

基于异质图神经网络的推荐算法研究

陈卓,李涵[†],杜军威

(青岛科技大学 信息科学技术学院,山东 青岛 266061)

摘要:基于图神经网络的推荐算法通过从图中获取知识,提高了推荐的解释性。然而随着推荐系统网络数据规模的不断扩大,用户-项目评分矩阵呈现出稀疏性问题,图神经网络难以学习到高质量的网络节点特征,导致推荐质量下降。本文将图神经网络与异质信息网络相结合,提出一种基于异质图神经网络的推荐算法。该算法使用异质信息网络对多源异质数据进行联合解码,将注意力机制引入用户-项目交互网络 and 用户社交网络的用户、项目聚合表示过程,从而实现用户-项目交互和用户社交两类网络间的节点及拓扑结构特征的有效融合。两个公开数据集上的对比实验结果表明,本文提出的算法在不断稀疏化的数据集上的推荐误差比基线方法少 40%。

关键词:图神经网络;异质信息网络;推荐;网络表示学习

中图分类号:TP18

文献标志码:A

Research on Recommendation Algorithm Based on Heterogeneous Graph neural Network

CHEN Zhuo, LI Han[†], DU Junwei

(School of Information Science and Technology, Qingdao University of Science and Technology, Qingdao 266061, China)

Abstract: By acquiring knowledge from a graph, the recommendation algorithm based on the graph neural network improves the recommendation interpretability. However, with the continuous expansion of the network data scale of the recommended system, the user-item scoring matrix displays a sparsity problem, which makes the graph neural network difficult to learn high quality network node features, and finally leads to the decline of recommendation quality. In this paper, a recommendation algorithm based on heterogeneous graph neural network is proposed by combining graph neural network with heterogeneous information network. This algorithm uses heterogeneous information network to decode multi-source heterogeneous data. And the attention mechanism is introduced into the user and item aggregation process of user-item interaction network and user social network, in order to realize the effective fusion of Node and topology characteristics of user-item interaction and user social networks. The experiment on two continuous sparse datasets show that the recommendation error of the algorithm proposed in this paper is 40% less than that of the baseline method.

Key words: graph neural network; heterogeneous information network; recommendations; network representation learning

* 收稿日期:2020-12-20

基金项目:国家自然科学基金资助项目(F030810), National Natural Science Foundation of China(F030810);山东省重点研发计划资助项目(2018GGX101052), Shandong Provincial Key Research and Development Plan Project Funding(2018GGX101052)

作者简介:陈卓(1978—),女,山东青岛人,青岛科技大学副教授,博士

[†] 通信联系人, E-mail: 1441995430@qq.com

随着电子商务和社交媒体平台的快速发展,推荐系统已经成为许多企业不可或缺的工具.一个高效的推荐系统能通过准确地捕捉用户的偏好,发现用户可能感兴趣的项目,从而提高用户对平台的满意度,提高用户的保留率.

推荐系统根据用户的兴趣和项目属性来评估用户对项目的偏好.由于用户兴趣和项目特征都用压缩向量表示,因此学习用户/项目交互和其他辅助信息,如社会关系和知识图的嵌入表示,成为该邻居需解决的关键问题.

在推荐系统中,大多数信息具有图结构,而图神经网络 GNN(Graph Neural Network)技术可以通过图节点之间的消息传递来捕捉图的相关性,因此 GNN 经常被用来生成用户/项目的嵌入表示.然而传统的基于 GNN 的推荐算法,只能够处理由单一类型节点构成的规则拓扑图,而当下网络中的数据并非只由单一类型节点构成.此外,传统 GNN 只融合节点的一阶邻居特征,无法获取节点在网络中的更深层结构关系.因此,当数据集稀疏,各节点均只有极少的邻居数时,基于传统 GNN 的推荐算法的推荐质量下降明显.

为了解决以上的不足之处,本文将图神经网络与异质网络相结合,提出深度推荐模型 H_GNN(Heterogeneous Graph Neural Network).本文的贡献可以总结为以下几点:

1)给出了异质信息网络的的多特征联合表示方法.面向用户/项目交互和用户社交两个域,利用异质信息网络中的多阶拓扑结构信息,增强网络连接稀疏情况下节点特征的代表能力.

2)提出了面向注意力机制的图神经网络推荐方法.通过对用户、项目、评分、社交等多维表示向量的有效融合,增强推荐模型在评分矩阵稀疏情况下,推荐模型的推荐质量.

3)通过在多个公共数据集上不断增加数据的稀疏性,验证本文模型推荐精度下降速度明显低于基线方法.

1 相关工作

1.1 基于异质信息网络的算法

近几年来,由多种节点或边组成的异质信息网络 HIN(Heterogeneous Information Network)作为一种融合复杂信息的强大建模方法被提出.与同构网络相比,由实体类型及其在 HIN 中的关系提供的异质

信息可以捕获更多语义上有意义的信息.2014年, Jacob 等人^[1]提出了一种将节点表示学习应用于不同节点类型共有的潜在空间上的新方法,但由于其将异质信息网络变成同构信息网络来处理,此类方法会丢失较多重要信息.2015年, Tang 等人^[2]提出了一种预测文本嵌入模型,但该方法不适用于除文本网络外的大多数异质信息网络.2017年,两种经典的基于元路径的异质信息网络表示学习方法^[3-4]被提出,它们使用元路径游走来捕获不同类型节点之间的关系.刘钰峰等人^[5]采用重启动随机游走进行查询推荐,在游走的基础上进行了改进.黄立威等人^[6]利用基于元路径的异质信息网络来做链路预测.近年来,异质信息网络作为一种新兴方向,逐渐被应用于推荐邻居中复杂关系的建模中. Shi 等人^[7]提出异质信息网络嵌入模型,通过异质信息网络生成特定关系对应的元路径,获得用户隐含向量,然后通过融合函数进行向量的融合并最终用于推荐.

上述算法在单个域上构建异质信息网络,在网络连接稀疏的情况下,节点可学习的邻居信息极少,使得节点表示学习质量不高.

1.2 基于图神经网络的推荐算法

图神经网络作为一种新型的拓展神经网络,可以在图上对节点进行特征提取和表示,是一种高效的神经网络结构.许多方法模型利用了 GNN 特有的优势来解决经典问题,并得到了优于传统方法的实验结果.例如, Berg 等人^[8]提出了一种图自编码器框架 GCMC(Graph Convolution Matrix Completion),从链路预测的角度解决推荐系统中的评分预测问题. Zhang 等人^[9]提出一种采用一堆 GCN(Graph Convolution Network)编码器/解码器与中间监督相结合的模型,以提高最终预测性能. Wu 等人^[10]利用 GNN 机制捕获了更深层次的社会扩散过程. Fan 等人^[11]提出一种基于图神经网络的模型用于推荐任务并展现了良好的性能.葛尧等人^[12]提出一种新的图卷积网络推荐算法,其使用两组图卷积来处理不同交互信息.上述算法均只能够处理由单一类型节点或单一类型关系构成的规则拓扑图,网络节点隐特征随机初始化, GNN 只融合节点的一阶邻居特征.由于上述算法忽略或未充分挖掘网络中节点间更深层的结构和语义信息,因此当网络节点均只有极少的邻居数,即用用户项目评分数据稀疏时,上述基于 GNN 的推荐算法的推荐质量明显下降.

1.3 注意力机制

注意力机制(Attention Mechanism)源于对人类

视觉的研究. 在认知科学中, 由于信息处理的瓶颈, 人类会选择性地关注所有信息的一部分, 同时忽略其他可见的信息, 上述机制通常被称为注意力机制. Velikovi 等人^[13]通过叠加图注意力层为中心节点的邻居节点分配不同的权重, 并据此融合邻居节点信息生成更有效的中心节点的特征表示. 张青博等人^[14]利用注意力机制分析用户对项目不同属性的关注度, 以此获取用户更准确的偏好信息.

注意力机制具有直观性、通用性和可解释性的优点, 已成为神经网络结构的重要组成部分, 被广泛应用到推荐系统、自然语言生成等不同类型的深度学习任务中^[15].

2 H_GNN 模型

2.1 H_GNN 模型框架

H_GNN 模型框架如图 1 所示, 图中显示了模型架构分为两部分: 首先是异质信息网络多特征融合(如图 1 中 H_GNN 第一部分), 采用迁移学习的思想, 构建面向图神经网络的预训练模型, 对购物和社

交两类数据进行联合解码, 共同学习用户、项目的低维隐特征, 从而最大限度地挖掘用户、项目之间的信息交互潜力, 提升图神经网络推荐模型的训练效率. 其次是面向注意力机制的图神经网络(如图 1 中 H_GNN 第二部分), 在图神经网络进行推荐建模时, 本文基于用户与项目间的不同交互行为、用户间的不同社交关系对用户偏好、项目特征表示的影响程度不同的假设, 将注意力机制引入用户/项目交互网络和用户社交网络的用户、项目聚合表示过程, 从而实现用户/项目交互和用户社交两类网络间的节点及拓扑结构特征的有效融合.

2.2 基于异质信息网络的信息多特征联合表示

本文构建的异质信息网络由用户、项目两类节点, 用户与项目间的交互关系和用户与用户间的社交关系构成. 其具体数学表示如下.

令 $U=\{u_1, u_2, \dots, u_n\}$ 和 $V=\{v_1, v_2, \dots, v_m\}$ 分别表示数据集中用户集合和项目集合, n 和 m 表示用户和项目的个数, $T \in R^{n \times m}$ 为用户项目交互矩阵, r_{ij} 表示用户 i 对项目 j 给出的评分, 如果用户没打出评分则 $r_{ij} = 0$, 评分可以看作是用户对该项目的喜好程度,

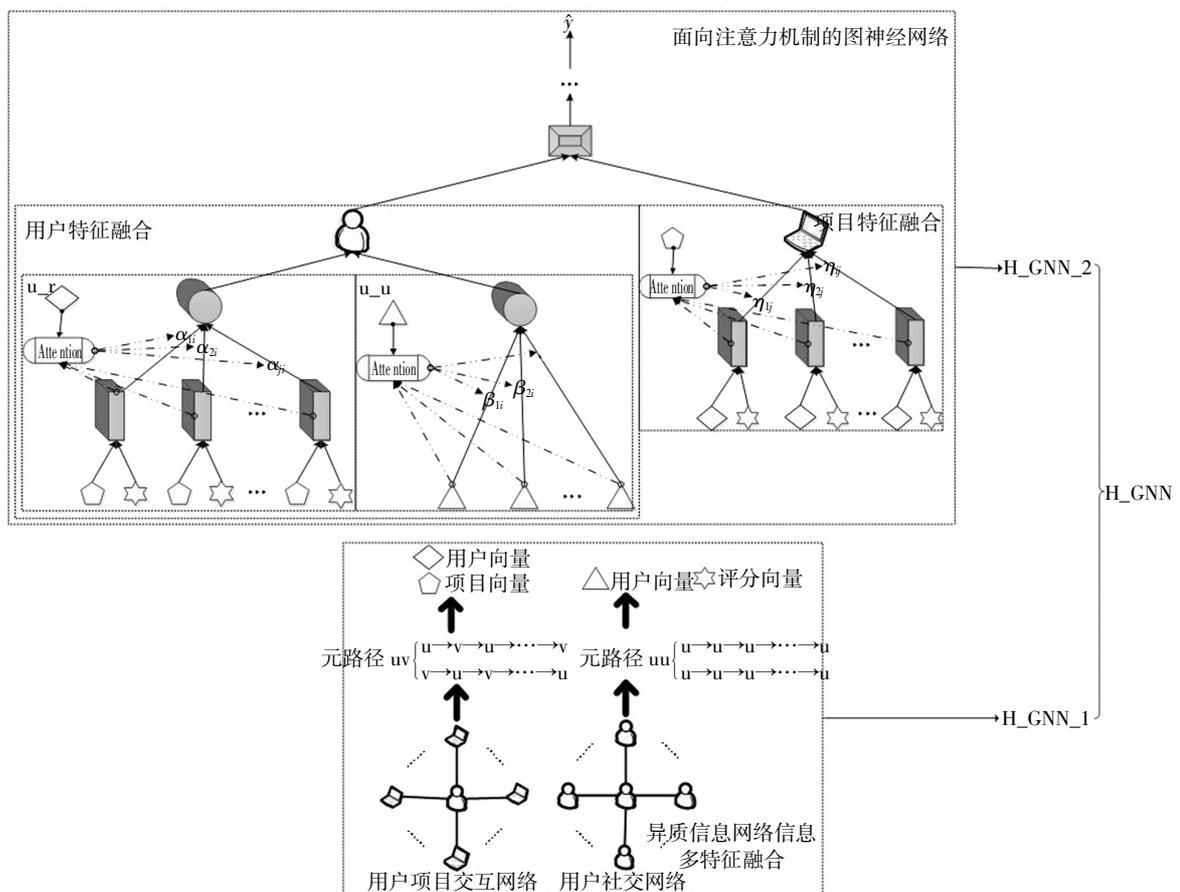


图 1 H_GNN 模型框架图

Fig.1 Block diagram of H_GNN model

评分越高代表用户越喜欢该项目. 一个用户可以对多个项目进行评分, 同样一个项目也可以被多个用户打分. $G \in R^{n \times n}$ 为用户社交矩阵. $\delta = (A, R)$ 表示一个网络结构图, 分为用户项目交互网络 u_v 和用户社交关系网络 u_u , 其中 A 表示网络图中的实体, 可以是用户或项目, R 表示实体之间的交互关系.

本文定义了两种元路径: 一种为用户-项目间的 UV 元路径, 体现用户与项目间的交互关系; 第二种是用户-用户间的 UU 元路径, 体现用户-用户间的社交关系. 下面给出路径生成规则.

具体计算公式为

$$P(n_{t+1}=x|n_t=v, \rho) = \begin{cases} \frac{1}{|N^{A_{t+1}}(v)|}, & (v, x) \in A \text{ and } \phi(x) = A_{t+1} \\ 0, & \text{otherwise} \end{cases} \quad (1)$$

式中: n_t 为当前节点, n_{t+1} 为下一个节点, $N^{A_{t+1}}(v)$ 表示 v 的邻居中属于 A_{t+1} 类型的节点, ρ 表示本文规定的元路径规则.

按照两种元路径分别经过采样后, 本文使用 Skip-gram^[6] 算法生成每个节点的特征向量, 将通过 UV 生成的用户和项目的向量表示为 $e_i^{u,v}$ 和 $e_j^{v,u}$, 将通过 UU 生成的用户向量表示为 $e_i^{u,u}$. 这里定义 L 为采样路径长度, L_c 为窗口大小. 此时上述两类网络节点的特征向量中已学习到用户/项目交互以及用户社交关系网络中的隐特征.

2.3 面向注意力机制的图神经网络推荐算法

用户/项目交互关系中附带评分属性, 同一用户对不同项目的评分、不同用户对同一项目的评分中蕴含着丰富的用户偏好和项目特征信息. 在用户/项目评分数据稀疏的情况下, 为充分挖掘用户/项目交互网络 and 用户社交网络中的关系和属性信息, 本文将注意力机制引入用户、项目的特征聚合表示过程, 从而实现用户/项目交互和用户社交两类网络间的节点及拓扑结构特征的有效融合.

在聚合与中心用户节点发生交互的邻居项目节点、社交用户节点时, 利用注意力机制根据用户特征为邻居项目、邻居用户分配不同的权重, 从而体现不同交互项目、不同社交用户在体现用户喜好特征时不同的重要性. 在聚合与中心项目节点发生交互的邻居用户节点时, 利用注意力机制根据项目特征为邻居用户分配不同的权重, 从而体现不同邻居用户在体现项目特征时不同的重要性.

2.3.1 用户特征融合

对于用户, 本文融合了独立的两部分, 针对用户项目交互网络的 u_v 和针对用户社交网络的 u_u .

u_v : 对于任何一个用户, 本文使用其邻居项目和评分来表示该用户针对某一项目的隐含向量表示, 然后通过 attention 网络生成对应的权重, 最后融合所有的隐含向量得到交互网络中该用户的隐含向量表示. 具体计算公式为

$$h_i^{u,v} = \text{Aggregation}(x_{jr}, \forall j \in N_i \text{ and } \forall r \in C) \quad (2)$$

式中: $h_i^{u,v}$ 表示用户 i 在交互网络中的隐含向量表示, C 表示用户对项目打出的所有评分, Aggregation 表示融合函数, 具体计算公式为

$$h_i^{u,v} = \sigma(w[\sum_{\substack{j \in N_i \\ r \in C}} \alpha_{ij} x_{jr}] + b) \quad (3)$$

σ 为激活函数, w 和 b 为神经网络参数, α_{ij} 为项目 j 对用户 i 的权重, 每个项目对用户的重要程度不同, 如果把所有的权重指数都置为 1, 会导致预测结果不理想, 因此本文通过两层神经网络训练权重. 具体计算公式为

$$\alpha_{ji} = \text{soft max}(w_2 \sigma(w_1 [x_{jr} \oplus e_i^{u,v}] + b_1) + b_2) \quad (4)$$

x_{jr} 表示项目 j 和对应评分 r 的向量融合. x_{jr} 具体计算公式为

$$x_{jr} = g_r(e_j^{v,u} \oplus e_r) \quad (5)$$

g_r 为一个多层全连接神经网络, \oplus 表示向量的拼接. e_r 表示随机初始化生成的评分向量.

u_u : 本文使用用户社交网络中该用户的邻居向量融合来表示该用户在社交网络中的隐含向量表示, 具体计算公式为

$$h_i^{u,u} = \text{Aggregation}(e_{j'}^{u,u}, \forall j' \in N_i) \quad (6)$$

$$h_i^{u,u} = \sigma(w[\sum_{j' \in N_i} \beta_{ji'} e_{j'}^{u,u}] + b) \quad (7)$$

式中: $\beta_{ji'}$ 为邻居 j' 对用户 i 的权重指数, 具体计算公式为

$$\beta_{ji'} = \text{soft max}(w_2 \sigma(w_1 [e_i^{u,u} \oplus e_{j'}^{u,u}] + b_1) + b_2) \quad (8)$$

由公式(3)和(7), 本文分别得到了用户/项目交互网络 and 用户社交网络中的用户隐特征, 并最终通过公式(9)将这两部分特征进一步融合. 具体计算公式为

$$h_i = \sigma(w_n \cdots (w_2 (h_i^{u,v} \oplus h_i^{u,u}) + b_2) \cdots b_n) \quad (9)$$

2.3.2 项目特征融合

项目的向量 $h_j^{v,u}$ 具体计算公式为

$$h_j^{v,u} = \text{Aggregation}(x_{ir}, \forall i \in N_j \text{ and } \forall r \in C) \quad (10)$$

$$h_j^{v,u} = \sigma(w[\sum_{\substack{i \in N_j \\ r \in C}} \eta_{ji} x_{ir}] + b) \quad (11)$$

$$x_{ir} = g_r(e_i^{u,r} \oplus e_r) \quad (12)$$

用户 i 对项目 j 的权重指数 η_{ij} , 具体计算公式为

$$\eta_{ij} = \text{soft max}(w_2 \sigma(w_1[x_{ir} \oplus e_j^{u,r}] + b_1) + b_2) \quad (13)$$

这里得到的项目隐含向量表示作为最终的项目向量表示.

2.3.3 评分预测

本文通过上面得到的用户向量和项目向量来预测用户对项目的评分, 在这里本文定义了一个多层的全连接层网络, 把用户和项目向量的拼接作为网络的输入, 网络的输出则是预测评分. 具体计算公式为

$$\hat{y} = \sigma(w_n \cdots (w_2(h_i \oplus h_j^{u,r}) + b_2) + \cdots + b_n) \quad (14)$$

2.3.4 模型学习

本文使用经典交叉熵损失函数进行模型更新, 具体计算公式为

$$\text{Loss} = \sqrt{\frac{1}{C} \sum_{\substack{i \in U \\ j \in V}} (\hat{y}_{ij} - y_{ij})^2} \quad (15)$$

式中: \hat{y}_{ij} 为用户 i 对项目 j 的预测评分, y_{ij} 为真实评分, U 是所有用户集合, V 是所有项目的集合. 对于优化器本文选择了在深度学习中广泛应用的 Adam 算法, 因为许多实证结果表明 Adam 算法优于其他随机优化算法.

3 实验与结果分析

3.1 数据集及评价指标

本文使用了 Ciao 和 Epinions 两个数据集进行对比实验, 这两个数据集是由亚利桑那州立大学学者在做社交网络方面研究的时候使用的数据集. 可以分别从 <http://www.cse.msu.edu/~tangjili/trust.html> 和 <http://www.trustlet.org/epinions.html> 网页链接上获取. 它们分别包含了 283 319 和 764 352 个评级.

本文采用了 RMSE(Root Mean Square Error)和 MAE(Mean Absolute Error)两项指标来验证模型准确度.

3.2 参数的设定

H_GNN 模型的超参数有路径长度、窗口大小、学习率和嵌入维度.

本文通过实验对比了在不同学习率下, 路径长度为 10、窗口大小为 5 和路径长度为 20、窗口大小为 10 的预测误差. 关于参数实验结果如表 1 所示, 表中显示了 H_GNN 模型在路径长度为 20、窗口大小为 10、学习率为 0.004 时预测误差最小.

表 1 路径长度、窗口大小、学习率对比实验

Tab.1 Comparative experiment of path length, window size and learning rate

路径长度	窗口大小	评价指标	学习率			
			0.001	0.002	0.003	0.004
10	5	RMSE	0.975 8	0.965 9	0.984 7	0.969 8
		MAE	0.753 4	0.748 1	0.761 3	0.732 8
20	10	RMSE	0.978 6	0.967 7	0.987 1	0.965 9
		MAE	0.756 2	0.738 6	0.750 6	0.731 3

关于在不同嵌入维度下, H_GNN 模型的预测误差实验结果如图 2、图 3 所示, 图中显示了 H_GNN 模型在嵌入维度为 64 时, 预测误差最小.

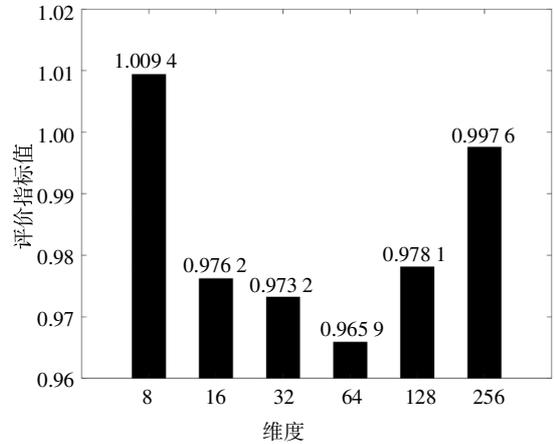


图 2 嵌入维度实验指标 RMSE 对比

Fig.2 Comparison of experimental index RMSE of embedded dimension

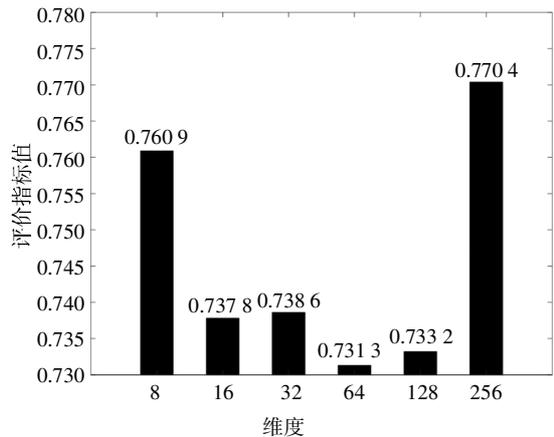


图 3 嵌入维度实验指标 MAE 对比

Fig.3 Comparison of experimental index MAE of embedded dimension

3.3 对比实验

为了评估 H_GNN 模型的推荐性能, 本文选择以

下六种推荐模型作为基线方法,进行对比实验.

SocialMF^[17](Social Matrix Factorization):主要思想是在矩阵分解中引入信任传播,用户表示接近其信任的用户.

NeuMF^[18](Neural Matrix Factorization):模型主要思想是结合了传统矩阵分解和多层感知机,可以同时抽取低维和高维的特征.

DeepSoR^[19](Deep Social Recommendation):主要思想是从社交关系学习到的用户表示集成到概率矩阵分解中.

DeepFM^[20](Deep Matrix Factorization):主要思想是联合训练 FM (Matrix Factorization) 模型和 DNN (Deep Neural Networks)模型,同时学习低阶特征组合和高阶特征组合.

Wide&Deep^[21](Wide and Deep):提出一种融合浅层模型和深层模型进行联合训练的框架.

GCMC^[8]:提出一种从链路预测角度解决评分预测的图自编码器框架.

GraphRec^[11](Graph Recommendation):主要思想是按用户商品间的交互关系和用户间的社交关系两

个层次,依次融合用户、项目特征,进而训练 GNN 网络预测评分.

H_GNN 与基线方法在 Ciao 和 Epinion 两个数据集上,按照 6:4 划分训练和测试集.关于模型对比实验结果如表 2 所示,表中显示了在两个数据集的两个评价指标下,H_GNN 模型均得到了最小的预测误差.

为了验证 H_GNN 模型在稀疏数据集上的推荐质量,本文基于 Ciao 数据集构造了不同稀疏程度的 9 个数据集,在保证 Ciao 数据集不出现用户、项目冷启动的情况下,依次对用户/项目评分数据进行了 9 次稀疏化,每次减少 10%的评分数据,并选择同样基于 GNN 且也融合了社交网络辅助信息的推荐邻居最先进的模型之一——GraphRec 模型作为基线方法.

关于 H_GNN 与基线方法中预测效果最好的 GraphRec 模型的稀疏度对比实验结果如图 4、图 5 所示,图中显示了在评分数据不断减少的过程中,H_GNN 模型相比 GraphRec 模型的推荐质量提升明显,在评分数据最为稀疏的 90%处,H_GNN 模型比 GraphRec 模型的推荐误差降低了约 40%.

表 2 推荐模型预测误差对比实验

Tab.2 Comparison experiment of recommended model prediction error

训练集	评价指标	SocialMF	NeuMF	DeepSoR	DeepFM	Wide & Deep	GCMC	GraphRec	H_GNN
Ciao	RMSE	1.059 2	1.082 4	1.043 7	1.038 7	1.034 5	1.022 1	1.009 3	0.965 9
Ciao	MAE	0.835 3	0.825 1	0.781 3	0.774 1	0.770 9	0.769 7	0.754 0	0.731 3
Epinions	RMSE	1.141 0	1.164 5	1.113 5	1.109 8	1.108 2	1.100 4	1.087 8	1.058 9
Epinions	MAE	0.896 5	0.909 7	0.852 0	0.848 4	0.846 5	0.860 2	0.844 1	0.829 7

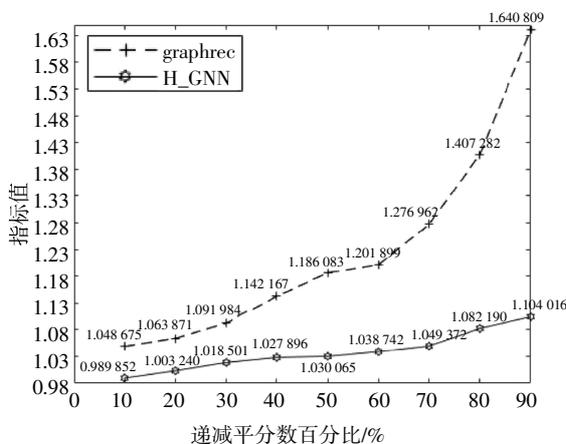


图 4 随稀疏度改变 RMSE 指标对比

Fig.4 RMSE index comparison with sparsity change

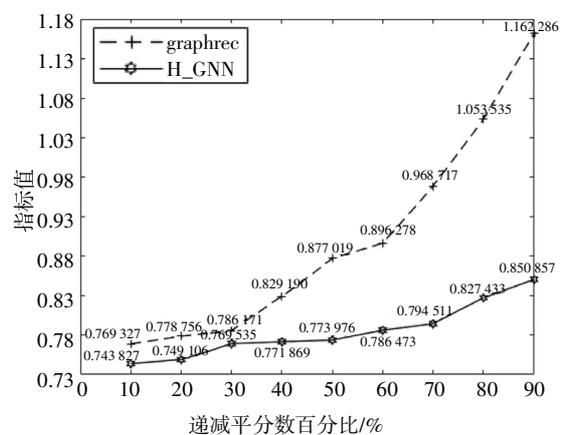


图 5 随稀疏度改变 MAE 指标对比

Fig.5 MAE index comparison with sparsity change

由上述实验结果可知,在用户/项目交互稀疏的情况下,相比于基线方法使用随机初始化用户/项目

节点表示进行推荐模型训练,本文提出的基于异质信息网络的多特征联合表示方法具有更强的节点特

征表示能力,提出的面向注意力机制的图神经网络推荐方法能有效融合用户、项目、评分、社交等多维特征提升推荐质量.

3.4 消融实验

为了探究基于异质信息网络的信息多特征联合表示、用户社交网络信息聚合对 H_GNN 模型训练效果的影响,本文在两种不同稀疏度的 Ciao 数据集上进行了两组消融实验.其中 H_GNN_2 模型为取消基于异质信息网络的信息多特征联合表示,直接采用随机值初始化用户、项目特征向量作为面向注意力机制的图神经网络推荐算法的输入;H_GNN-u_u 模型为在面向注意力机制的图神经网络推荐算法中,取消用户社交网络 u_u,只采用用户项目交互网络 u_v 进行用户特征聚合.关于消融实验结果如图 6、图 7 所示,图中显示了在稀疏度为 50%和 90%的 Ciao 数据集上,H_GNN 模型的预测误差明显低于 H_GNN_2 和 H_GNN-u_u 模型.

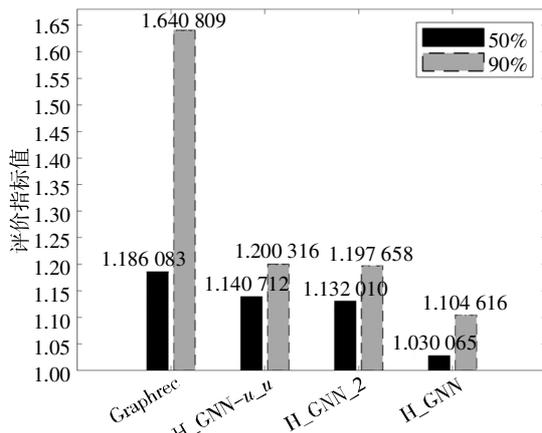


图 6 消融实验中 RMSE 指标对比

Fig.6 RMSE index comparison in ablation experiment

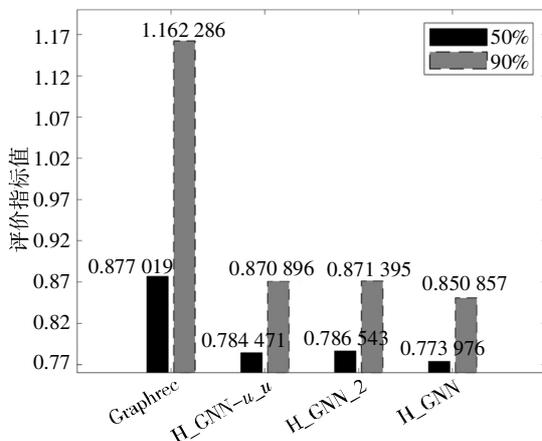


图 7 消融实验中 MAE 指标对比

Fig.7 MAE index comparison in ablation experiment

由 H_GNN_2 消融实验结果可知,使用基于异质信息网络的信息多特征联合表示有助于提升 H_GNN 模型推荐质量.由 H_GNN-u_u 消融实验结果可知,融合用户社交信息,使用户特征向量中包含用户社交关系特征,同样有助于提升 H_GNN 模型推荐质量.

4 结 论

数据稀疏性问题是推荐系统面临的最具挑战性的问题之一.数据稀疏使得图网络中节点可学习的结构信息变少,因此传统基于 GNN 的推荐算法预测误差大.本文提出一种基于异质图神经网络的推荐算法,使用异质信息网络对多源异质数据进行联合解码,引入注意力机制进行用户/项目交互网络和用户社交网络中用户、项目特征的聚合表示,从而充分挖掘稀疏数据集中蕴含图节点及拓扑结构特征.通过在两个公开数据集上进行的大量对比实验结果表明,本文提出的算法在原始和不断稀疏化的数据集上的推荐误差均明显小于所有的基线方法.

随着时间的推移,推荐系统中的网络节点及其关系会不断变化,目前本文的推荐模型仅适用于静态图网络,后续可进一步开展动态图网络增量计算推荐算法的研究.

参考文献

- [1] JACOB Y, DENOYER L, GALLINARI P. Learning latent representations of nodes for classifying in heterogeneous social networks[C]//Proceedings of the 7th ACM International Conference on Web Search and Data Mining. New York, USA: ACM, 2014: 373—382.
- [2] TANG J, QU M, MEI Q Z. PTE: predictive text embedding through large-scale heterogeneous text networks [C]//Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Sydney NSW Australia. New York, USA: ACM, 2015: 1165—1174.
- [3] DONG Y X, CHAWLA N V, SWAMI A. Metapath2vec: scalable representation learning for heterogeneous networks[C]//Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Halifax NS Canada. New York, USA: ACM, 2017: 135—144.
- [4] FU T Y, LEE W C, LEI Z. HIN2Vec: explore meta-paths in heterogeneous information networks for representation learning[C]//Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. New York, USA: ACM, 2017: 1797—1806.
- [5] 刘钰峰, 李仁发. 基于 Term-Query-URL 异构信息网络的查询推

- 荐[J]. 湖南大学学报(自然科学版), 2014, 41(5): 106—112.
- LIU Y F, LI R F. Query suggestion by constructing heterogeneous term-query-URL information network [J]. Journal of Hunan University (Natural Sciences), 2014, 41(5): 106—112.
- [6] 黄立威, 李德毅, 马于涛, 等. 一种基于元路径的异质信息网络链路预测模型[J]. 计算机学报, 2014, 37(4): 848—858.
- HUANG L W, LI D Y, MA Y T, *et al.* A link prediction model for heterogeneous information networks based on meta-path [J]. Chinese Journal of Computers, 2014, 37(4): 848—858. (In Chinese)
- [7] SHI C, HU B, ZHAO X, *et al.* Heterogeneous information network embedding for recommendation [J]. IEEE Transactions on Knowledge and Data Engineering, 2019, 31(2): 357—370.
- [8] BERG R V D, KIPF T N, WELLING M. Graph convolutional matrix completion[EB/OL]. 2017: arXiv: 1706.02263 [stat.ML]. <https://arxiv.org/abs/1706.02263>.
- [9] ZHANG J N, SHI X J, ZHAO S L, *et al.* STAR-GCN: stacked and reconstructed graph convolutional networks for recommender systems [C]//Proceedings of the Twenty-Eighth International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2019: 4264—4270.
- [10] WU L, SUN P, FU Y, *et al.* A neural influence diffusion model for social recommendation [C]//International ACM SIGIR Conference on Research and Development in Information Retrieval. New York, USA: ACM, 2019: 235—244.
- [11] FAN W Q, MA Y, LI Q, *et al.* Graph neural networks for social recommendation [C]//The World Wide Web Conference - WWW '. New York, USA: ACM Press, 2019: 417—426.
- [12] 葛尧, 陈松灿. 面向推荐系统的图卷积网络 [J]. 软件学报, 2020, 31(4): 1101—1112.
- GE Y, CHEN S C. Graph convolutional network for recommender systems [J]. Journal of Software, 2020, 31(4): 1101—1112. (In Chinese)
- [13] VELIKOVI P, CUCURULL G, CASANOVA A, *et al.* Graph attention networks [EB/OL]. (2017-10-30)[2020-03-30]. <https://arxiv.org/abs/1710.10903>.
- [14] 张青博, 王斌, 崔宁宁, 等. 基于注意力机制的规范化矩阵分解推荐算法[J]. 软件学报, 2020, 31(3): 778—793.
- ZHANG Q B, WANG B, CUI N N, *et al.* Attention-based regularized matrix factorization for recommendation [J]. Journal of Software, 2020, 31(3): 778—793. (In Chinese)
- [15] CHAUDHARI S, POLATKAN G, RAMANATH R, *et al.* An attentive survey of attention models[EB/OL]. 2019: arXiv: 1904.02874 [cs.LG]. <https://arxiv.org/abs/1904.02874>.
- [16] MIKOLOV T, CHEN K, CORRADO G, *et al.* Efficient estimation of word representations in vector space [EB/OL](2013-10-23)[2014-2-23]. <http://dblp.uni-trier.de/db/journal-alsort/corr1301.html>.
- [17] JAMALI M, ESTER M. A matrix factorization technique with trust propagation for recommendation in social networks [C]//Proceedings of the Fourth ACM Conference on Recommender Systems - RecSys '. New York, USA: ACM Press, 2010: 135—142.
- [18] HE X, LIAO L, ZHANG H, *et al.* Neural collaborative filtering [C]//International Conference on World Wide Web. Switzerland: International World Wide Web Conferences Steering Committee, 2017: 173—182.
- [19] WEN Q F, QING L, MIN C. Deep modeling of social relations for recommendation [C]//National Conference of the American Association for Artificial Intelligence. New Orleans: Internet Society, 2018: 8075—8076.
- [20] GUO H F, TANG R M, YE Y M, *et al.* DeepFM: a factorization-machine based neural network for CTR prediction [C]//Proceedings of the Twenty-Sixth International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2017: 2782—2788.
- [21] CHENG H T, KOC L, HARMSSEN J, *et al.* Wide & deep learning for recommender systems [C]//Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. New York, USA: ACM, 2016: 7—10.