

文章编号: 2095-2163(2024)02-0001-08

中图分类号: TP391

文献标志码: A

融合多源异构数据的图卷积神经网络混合推荐模型

刘 铭, 何利力, 郑军红

(浙江理工大学 计算机科学与技术学院, 杭州 310018)

摘要: 推荐系统可以让用户在海量数据环境下挑选出自己真正需要的内容,为更全面地反映用户个人偏好,提高推荐的准确度,本文提出一种融合多源异构数据和图卷积神经网络的混合推荐模型(MHDGCN)。该模型融合用户评分和评论等用户-项目交互数据,先将其转化为特征向量,然后将特征向量使用图卷积神经网络进行聚合和加权;接着采用 Transformer 重新分配聚合后的权重系数;最后将聚合后的特征向量优化相关参数得到推荐结果。经在真实数据集上的对比实验,MHDGCN 在准确率、召回率、平均倒数排名(Mrr)、命中率和归一化折损累计增益(NDCG)5个指标上均优于基线方法,验证了模型的有效性,提升了推荐模型的推荐性能。

关键词: 多源异构; 图卷积神经网络; Transformer; 注意力机制; 推荐算法

Hybrid recommendation model based on graph convolution network integrating multi-source heterogeneous data

LIU Ming, HE Lili, ZHENG Junhong

(School of Computer Science and Technology, Zhejiang Sci-Tech University, Hangzhou 310018, China)

Abstract: The recommendation system allows users to pick out what they really need in an environment of massive data. In order to fully reflect the personal preferences of users and improve the accuracy of recommendation, this paper proposes a hybrid recommendation model (MHDGCN) that integrates multi-source heterogeneous data based on graph convolutional neural network. Firstly, the model integrates the ratings, comments and social network dynamic data of users and converts them into feature vectors. The feature vectors are aggregated and weighted using the graph convolutional neural network. Then transformer is used to redistribute the aggregated weight coefficients. Finally, the aggregated feature vectors are optimized to obtain the recommendation results. Comparison experiments on real datasets show that MHDGCN is superior to the baseline method in accuracy rate, recall rate, Mrr, hit rate and NDCG, which verifies the effectiveness of the model.

Key words: multi-source heterogeneous; GCN; Transformer; attention mechanism; recommendation algorithm

0 引言

随着信息技术的快速迭代发展,信息过载问题日益严重^[1]。传统的协同过滤推荐算法通过用户的历史行为交互和用户偏好进行推荐^[2]。其中,矩阵分解^[3]是最流行的一种协同过滤算法。该算法使用特征向量来表示用户和项目,将用户和项目投影到共享的潜在空间中,用户对项目的交互也被表示为其潜在向量的内积^[4]。传统推荐算法基于其快速训练和快速部署的特性,在一定程度上可以解决信息过载问题,但无法很好地处理稀疏性大的数

据,导致推荐准确性不理想等相关问题^[5]。

学者们为在一定程度上缓解数据稀疏性和提高推荐性能,基于图的方法被应用到推荐系统中^[6]。图神经网络^[7](Graph Neural Network, GNN)中的图结构利用节点之间应用推理发现新的连接,从而提高推荐准确性和推荐项目多样性。Wang 等^[8]提出一种基于深度图卷积的用户-项目嵌入神经网络协同过滤算法(NGCF),其主要通过传播嵌入用户-项目的图结构,对用户-项目交互图中高阶连通性的表达建模,之后通过矩阵分解协同过滤框架完成推荐。He 等^[9]提出了一种名为 LightGCN 的推荐算法

基金项目: 浙江省重点研发计划项目(2022C01238)。

作者简介: 刘 铭(1998-),男,硕士研究生,主要研究方向:软件工程技术;何利力(1966-),男,博士,教授,博士生导师,主要研究方向:智能软件系统与工程。

通讯作者: 郑军红(1978-),男,博士,讲师,主要研究方向:智能软件系统与工程。Email: zdzhengjh@sohu.com

收稿日期: 2023-02-24

模型,其是一种基于深度图卷积的用户-项目嵌入神经网络协同过滤算法,是在 NGCF 上进行的优化和改进。通过消融实验,证明了在邻域聚合时自信息的多余,以及在损失函数方面进行了相关的优化。由以上可知,基于图神经网络的协同过滤推荐算法相比传统的卷积神经网络,能够在一定程度上缓解数据稀疏性和提高推荐性能。虽然基于 GCN 的模型能够有效提取节点之间的高阶信息,但因平滑问题而无法加大对特征提取的深度。

为了进一步提高推荐性能和缓解数据的稀疏性问题,通过引入注意力机制^[10],捕获用户-项目之间长距离的依赖关系,从而提高推荐性能和适应数据稀疏性的数据集。刘雨昕等^[11]基于 LightGCN 进行改进,将层组合系数改为可学习的模型参数,利用注意力机制学习加权系数,进而优化目标节点的最终嵌入表示,提升最终的推荐效果。王巍等^[12]提出 GCACF 算法,使用改进的图神经网络算法提取特征信息,并使用注意力机制重新分配特征信息的权重,提高了推荐性能。

综上所述,在以上的模型中引入注意力机制有很好的效果,但是缺乏对用户的兴趣、评论等相关特征信息的使用。因此,本文提出一种融合多源异构数据和图卷积神经网络的混合动态推荐模型(Multi-source Heterogeneous Data Graph Convolution Network

Dynamic Model, MHDGCN)。首先,该模型融合用户评分和评论等用户-项目交互数据,将其转化为特征向量,然后将特征向量使用图卷积神经网络进行聚合和加权,之后采用 Transformer 重新分配聚合后的权重系数,最后将聚合后的特征向量优化相关参数,得到推荐结果。

1 MHDGCN 模型

MHDGCN 模型需将初始的用户和项目相关信息转换为 One-Hot 编码。但 One-Hot 编码中的向量彼此正交,用户和项目彼此之间没有相似关系,需通过 WordVec2 模型^[13],将 One-Hot 转化为低纬度的连续值,并将其中意思相近的词映射到向量空间相近的位置,然后使用图卷积神经网络对用户项目特征向量进行全特征迭代抽取相关信息,之后将图卷积得到的用户-项目矩阵通过 Transformer 进一步提取用户的偏好特征,将得到的用户-项目评分矩阵进行一个全连接,通过 softmax 得出预结果。

MHDGCN 模型主要由 4 个模块组成,模块 1 是数据预处理阶段,模块 2 是图卷积神经网络对数据特征聚合阶段,模块 3 是一种基于注意力机制的深度神经网络(Transformer)的编码器(Encoder)和解码器(Decoder),模块 4 是模型预测阶段。MHDGCN 模型整体架构如图 1 所示。

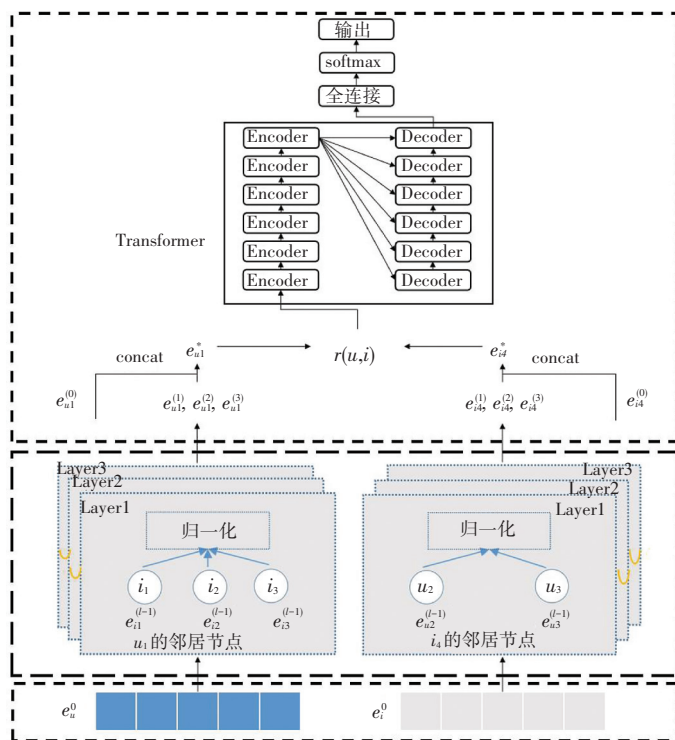


图 1 MHDGCN 模型结构

Fig. 1 Structure of MHDGCN

1.1 数据预处理

若有用户集合 $U = \{u_1, u_2, \dots, u_n\}$ 和商品集合 $I = \{i_1, i_2, \dots, i_m\}$, n 和 m 分别为用户和商品的总数, 定义用户与商品的交互矩阵为 $E \in M^{m \times n}$, $E_{ij} = \{1, review\}$, 表示用户 u_i 对商品 i_j 发生了交互, 并进行评论的内容。对交互矩阵 E 进行 One-hot 编码^[14], 再采用 Word2vec 的 Skip-gram 模型来获得稠密的连续特征向量。

Skip-gram 模型^[15]本质上是计算输入向量与目标输出向量之间的余弦相似度, 余弦相似度表示词语之间的关系, 最后进行 softmax 归一化。其计算公式为

$$p(\omega_0 | \omega_i) = \frac{e^{U_0 \cdot I_i}}{\sum_j e^{U_j \cdot I_i}} \quad (1)$$

其中, I_i 是 Embedding 层矩阵里的列向量, 也是 ω_i 的输入矢量; U_j 是 softmax 层矩阵里的列向量, 也就是 ω_i 的输出矢量。

将得到的稠密连续特征向量按照一定的维度产生 e_u^0 和 e_i^0 。其中, e_u^0 表示初始用户特征向量, e_i^0 表示初始商品特征向量。

1.2 图卷积神经网络

图卷积网络 (Graph Convolutional Network, GCN) 的作用类似于卷积神经网络 (Convolutional Neural Network, CNN), 但是 GCN 主要操作的对象是图数据。通过提取用户-商品交互的网络图的空间结构特征, 每一个卷积层处理一阶邻域的特征信息, 通过多层的卷积层实现多阶邻域的聚合, 最终实现聚合各个节点的特征。这种聚合各个邻居节点特征的方式可以表示为

$$e_u^{(k+1)} = AGG(e_u^{(k)}, \{e_i^{(k)} : i \in N_u\}) \quad (2)$$

式中: $e_u^{(k)}$ 表示第 k 层用户的嵌入, $e_i^{(k)}$ 表示第 k 层商家的嵌入, N_u 表示用户与商家的关联集合。AGG^[16] 是一个抽象表示的聚合函数, 是整个图卷积神经网络的核心部分, 通过多层的图卷积层来实现多阶邻域的聚合, 最终实现聚合各个节点的特征。

在图卷积神经网络模型中采用优化后简单加权和聚合的方式, 并选择再聚合时不与其本身相连接。这种用户-项目交互的图卷积可以用公式表示为:

$$e_u^{(k+1)} = \sum_{i \in N_u} \frac{1}{\sqrt{|N_u|} \sqrt{|N_i|}} e_i^{(k)} \quad (3)$$

$$e_i^{(k+1)} = \sum_{u \in N_i} \frac{1}{\sqrt{|N_i|} \sqrt{|N_u|}} e_u^{(k)} \quad (4)$$

式中: $e_u^{(0)}$ 、 $e_i^{(0)}$ 分别表示用户 u 和商品 i 的嵌入,

N_i 、 N_u 分别表示用户与商品的节点集, 拉普拉斯范数 $\frac{1}{\sqrt{|N_i|} \sqrt{|N_u|}}$ 表示商家对用户偏好的贡献程度。在经过多次卷积之后, 可以得到用户和商品的多个嵌入表示:

$$e^u = \sum_{k=0}^K \frac{1}{k+1} e_u^{(k)} \quad (5)$$

$$e^i = \sum_{k=0}^K \frac{1}{k+1} e_i^{(k)} \quad (6)$$

式中: $\frac{1}{k+1}$ 表示第 k 层嵌入聚合后嵌入表示的权重, 需要通过学习而不断变化的参数, 且 $\frac{1}{k+1} \geq 0$ 。

1.3 Transformer 神经网络

Transformer 由多层堆叠的 Encoder 和 Decoder 构成, 且每层又包括多头注意力机制^[17], 以及残差神经网络和归一化。Transformer 的模型如图 2 所示:

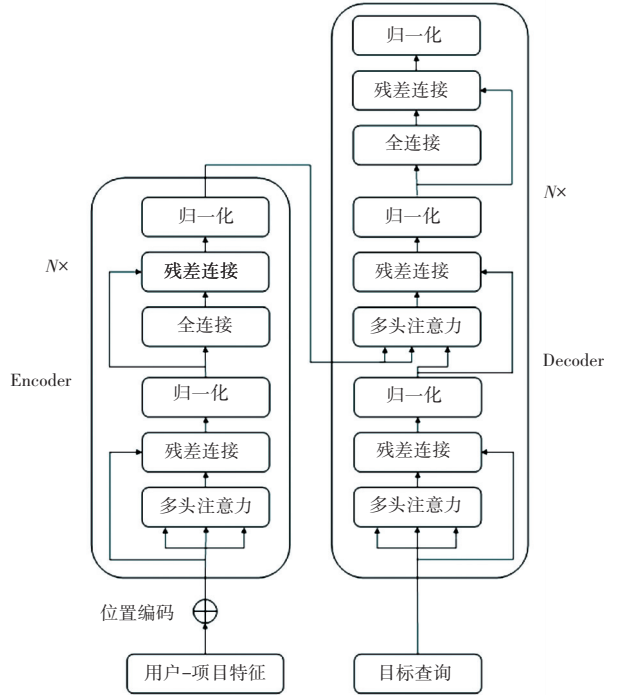


图 2 Transformer 模型结构

Fig. 2 Structure of transformer module

自注意力机制主要是模仿生物视觉的显著性检测和选择性注意, 建立长距离的依赖关系^[18], 解决卷积神经网络的局限性。因自注意力机制在对当前位置的信息进行编码时, 会过度的将注意力集中于自身的位置, 所以在此采用多头注意力机制可以生成更加准确的全局嵌入向量。

多头注意力机制将查询(Queue)、键(Key)和值(Value)分别进行不同的且经过训练的 h (头的数量)次3个维度线性投影,然后将其拼接起来再次投影,得到最后的结果。多头注意机制的项目嵌入矩阵 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T \in R^{n \times d}$, x_i 为所有项目中第 i 个项目的嵌入向量,输出为 $Y = [y_1, y_2, \dots, y_n] \in R^{n \times d}$, y_i 为经过多头注意力机制新生成的第 i 个项目的嵌入向量。公式为:

$$head = Attention(Q W_i^Q, K W_i^K, V W_i^V) \quad (7)$$

$$Attention(Q, K, V) = \text{softmax}\left(\frac{Q K^T}{\sqrt{d}}\right) V \quad (8)$$

$$Y = Concat(head_1, \dots, head_h) W^o \quad (9)$$

其中, Q 表示查询; K 代表键; V 代表值; W_i^Q 、 W_i^K 、 W_i^V 分别为3个维度的投影矩阵; W^o 为权重矩阵。注意层直观的计算出所有值的加权和,其中查询 i 和 j 之间的权值与查询 i 与 j 之间的交互有关。缩放因子 \sqrt{d} 是为了避免内积过大,尤其是在维度较高的情况。

每个解码器有两个多头注意力机制层,第一个多头注意力机制层采用了掩码^[19]的操作,主要是为了遮盖当前位置之后的信息,确保当前位置的预测结果只取决于当前位置输出。第二个多头注意力机制层和编码器中相同,但是输入 Q 、 K 、 V 来源不同, K 、 V 通过最后一层的输出计算得出, Q 则是由第一个掩码注意力机制层的矩阵计算得出。

1.4 预测层

将产生的所有用户和商品特征连接起来($\{u_i^1, \dots, u_i^n\}$ 表示用户特征、商家 $\{i_1^1, \dots, i_1^n\}$ 表示商品特征),计算用户向量和商品向量的内积,得出推荐的分数。再使用 softmax 函数,对所有的推荐分数进行归一化, \hat{z} 表示用户对商家的综合评分矩阵,得到最终预测评分应用于推荐列表(TOP - N)推荐,其公式如下:

$$\hat{y}_{u,i} = u_i^T i_i \quad (10)$$

$$\hat{z} = \text{softmax}(\hat{y}_i) \quad (11)$$

1.5 模型学习

本模型的任务是进行TOP - N 推荐,为了学习模型参数,目标函数使用BPR损失函数,其计算公式为

$$L_{BPR} = \sum_{(u,i,j) \in o} -\ln \sigma(\hat{y}_{ui} - \hat{y}_{uj}) + \lambda \|\theta\|_2^2 \quad (12)$$

其中, $o = \{(u, i, j) \mid (u, i) \in R^+, (u, j) \in R^-\}$ 表示成对的训练数据; R^+ 表示用户已经交互的集

合; R^- 表示未进行交互的集合; λ 是 L_2 正则化系数,防止过拟合。本文使用Adam优化器,更新模型参数。

2 实验与分析

2.1 实验环境

代码在开源的深度学习框架Pytorch-1.5.1开发,底层为Python3.8.3,所用操作系统为Windows10。

2.2 数据集

本文使用的实验数据来自于亚马逊^[20]公开数据集中较常用的Kindle_Store和Videos_Games数据集,数据集的统计见表1。

表1 数据集

Table 1 Statistics of datasets

数据集名称	用户数	物品数	评论数	稀疏度/%
Kindle_Store	68 223	61 935	982 619	99.97
Videos_Games	24 303	10 672	231 780	99.91

2.3 实验评价指标

在实验中,使用召回率(Recall@ N)、平均倒数排名(Mrr@ N)、命中率(Hit@ N)、归一化折损累计增益(NDCG@ N)、准确率(Precision@ N)5个指标来评估TOP - N 推荐的性能。

召回率是一种计算数据集中相关项目分数的方法,表示正确预测为正占全部正样本的比例,其计算公式为

$$\text{Recall@}N = \frac{I_u \cap I_r}{|I_r|} \quad (13)$$

平均倒数排名是计算由算法找到的第一个相关项在实际推荐列表中的排名,其计算公式为

$$\text{Mrr@}N = \frac{1}{|I_r|} \sum_{u \in U} \frac{1}{\text{rank}_u^*} \quad (14)$$

其中, rank_u^* 算法是为用户找到的第一个相关项的排名位置。

命中率是计算每个用户在Top - k 列表中属于测试集合的总数与测试集合的总数比,其计算公式为

$$\text{Hit@}N = \frac{I_u}{I} \quad (15)$$

归一化折损累计增益是考虑每个商品实际的相关性与前后顺序,相当于不同的用户之间进行标准化,其计算公式为

$$\text{NDCG@}N = \frac{\sum_{i=1}^p \frac{2^{\text{rel}_i} - 1}{\log_2 i + 1}}{\sum_{i=1}^{\text{REL}} \frac{2^{\text{rel}_i} - 1}{\log_2 i + 1}} \quad (16)$$

其中, rel_i 代表用户对 i 这个位置上的相关度; $|REL|$ 表示按照相关性从大到小进行排序的结果, 取前 P 个结果组成的集合。

准确率主要体现推荐算法所产生的推荐项目中用户感兴趣商家所占的百分比:

$$Precision@N = \frac{I_u \cap I_r}{|I|} \quad (17)$$

2.4 基准算法及参数设置

本次实验使用基准算法如下:

(1) NGCF^[8] 是一种基于深度图卷积神经网络, 主要通过传播嵌入用户-项目的图结构, 对用户-项目交互图中高阶连通性的表达建模, 之后通过矩阵分解协同过滤框架完成推荐。

(2) LightGCN^[9] 在 NGCF 基础上进行优化和改进, 是一种基于深度图卷积的用户-项目嵌入神经网络协同过滤算法。通过消融实验, 证明了在邻域聚合时多余的自信息, 以及进行了相关的优化后完成推荐。

(3) LightGCN-s^[11] 基于 LightGCN 进行改进, 将层组合系数改为可学习的模型参数, 利用注意力机制学习加权系数, 进而优化目标节点的嵌入表示, 为后续的排名预测提供更加有效的嵌入向量, 从而提升最终的推荐效果。

(4) GCACF^[12] 使用改进的图神经网络算法提取特征信息, 并使用注意力机制重新分配特征信息的权重, 以此进行推荐。

实验按照 8 : 1 : 1 的比例在用户维度上随机划分数据集来构建训练集、验证集和测试集; MHDGCN 模型超参数的设置见表 2。

表 2 模型的超参数设置

Table 2 Hyperparameter settings

超参数名称	参数值
用户、项目嵌入维数	64
优化器	Adam
学习率	0.001
批处理大小	256
L2 正则项系数	1e-2

2.5 实验结果分析

2.5.1 不同推荐算法比较

为了评估 MHDGCN 模型的性能, 在 Amazon-Kindle_Store 数据集进行实验, 通过设置 TOP - N 模拟不同程度的稀疏数据场景, 不同推荐算法在稀疏场景下的性能试验结果如图 3~图 7 所示:

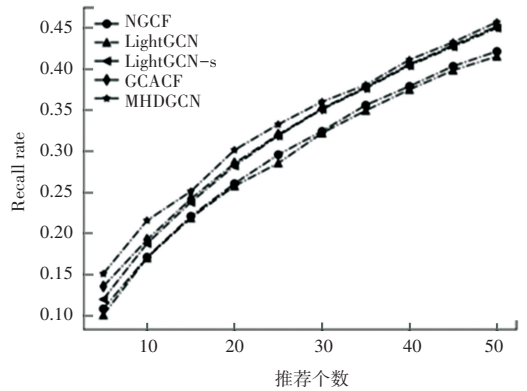


图 3 召回率曲线

Fig. 3 Curve of recall rate




图 4 平均倒数排名曲线

Fig. 4 Curve of MRR

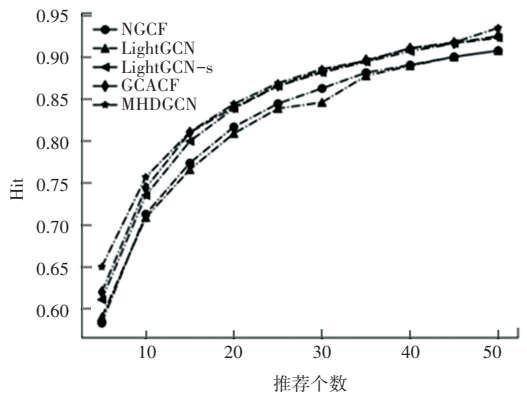


图 5 命中率曲线

Fig. 5 Curve of Hit rate

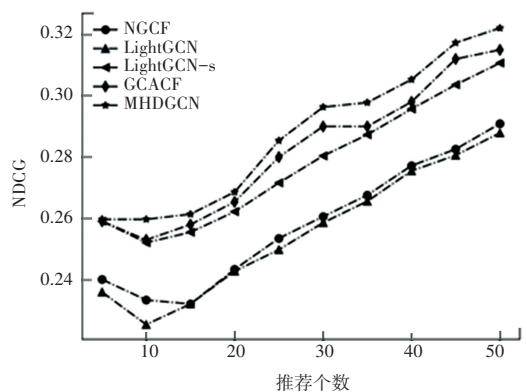


图 6 归一化折损累计增益曲线

Fig. 6 Curve of NDCG




图7 准确率曲线

Fig. 7 Curve of Precision

通过实验,统计了各算法在推荐个数为5、10、15、20、25、30、35、40、50时的实验结果。由图可以看出,MHDGCN与基准算法在召回率、命中率以及归一化折损累计增益指标与推荐项目个数成正比,与准确率成反比。加入注意力机制的LightGCN-s和GCACF的推荐性能明显好于LightGCN模型,说明引入注意力机制能在一定程度上提升模型的推荐性能。MHDGCN相比于几种基准算法在推荐性能指标Recall、MRR、Hit、NDCG、Precision上均有显著提升。

为了验证模型的有效性,在参数不变的情况下,对Amazon-Videos_Games数据集进行实验,结果见表3。

表3 Videos_Games 实验结果

Table 3 Experimental results of Videos_Games

模型	指标	N									
		5	10	15	20	25	30	35	40	45	50
NGCF	Recall@N	0.113 0	0.178 7	0.230 6	0.272 2	0.309 0	0.338 9	0.372 0	0.396 1	0.421 6	0.440 5
	MRR@N	0.410 9	0.429 1	0.434 1	0.434 2	0.438 0	0.436 6	0.434 0	0.429 1	0.434 5	0.439 9
	Hit@N	0.609 5	0.745 0	0.808 5	0.853 6	0.882 4	0.901 4	0.921 0	0.930 5	0.940 7	0.948 3
	NDCG@N	0.250 9	0.243 9	0.242 5	0.254 4	0.264 9	0.272 3	0.279 6	0.289 7	0.295 3	0.304 0
	Precision@N	0.219 3	0.180 6	0.158 7	0.140 2	0.132 0	0.121 8	0.113 9	0.108 9	0.101 2	0.098 4
LightGCN	Recall@N	0.105 1	0.177 8	0.228 5	0.269 2	0.298 2	0.336 5	0.365 2	0.391 9	0.416 4	0.434 2
	MRR@N	0.406 9	0.427 0	0.432 4	0.435 2	0.436 2	0.430 5	0.434 0	0.426 9	0.432 0	0.430 6
	Hit@N	0.616 8	0.740 8	0.800 4	0.845 3	0.876 3	0.884 0	0.917 0	0.929 5	0.940 6	0.948 3
	NDCG@N	0.246 6	0.235 5	0.242 5	0.253 7	0.261 0	0.270 2	0.277 6	0.287 9	0.293 2	0.300 9
	Precision@N	0.219 6	0.178 5	0.158 3	0.139 3	0.131 7	0.121 1	0.113 8	0.108 9	0.100 1	0.098 6
LightGCN-s	Recall@N	0.125 1	0.196 0	0.248 5	0.294 8	0.333 1	0.366 7	0.393 4	0.422 4	0.446 3	0.470 1
	MRR@N	0.435 8	0.455 0	0.460 3	0.457 7	0.461 3	0.463 2	0.463 1	0.462 4	0.465 2	0.463 4
	Hit@N	0.638 6	0.768 2	0.835 6	0.876 3	0.904 3	0.921 2	0.934 4	0.947 5	0.957 3	0.964 3
	NDCG@N	0.270 8	0.263 4	0.267 0	0.274 0	0.283 8	0.293 0	0.300 2	0.309 0	0.317 3	0.324 7
	Precision@N	0.236 2	0.193 2	0.168 1	0.151 2	0.139 3	0.129 5	0.121 0	0.114 4	0.108 5	0.103 6
GCACF	Recall@N	0.141 5	0.200 7	0.252 7	0.297 9	0.334 5	0.367 8	0.395 0	0.423 9	0.448 4	0.472 3
	MRR@N	0.437 9	0.461 1	0.463 4	0.465 7	0.466 8	0.468 3	0.466 6	0.468 3	0.465 7	0.464 3
	Hit@N	0.647 9	0.777 5	0.846 5	0.877 8	0.905 0	0.923 3	0.936 3	0.951 0	0.957 7	0.966 6
	NDCG@N	0.270 8	0.264 4	0.269 6	0.277 3	0.292 6	0.303 1	0.303 1	0.311 4	0.326 0	0.329 2
	Precision@N	0.233 8	0.193 3	0.170 3	0.152 6	0.135 9	0.132 7	0.121 0	0.115 0	0.109 7	0.104 3
MHDGCN	Recall@N	0.157 6	0.225 3	0.262 3	0.315 0	0.347 6	0.376 3	0.397 7	0.429 7	0.452 1	0.477 7
	MRR@N	0.440 6	0.463 1	0.464 4	0.472 7	0.468 3	0.468 8	0.468 8	0.469 7	0.471 6	0.477 3
	Hit@N	0.679 4	0.791 0	0.847 2	0.882 0	0.908 0	0.925 3	0.935 7	0.951 5	0.958 6	0.976 7
	NDCG@N	0.271 4	0.271 4	0.273 2	0.280 7	0.298 2	0.309 6	0.311 2	0.319 0	0.331 6	0.336 6
	Precision@N	0.245 2	0.199 5	0.174 3	0.156 5	0.146 2	0.138 0	0.126 0	0.120 5	0.115 7	0.109 7

通过两个数据集的实验对比可得出,在稀疏性较低的数据集中,所有推荐算法的性能都有一定的提升,由此可以得出数据的稀疏性越低,推荐性能越差。

2.5.2 不同聚合阶数下的效果实验

为了探究本模型在不同聚合阶数下对推荐性能

的影响,分别在 Kindle_Store 和 Videos_Games 数据集上进行实验,同时使用 Recall@5 和 Precision@5 对不同阶数的模型影响,其他参数保持不变。

根据表 4 可知,随着聚合阶数的增加,在两种数据集上的召回率和准确率都有一定的提升。

表 4 不同聚合阶数下对推荐性能的影响

Table 4 Effects of different polymerization orders on recommendation performance

模型	指标	Kindle_Store				Videos_Games			
		1	2	3	4	1	2	3	4
MHDGCN	Recall@5	0.125 1	0.143 7	0.148 5	0.150 8	0.128 2	0.136 0	0.140 5	0.143 3
	Precision@5	0.221 0	0.227 9	0.233 8	0.234 6	0.211 4	0.217 5	0.221 5	0.222 9

2.5.3 消融实验

为了探究各个模块对于整体模型的影响,分别在 Kindle_Store 数据集下进行了去除评论等相关特

征信息处理模块和去除 Transformer 模块两组实验。具体实验结果如图 8 所示:




图 8 消融实验对比

Fig. 8 Ablation experiments

实验结果表明,去除评论等相关特征信息处理模块的影响略小于 Transformer 模块,对整个模型的影响约为 4.32%,而去除 Transformer 模块影响约为 6.85%。由此可以看出,对于评论特征提取与 Transformer 模块对于实验的结果都十分重要。

综上所述,本文提出的 MDHGCN 模型在各项指标上都优于其他算法,推荐结果更好。因此,加入用户行为及评论信息使推荐更为准确;且融合图卷积神经网络和 Transformer 得出的模型能够提高推荐算法性能。

3 结束语

MHDGCN 是一种融合多源异构数据和图卷积神经网络的混合推荐模型,不仅能够基于用户评分、评论和社交网络动态数据,而且还能通过图卷积神

经网络进行聚合和 Transformer 重新分配聚合后的权重系数进行深度挖掘用户和项目的信息,提高推荐算法性能。通过在真实数据集上进行对比实验,MHDGCN 在准确率、召回率、Mrr、命中率和 NDCG 5 个指标上均优于基线方法,验证了模型的有效性,能够在一定程度上缓解数据稀疏性问题,提升推荐模型的推荐质量。

参考文献

[1] WANG H, ZHAO M, XIE X, et al. Knowledge graph convolutional networks for recommender systems [J]. arXiv preprint arXiv: 1905.04413v1, 2019.

[2] BAI T, WEN J R, ZHANG J, et al. A neural collaborative filtering model with interaction-based neighborhood [C]//Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. 2017: 1979-1982.

[3] 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.
- [4] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering [C]//Proceedings of the 26th International Conference on World Wide Web. IEEE, 2017; 173-182.
- [5] CHICAIZA J, VALDIVIEZO-DIAZ P. A comprehensive survey of knowledge graph-based recommender systems: Technologies, development, and contributions [J]. Information, 2021, 12 (6): 232.
- [6] 王星凯, 邓浩江, 盛益强. 基于深度学习的智能推荐系统综述 [J]. 网络新媒体技术, 2021, 10 (1): 1-11, 36.
- [7] KIPF T N, WELING M. Semi-supervised classification with graph convolutional networks [J]. arXiv preprint arXiv: 1609.02907, 2016.
- [8] 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.
- [9] 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. IEEE, 2020; 639-648.
- [10] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J]. arXiv preprint arXiv:1706.03762,2017.
- [11] 刘雨昕,陈春雨. 基于图卷积神经网络的推荐算法[J]. 应用科技,2022,49(4):13-17.
- [12] 王巍,杜雨暄,郑小丽,等. 基于图卷积自注意力机制的神经协同推荐算法[J]. 计算机工程与应用, 2023,59(13):247-258.
- [13] MIKOLOV T, CHEN K, CORRADO G, et al. Efficient estimation of word representations in vector space [J]. arXiv preprint arXiv: 1301.3781, 2013.
- [14] CHEN C, ZHANG M, LIU Y, et al. Neural attentional rating regression with review-level explanations[C]//Proceedings of the 2018 World Wide Web Conference. IEEE, 2018;1583-1592.
- [15] MIKOLOV T, SUTSKEVER I, CHEN K, et al. Distributed representations of words and phrases and their compositionality[J]. arXiv preprint arXiv:1310.4546,2013.
- [16] 刘艺璇,孙英娟,李婉桦,等. 基于图神经网络和 LSTM 的社交推荐算法[J]. 长春师范大学学报,2022,41(8):48-53.
- [17] 马欣. 基于 Transformer 的序列推荐研究[D]. 长春:长春师范大学,2022.
- [18] TAI C Y, WU M R, CHU Y W, et al. Mvin: Learning multiview items for recommendation[C]//Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2020; 99-108.
- [19] ZHANG J, SHI X, ZHAO S, et al. STAR-GCN: Stacked and reconstructed graph convolutional networks for recommender systems [J]. arXiv preprint arXiv: 1905.13129, 2019.
- [20] MCAULEY J, LESKOVEC J. Hidden factors and hidden topics: understanding rating dimensions with review text [C]//Proceedings of the 7th ACM Conference on Recommender Systems. 2013; 165-172.