中国电子信息产业集团有限公司第六研究所