

李小波, 马珍弟, 郑健, 等. 基于图神经网络的非物质文化遗产推荐模型[J]. 智能计算机与应用, 2025, 15(2): 198-207.
DOI: 10.20169/j.issn.2095-2163.24101701

基于图神经网络的非物质文化遗产推荐模型

李小波¹, 马珍弟¹, 郑健¹, 田中娟²

(1 浙江师范大学 计算机科学与技术学院, 浙江 金华 321004; 2 浙江师范大学 艺术学院, 浙江 金华 321004)

摘要: 针对非物质文化遗产推荐系统存在用户偏好难以捕捉和内容信息挖掘不充分的问题, 提出了一种基于改进注意力机制的残差图神经网络(GNN-AR)推荐模型。该模型通过引入图注意力网络来捕捉用户潜在的兴趣偏好, 能够更加精确地建模用户与非物质文化遗产内容之间的关系; 利用文本提取器有效提取非物质文化遗产中的文本内容信息, 从而增强了对内容特性的理解。为进一步提升模型的表达能力, 融合残差连接机制捕捉用户行为与内容特性之间的复杂交互关系, 避免了信息在深层网络中的过度衰减, 确保特征信息的有效传递。为验证提出模型的有效性, 在3个数据集上进行的实验结果表明, GNN-AR模型在捕捉用户偏好和挖掘非物质文化遗产内容信息方面优于现有的主流推荐方法。此外, 该模型在多个评价指标上有较为显著的提升, 验证了其在非物质文化遗产推荐系统中的应用潜力, 为非物质文化遗产数字化保护与传承提供了新的思路与方法。

关键词: 推荐系统; 图神经网络; 非物质文化遗产; 残差连接; 注意力机制

中图分类号: TP391 **文献标志码:** A **文章编号:** 2095-2163(2025)02-0198-10

Recommendation model for intangible cultural heritage based on graph neural network

LI Xiaobo¹, MA Zhendi¹, ZHENG Jian¹, TIAN Zhongjuan²

(1 School of Computer Science and Technology, Zhejiang Normal University, Jinhua 321004, Zhejiang, China;
2 College of Art, Zhejiang Normal University, Jinhua 321004, Zhejiang, China)

Abstract: To address the challenges in intangible cultural heritage (ICH) recommendation systems, specifically the difficulty in capturing user preferences and insufficient content information mining, this paper proposes a residual graph neural network recommendation model based on an improved attention mechanism (GNN-AR). The model leverages a graph attention network to capture users' latent interest preferences, enabling more precise modeling of the relationships between users and ICH content. A text extractor is employed to effectively extract textual content information from ICH, thereby enhancing the understanding of content characteristics. To further improve the model's expressiveness, a residual connection mechanism is introduced to capture the complex interactions between user behavior and content features, preventing information degradation in deep networks and ensuring the effective transmission and fusion of feature information. To validate the effectiveness of the proposed model, experiments were conducted on three datasets. The results demonstrate that the GNN-AR model outperforms existing mainstream recommendation methods in capturing user preferences and mining ICH content information. Additionally, the model shows significant improvements across multiple evaluation metrics, verifying its potential for application in ICH recommendation systems and providing new insights and methods for the digital protection and inheritance of ICH.

Key words: recommendation system; graph neural network; Intangible Cultural Heritage; residual connection; attention mechanism

0 引言

非物质文化遗产(以下简称“非遗”)是指人类

在社会实践中所创造的,以口头传统、表演艺术、社会习俗、仪式、节庆等方式传承的、以符号、象征和象征意义为主要特征的文化形式和传统知识体系,是

基金项目: 教育部人文社会科学研究规划基金(22YJAZH053); 浙江省哲学社会科学重点研究基地江南文化研究中心课题(2022JDKTYB10)。

作者简介: 马珍弟(1999—),男,博士研究生,主要研究方向:深度学习; 郑健(1999—),男,硕士,主要研究方向:推荐系统; 田中娟(1972—),女,硕士,教授,主要研究方向:非物质文化遗产。

通信作者: 李小波(1969—),男,博士,教授,主要研究方向:人工智能,数字人文。Email: lxb@zjnu.edu.cn。

收稿日期: 2024-10-17

民族文化和人类文明的重要组成部分^[1]。非物质文化遗产在数字化进程中面临多方面的挑战,其受众较小且用户与非遗内容之间的交互数据较为稀缺,许多数字化系统在信息挖掘方面和数据稀疏性问题上表现出较大的局限性,难以有效获取知识^[2]。此外,用户兴趣与非遗内容的匹配难度较高,传统信息提取方法难以准确捕捉用户对深层文化内涵的兴趣偏好,导致文化传播难度增大^[3]。

推荐系统的出现为非遗文化的传播提供了一个新方向。通过分析用户的浏览历史、喜好和行为模式,推荐系统可以向用户推荐其可能感兴趣但尚未了解的非遗项目,从而扩大用户对非遗文化的认知范围^[4]。推荐系统在非遗数字化保护方面具有个性化推荐、发现潜在兴趣和提高传播效率,解决“信息过载”等优势,有助于促进非遗文化的传承与保护^[5]。

随着信息复杂度的提升,传统推荐算法在捕捉用户与物品之间深层次交互关系方面仍然存在一定的局限性^[6]。深度推荐算法使用多层神经网络学习用户和物品的表示,其中包括用户和物品的特征向量、隐含表示等。通过对深度学习模型的训练,能够提取出更为复杂的用户与物品特征,从而提升推荐系统的精准度^[7]。

图神经网络(Graph Neural Networks, GNN)能够有效处理非遗数据中的复杂关系结构,如非遗项目、传承人、地域文化之间的联系。Scarselli等^[8]定义了图结构数据上进行信息传播和节点表示学习的方法,建立了图神经网络的理论基础。Kipf等^[9]引入图拉普拉斯算子,将谱卷积理论简化为一种高效的层级计算方法,使得在大规模图上进行图卷积变得可行。Hamilton等^[10]提出了GraphSAGE模型,通过采用可扩展的邻居采样和聚合策略,有效捕捉图数据中节点间的复杂关系。He等^[11]提出了一种轻量级的图卷积网络架构LightGCN,通过去除复杂的非线性激活函数和特征变换,专注于信息的传播和聚合,从而提高了计算效率和模型可解释性。Veličković等^[12]引入了自注意力机制,使得模型能够根据邻居节点的重要性动态调整特征聚合过程,通过多头注意力机制增强了模型的表达能力。Xu等^[13]进一步改进了GAT的注意力机制,提出了一种使用关联矩阵的方法,以增强模型对图结构的建模能力。

基于以上研究,本文提出了一种改进的注意力机制结合残差连接的图神经网络(GNN-AR)推荐

模型。该模型能够充分挖掘用户与非物质文化遗产项目之间的复杂交互关系,通过残差连接机制增强信息传递的有效性。引入了融合文本特征的图注意力机制,精准捕捉用户的兴趣偏好,增强了用户与非遗项目的匹配度。

1 相关工作

1.1 图神经网络在推荐系统中的应用

随着图神经网络(GNNs)技术的不断成熟,越来越多的研究者开始探索其在推荐系统中的应用,并取得了显著成果。例如,GATNE^[14]提出了图注意力网络,用于异质图上的推荐任务,通过引入不同类型的边权重来学习多元关系的表示。NGCF^[15]结合了图卷积网络和嵌入传播机制,在不增加复杂度的情况下,有效增强了用户与项目的交互表示。

SEAL^[16]通过将图神经网络应用于链路预测任务,在考虑局部子图信息的基础上,展示了GNNs在捕捉复杂关系方面的潜力。HeteroRec^[17]提出了一种基于异质图神经网络的推荐方法,通过建模多种类型的用户与项目交互关系,提升了跨域推荐的效果。DGRec^[18]引入动态图神经网络,能够在不断变化的用户行为图中捕捉时间序列信息,增强了推荐系统适应性。TAGNN^[19]通过在GNN中结合序列信息和图结构信息,有效提升了会话推荐的精度,特别是在短期用户行为预测任务中展现了强大的表现。

1.2 图注意力机制在推荐系统中的应用

图注意力机制在推荐系统中,通过动态调整权重,能够聚焦于与用户偏好最为相关的特征或项目。例如,SASRec^[20]利用自注意力机制,在不考虑时间顺序的情况下,有效建模了用户的序列化行为,从而提高了个性化推荐的准确度。MA-GNN^[21]提出一种新型的双分支多注意力图神经网络,通过使用图注意力网络来聚合局部信息,同时通过语义相似性增强实体嵌入。Vision GNN^[22]提出了一种将图像划分为若干节点并使用GNN进行处理的架构,通过K近邻方法将图像划分成不同的节点,进而使用图结构进行训练,突破了传统卷积神经网络的限制。SR-GNN^[23]模型结合了图神经网络和空间关系感知机制,用于细粒度图像分类。OSAN^[24]提出了一种有序子图聚合网络,通过聚合子图信息来提高图神经网络的性能。GDCNN^[25]引入了一种基于测地线距离的图神经网络,能够更有效地捕捉图中的长距离依赖关系,从而提高图表示学习的效果。IRGN^[26]提出了一种迭代优化的图神经网络,用于

抗体序列-结构共设计,显著提高了抗体设计的准确性和效率。KGNN^[27]提出了一种新的K-hop消息传递方法,用来增强GNN的表达能,并通过理论和实验验证了其有效性。RGNN^[28]提出了一种自适应残差图神经网络,利用自适应残差连接来解决深层GNN中的梯度消失问题。

2 相关定义

设:给定用户集合 $U = \{u_1, u_2, \dots, u_m\}$ 和非遗项目集合 $V = \{v_1, v_2, \dots, v_n\}$,用户与项目的交互矩阵可以表示为 $R \in R^{m \times n}$,其中 R_{ij} 表示用户对项目的偏好评分。通过学习目标映射函数 $f: U \times V \rightarrow R$,能够准确预测未知的用户-项目交互,即对于任意 $(u_i, v_j) \in U \times V$,预测 $\hat{R}_{uw} = f(u_i, v_j)$ 接近真实值 R_{uw} 。

其中,用户 u 和项目 v 的潜在表示为 h_u 和 h_v ,经过多层图卷积网络更新后,得到最终的节点表示 h_u^{final} 和 h_v^{final} 。用户对项目的偏好分数 \hat{R}_{uw} ,可以利用下式来排序推荐列表,并在训练时最小化损失函数。

$$\hat{R}_{uw} = (h_u^{\text{final}}, h_v^{\text{final}}) \quad (1)$$

通过模型预测概率 \hat{y}_{uw} 表示用户 u 对项目 v 兴趣的概率,真实标签 y_{uw} 表示用户 u 对项目 v 的兴趣

(1表示感兴趣、0表示不感兴趣),然后利用下式计算交叉熵损失函数。

$$L = - \sum_{(u,v) \in E} y_{uv} \log(\hat{y}_{uv}) + (1 - y_{uv}) \log(1 - \hat{y}_{uv}) \quad (2)$$

3 GNN-AR 模型

3.1 GNN-AR 模型框架

GNN-AR 推荐模型的具体框架结构如图1所示,模型主要由图剪边器、残差多层图卷积、词向量注意力聚合和评分预测等4部分组成。

(1)图剪边器旨在处理稠密的图结构,去除图中的噪声或无关的边,从而简化图的结构,提高模型的训练效率和推荐精度。

(2)残差多层图卷积网络旨在通过多个卷积层对图数据进行特征提取。每一层图卷积负责聚合节点的邻居信息,从而更新节点的表示。

(3)词向量注意力聚合用于整合文本信息与节点嵌入信息。引入注意力机制,计算文本词向量和节点的嵌入向量的权重,以及每个词和节点的重要性分数。最终,利用加权聚合的方式,生成文本的全局表示和节点的全局表示。

(4)评分预测获取模型的最终输出结果。通过对节点表示的进一步处理,生成用户对项目的评分用于推荐系统中的排序任务。

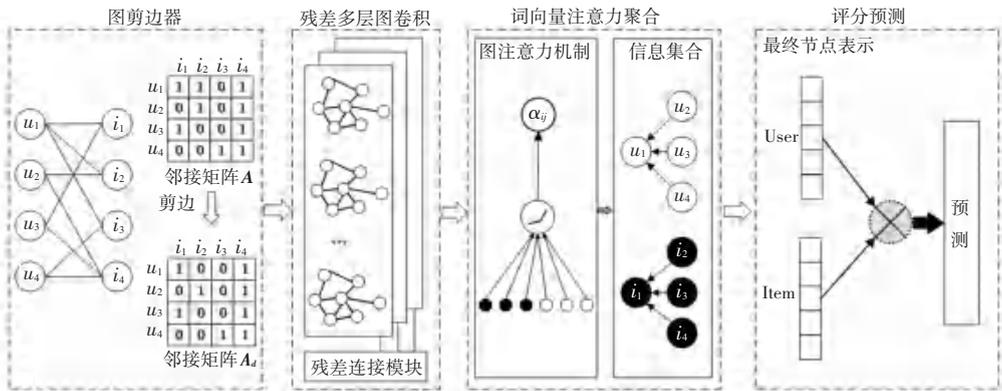


图1 GNN-AR 模型框架图

Fig. 1 GNN-AR Model Framework

3.2 GNN-AR 模型实现

3.2.1 图剪边器

为了消除图结构中的大量噪声或无关边,设计了图剪边器,旨在识别和移除不相关或影响较小的边,优化模型的整体性能。 E 表示边集合,通过图剪边器,筛选出一部分重要边集合 $E' \subseteq E$,每条边 $e_{ij} \in E$ 连接节点 v_i 和 v_j ,对节点特征向量 h_i 和 h_j 之

间的相似度进行权重计算,用来衡量边的重要性。可通过下式计算边的权重。

$$w_{ij} = \frac{h_i^T \cdot h_j}{\|h_i\| \cdot \|h_j\|} \quad (3)$$

其中, h_i 和 h_j 是节点 v_i 和 v_j 的特征向量, w_{ij} 是边 e_{ij} 的权重,表示节点 v_i 和 v_j 之间的关系强度。

通过边剪枝策略设定一个加权剪枝值 τ ,当边

的权重 w_{ij} 小于该阈值时, 移除这条边, 否则保留。剪边的策略可以定义为 $E' = \{e_{ij} \in E \mid w_{ij} \geq \tau\}$, 其中 E' 是剪枝后的边集合, τ 是剪枝阈值。通过为每一条边分配不同的权重, 根据相似度大小进行加权剪边, 保留权重前 k 条边。最后, 通过下式对保留的边权重进行归一化, 以确保计算的数值稳定性。归一化后的权重 w_{ij} 保证所有保留边的权重和为 1。

$$\hat{w}_{ij} = \frac{\exp(w_{ij})}{\sum_{e_{ik} \in E'} \exp(w_{ik})} \quad (4)$$

3.2.2 残差多层图卷积

图卷积神经网络是图神经网络中的核心组件, 其原理主要包括邻居节点特征聚合、权重参数学习和特征更新 3 个步骤。

在通过线性变换之后, 可以得到用户与项目节点的初始嵌入向量 $e^{(0)} \in R^d$, 其中 d 用来表示嵌入的维度。图卷积层对每个节点 i 进行处理, 通过聚合其邻居节点的特征来捕获局部邻域信息。在用户和项目的交互图上执行图卷积操作, 分别获得下一层的用户节点嵌入和项目节点嵌入, 图卷积计算过程如下式所示。

$$e_i^{(l)} = \sigma \left(\sum_{j \in N_i \cup \{i\}} \alpha_{ij}^{(l-1)} \mathbf{W} e_j^{(l-1)} \right) \quad (5)$$

其中, l 用来表示图卷积的层数; 参数 α_{ij} 表示第 i 个节点和第 j 个节点之间的权重系数; N_i 可表示节点 i 的邻居集合; e_i 表示第 i 个节点的嵌入信息; \mathbf{W} 是权重参数矩阵 (可通过训练得到); $\sigma(\cdot)$ 表示非线性激活函数。

多层图卷积网络能够在交互图中提取有效的协同关系信息, 并通过增加嵌入传播的层数, 实现高阶协同关系信息的传递。节点在 l 层的嵌入函数可以用下式来表示。

$$e_u^{(l)} = \sigma(\tilde{\mathbf{D}}^{-1/2} \tilde{\mathbf{A}} \mathbf{D}^{-1/2} e_u^{(l-1)} \mathbf{W}^{(l)}) \quad (6)$$

其中, $e_u^{(l)}$ 表示节点 u 在第 l 层的嵌入信息; σ 为激活函数; $\tilde{\mathbf{D}}$ 为归一化的节点度矩阵; $\tilde{\mathbf{A}}$ 为带自环的邻接矩阵; $e_u^{(l-1)}$ 为节点 u 在第 $l-1$ 层的嵌入信息; $\mathbf{W}^{(l)}$ 为第 l 层的权重矩阵。

然而, 仅增加网络层数并不总能有效地提升模型性能, 为此引入残差连接, 每个残差模块包括两层以上的卷积层, 以便在深层网络中维持信息的有效传递和避免梯度消失问题。如图 2 所示, $F(x)$ 是任何深度学习模型中的映射, 如卷积层或全连接层。通过将输入 x 直接加到变换后的输出 $F(x)$ 上, 得到最终输出 $H(x)$ 。该模型能够捕捉到输入与输出之

间的残差, 有效地缓解深层神经网络中梯度消失的问题。

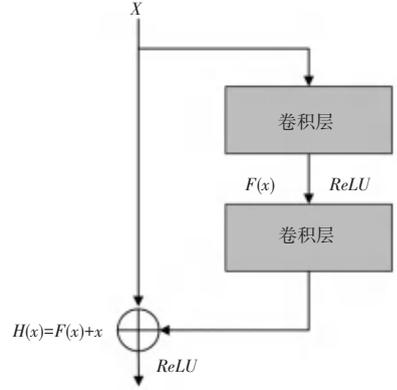


图 2 残差网络结构图

Fig. 2 Residual Network Architecture

3.2.3 词向量注意力聚合

为了提高模型对非遗文本数据的理解能力, 设计了一种高效的词向量提取器。通过从项目文本中提取有效特征, 使模型能够更准确地捕捉非遗的核心信息。此外, 模型引入了注意力机制, 使其能够动态调整对文本中各个词汇或片段的重要性权重。根据上下文的相关性进行智能权重分配, 有效过滤了冗余或噪声数据, 为用户提供更加个性化和精准的推荐, 图 3 展示了词向量注意力聚合的框架。

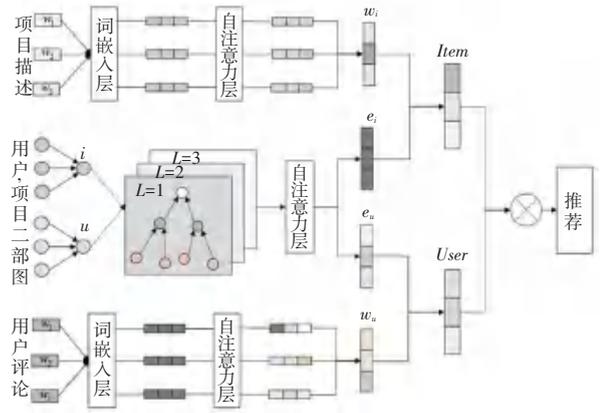


图 3 词向量注意力聚合结构图

Fig. 3 Word Vector Attention Aggregation Structure

给定一个非物质文化遗产项目 p 的文本描述 T_p , 通过词向量提取器将其转化为向量表示 v_p , 以捕获该文本中的语义信息。利用词嵌入层将文本 T_p 中的每个单词 w_i 转化为词向量 e_i , 利用预训练的词向量 Word2Vec 得到的词嵌入矩阵 \mathbf{W}_e , 通过下式对其进行映射。

$$e_i = \mathbf{W}_e \cdot w_i \quad (7)$$

其中, e_i 是文本中第 i 个单词的词向量表示; W_e 是词嵌入矩阵; w_i 是文本中的单词。

在特征提取层,使用卷积神经网络来提取局部上下文信息。设 F 为卷积核,用于连续的 k 个词向量序列 $e_{i:i+k-1}$,具体计算如下式所示。

$$c_i = \text{ReLU}(F \cdot e_{i:i+k-1} + b) \quad (8)$$

其中, c_i 是通过卷积提取的特征向量, F 是卷积核, b 是偏置项, ReLU 是激活函数。然后将整个文本的特征合并为一个向量表示,使用平均池化来汇总特征,公式如下:

$$v_p = \text{MaxPool}(c_1, c_2, \dots, c_n) \quad (9)$$

其中, v_p 是项目文本 T_p 的最终向量表示, n 是文本中单词的数量。最终,文本提取器输出的向量 v_p 可以作为推荐模型中的输入。

借助预训练的词嵌入模型,将每个词转换为固定维度的词向量,从而构建词向量矩阵;之后,运用注意力机制对这些词向量进行加权,动态地为每个词分配重要性权重;最终通过加权求和生成节点的文本表示向量,有效融合了文本的潜在信息和上下文特征。结合下式为输入词向量构建查询 Q 键、 K 值、 V 矩阵,设置词向量 $X_v \in R^{n \times d}$ 。

$$Q = X_v W_Q, K = X_v W_K, V = X_v W_V \quad (10)$$

其中, $W_Q, W_K, W_V \in R^{d \times d_k}$ 是可通过训练得到的权重矩阵。通过计算查询与键的相似度来获取注意力分数,使用点积来衡量相似性,然后通过下式进行标准化权重。

$$A = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right) \quad (11)$$

其中, $A \in R^{n \times n}$ 是注意力权重矩阵。根据权重矩阵 A 对词向量进行加权求和,得到下式:

$$H_v = AV \quad (12)$$

其中, H_v 是节点 v 的聚合文本特征。

然后构建用户与项目的二部图,并利用注意力机制动态建模用户与项目之间的关系,从而获得用户的嵌入表示 e_u 和项目表示 e_i 。对节点嵌入向量同样应用注意力机制,设置一个注意力权重向量 $w_{\text{node}} \in R^d$,由下式得出节点嵌入的注意力得分。

$$\beta_i = \frac{\exp(w_{\text{node}}^T \cdot h_i)}{\sum_{j=1}^m \exp(w_{\text{node}}^T \cdot h_j)} \quad (13)$$

其中, h_i 是第 i 个节点的嵌入向量, β_i 是第 i 个节点的注意力权重系数。

最终,基于这些权重对节点嵌入进行加权求和,结合下式得到节点的全局表示向量 H_u :

$$H_u = \sum_{i=1}^m \beta_i \cdot h_i \quad (14)$$

通过将文本表示 v_p 和节点表示 H_u 进行融合,使用加权求和方式得到最终的节点表示。

设定两个可学习的融合权重参数 λ_1 和 λ_2 ,分别控制文本表示和节点表示的贡献,结合下式最终节点表示如下:

$$Z = \lambda_1 \cdot v_p + \lambda_2 \cdot H_u \quad (15)$$

文本词向量和节点嵌入经过各自的注意力机制处理后,生成的全局表示通过融合机制共同决定了最终的节点表示。得到的用户节点表示 (User) 和项目节点表示 (Item),综合了用户与项目的语义信息和图结构信息,具有更丰富的表征能力。

3.2.4 评分预测

经过 L 层的信息嵌入传播,最终获得用户 u 和项目 i 的节点嵌入信息,具体计算过程见下式:

$$H_u = \sum_{l=0}^L W_l H_u^{(l)} \quad (16)$$

$$H_i = \sum_{l=0}^L W_l H_i^{(l)} \quad (17)$$

其中, W_l 代表在不同层组合中的权重。通过计算用户节点 u 和项目节点 i 的最终嵌入向量内积,可以得到用户对特定项目的偏好评分,如下式所示。

$$\hat{R}_{ui} = H_u^T H_i \quad (18)$$

利用内积运算得到的相似度作为用户 u 对项目 i 的评分预测。最后将所有候选项目进行排序,根据预测的评分生成推荐列表,以便向用户推荐最符合的项目。

4 实验

本文实验所使用的操作系统为 Windows 11 专业版,开发环境为 Python 3.7.9,并基于 Pytorch 1.11 实现了本文中的模型。

4.1 实验设置

4.1.1 数据集

本文研究中使用了两个公用推荐数据集 Yelp^[29] 和 Books^[30],以及一个自建的非遗项目评分数据集 FeiYi。FeiYi 数据集中有上千条非物质文化遗产项目的详细信息,如项目名称、所属地区、公布时间、项目描述等。此外,还包含了用户信息,如用户名、用户 ID 等。用户对非遗项目的评分信息也被记录在数据集中。数据集的统计数据见表 1。

表1 评估数据集的详细信息

Table 1 Detailed information of the evaluation dataset

DataSet	User	Item	Interaction
Yelp	161 305	114 852	957 923
Books	59 703	52 802	765 308
FeiYi	2 165	1 473	41 226

4.1.2 对比模型

为了评估本文提出的方法,实验将 GNN-AR 与如下基线模型进行了综合性能比较。

STGCN^[31]:一种时空图卷积神经网络,用于处理时空序列数据,能够有效捕捉时空关系并进行预测。

GCMC^[32]:通过结合图卷积和多模态特征学习,能够更有效地挖掘和融合图数据中的复杂结构信息与多样化特征,从而提升推荐系统的性能。

NGCF^[15]:一种基于图卷积神经网络的推荐模型,提出了显式邻居信息传播和聚合机制,将用户和项目的特征通过邻居节点传播,从而捕获多阶交互关系。

GCCF^[33]:一种采用线性残差图卷积方法的图卷积神经网络模型,用于改进基于图的协同过滤推荐系统的性能。

LightGCN^[11]:一种轻量级的图卷积神经网络模型,专注于学习用户和物品之间的交互关系,以简化模型结构并提高推荐性能。

KGAT^[34]:将基于项目知识的关系信息纳入图注意力机制中的图神经网络推荐模型,通过多层消息传递机制捕捉用户和物品之间的高阶连接信息。

HGAT^[35]:使用不同类型的节点和边之间的异质邻接矩阵来表示异质图的结构。引入了异质图卷积操作,允许节点之间的信息传播跨越不同类型的边。

4.1.3 评价指标

实验采用两个常用的评估指标: NDCG@K 和 HR@K,以衡量推荐系统的性能。本实验的 K 值分别设置为 10 和 20。NDCG 定义为:

$$\text{NDCG}@K = \frac{\text{DCG}@K}{\text{IDCG}@K} \quad (19)$$

$$\text{DCG}@K = \sum_{i=1}^k \frac{2^{\text{rel}_i} - 1}{\log_2(i+1)} \quad (20)$$

$$\text{IDCG}@K = \sum_{i=1}^k \frac{1}{\log_2(i+1)} \quad (21)$$

其中, rel_i 表示第 i 个推荐结果的相关程度, K 表示推荐列表的长度。HR 定义为:

$$\text{HR}@K = \frac{\text{Number of Hit}@K}{\text{Total number of users}} \quad (22)$$

其中,“Number of Hit@K”表示用户实际点击

列表中的某一项的数量,“Total number of users”表示参与评估的用户总数。

为了验证 GNN-AR 模型的性能,在数据集上进行了多次的对比实验。实验结果见表 2~表 4。

表2 GNN-AR 模型在 Yelp 数据集对比结果

Table 2 Comparison of GNN-AR model results on the Yelp dataset

Methods	Yelp			
	HR@10	HR@20	NDCG@10	NDCG@20
STGCN	0.222 2	0.308 3	0.164 2	0.193 1
GCMC	0.234 9	0.322 0	0.170 4	0.202 2
NGCF	0.235 7	0.327 2	0.174 2	0.203 7
GCCF	0.236 3	0.328 3	0.178 3	0.203 3
LightGCN	0.242 7	0.340 5	0.181 9	0.210 4
KGAT	0.243 3	0.334 2	0.183 1	0.215 1
HGAT	0.242 1	0.333 9	0.187 7	0.216 5
GNN-AR	0.251 7	0.343 1	0.189 1	0.220 4

表3 GNN-AR 模型在 Books 数据集对比结果

Table 3 Comparison of GNN-AR model results on the Books dataset

Methods	Books			
	HR@10	HR@20	NDCG@10	NDCG@20
STGCN	0.074 2	0.115 1	0.036 5	0.046 6
GCMC	0.076 1	0.117 5	0.037 3	0.047 4
NGCF	0.066 5	0.103 2	0.032 7	0.041 8
GCCF	0.080 6	0.118 5	0.038 4	0.050 5
LightGCN	0.083 9	0.127 8	0.040 9	0.051 6
KGAT	0.078 9	0.121 0	0.040 7	0.049 2
HGAT	0.081 4	0.125 8	0.039 1	0.049 7
GNN-AR	0.087 2	0.132 5	0.042 3	0.052 8

表4 GNN-AR 模型在 FeiYi 数据集对比结果

Table 4 Comparison of GNN-AR model results on the FeiYi dataset

Methods	FeiYi			
	HR@10	HR@20	NDCG@10	NDCG@20
STGCN	0.096 6	0.154 7	0.164 3	0.196 2
GCMC	0.101 4	0.162 5	0.168 1	0.199 4
NGCF	0.108 2	0.167 2	0.176 0	0.205 5
GCCF	0.115 1	0.173 8	0.179 4	0.208 4
LightGCN	0.120 4	0.180 6	0.178 7	0.210 2
KGAT	0.121 0	0.181 9	0.180 7	0.211 2
HGAT	0.121 8	0.182 3	0.181 3	0.212 3
GNN-AR	0.123 0	0.183 9	0.183 2	0.214 9

4.1.4 参数设置

实验使用 Xavier 初始化模型的所有可训练参数,通过 Adam 优化器来优化图神经网络模型,学习率一般在 $\{0.0001, 0.001, 0.01, 0.1\}$ 范围内扫描调整,本实验设置为 0.001;正则化权重在 $\{0.1, 0.01, 0.001, 0.0001\}$ 范围内扫描调整,本实验固定为 0.0001;训练时的 batch size 固定为 256;嵌入维度设置为 64,图卷积的层数设置为 4。

4.2 实验结果分析

4.2.1 模型对比分析

在对比实验中,GNN-AR 模型在不同数据集上的表现明显优于所参考的基线模型。在 Yelp 数据集中,GNN-AR 模型在 HR@10 指标上相较于最佳基线模型 KGAT 提升了约 3.45%。在 NDCG@10 指

标上,模型较最佳基线模型 HGAT 提升了约 0.75%。此外,GNN-AR 模型在 HR@20 和 NDCG@20 指标上分别提升了约 0.76%和 1.80%。在 Books 数据集上的性能对比结果表明,GNN-AR 模型在 HR@10 和 HR@20 指标上分别提高了约 3.93%和 3.68%,体现了其在捕捉用户偏好方面的优势。在 FeiYi 数据集上的性能对比结果显示,GNN-AR 模型在各项评价指标上均优于现有的基线模型。特别是与 HGAT 模型相比,GNN-AR 在 HR@10、HR@20、NDCG@10 和 NDCG@20 指标上分别提升了约 0.98%、0.88%、1.05%和 1.22%,结果表明 GNN-AR 模型在捕捉用户潜在兴趣的有效性。图 4 直观展示了 GNN-AR 模型与其他基线模型在不同评价指标上的性能对比结果。

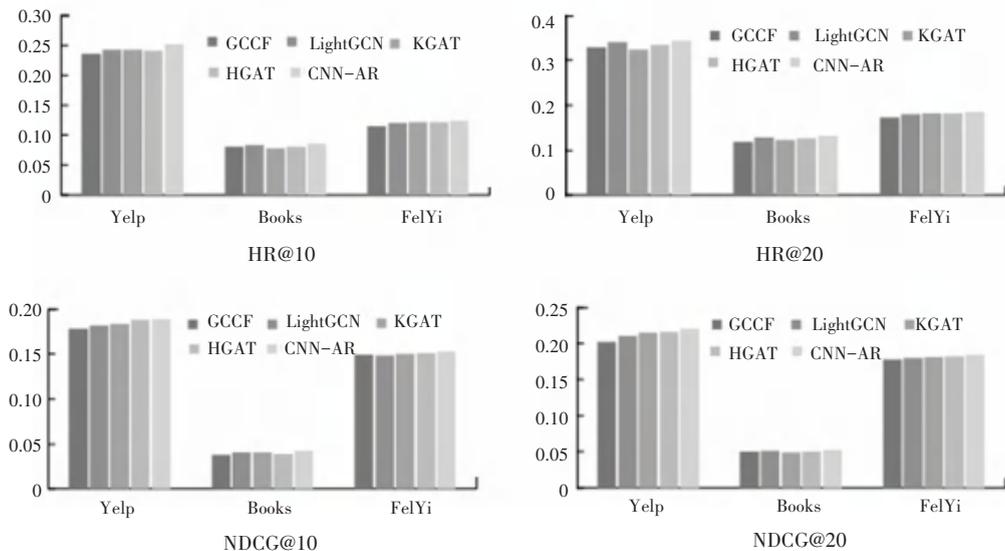


图 4 评价指标性能对比图

Fig. 4 Comparison of evaluation metrics performance

由上述实验结果可知,在深层网络结构中,GCCF 模型通过加入残差模块,有效地缓解了训练中存在的梯度消失和梯度爆炸问题。由于 LightGCN 模型采用了一种基于邻接矩阵的加权求和方式,只考虑与其直接相连的节点的信息,并将这些信息进行加权求和,作为该节点的表示,在对比实验中获得了不错的效果。KGAT 模型和 HGAT 模型加入了注意力机制,在大部分实验中都获得了比图卷积模型更好的性能指标。实验结果表明,引入注意力机制可以使模型更加聚焦于对当前节点表示更有贡献的邻居节点。本文提出的 GNN-AR 模型在捕捉用户与项目之间复杂交互关系方面具有较强的能力。通过引入改进的注意力机制和残差图卷积方法,模型能够更加有效地提取和利用图结构中的高阶特征信息,从而在多个关键评

价指标上都展现出了显著的改进。

4.2.2 参数分析

在 GNN-AR 模型中,通过堆叠多个图卷积层,模型能够学习到更深层次的图结构特征,从而提升推荐系统的性能。如图 5 所示,随着图卷积层的加深,GNN-AR 模型在各项评价指标上均表现出了显著的提升,这证明了图卷积层对于模型性能的积极影响。然而,也需要注意避免过度堆叠图卷积层,以免引起过拟合或模型复杂度过高的问题。

如图 6 所示,当嵌入维度增至 128 时,模型性能并未显著提升,甚至出现了下降趋势,这一现象可能是由于过大的嵌入维度导致模型过拟合。因此,将图卷积嵌入维度设定为 64,确保在保持足够高的表征能力的同时,降低模型的复杂度,提高训练和推荐的效果。

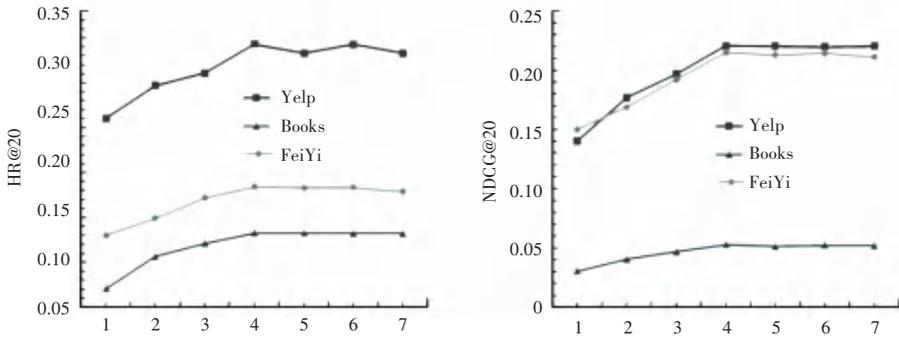


图 5 图卷积层数对模型的影响

Fig. 5 Impact of different numbers of graph convolutional layers on the model

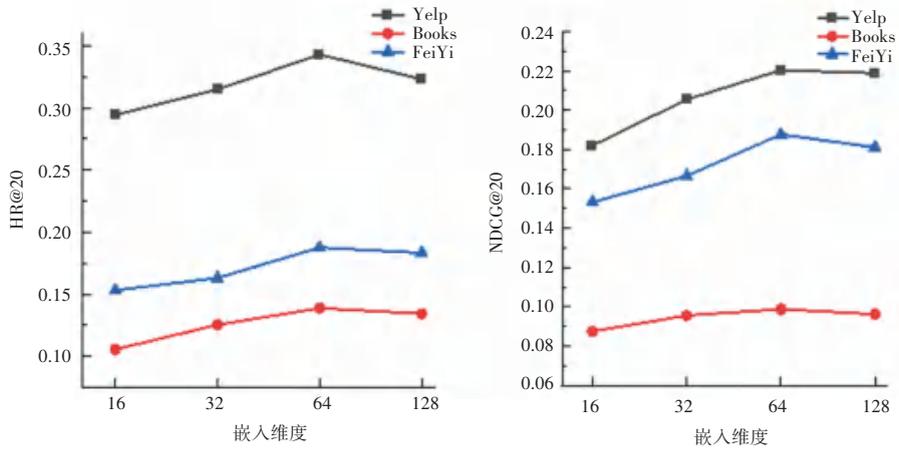


图 6 嵌入维度对模型的影响

Fig. 6 Impact of different embedding dimensions on the model

4.2.3 消融分析

为了更细致的验证本章所提出的 GNN-AR 模型的有效性,通过实验进一步验证图剪边器、残差多层图卷积、词向量注意力聚合的有效性,表 5 展示了

相应的测试结果。其中 GNN-R、GNN-D、GNN-A 分别指仅使用残差多层图卷积、图剪边器和词向量注意力聚合的 GNN-AR 变体模型。

表 5 消融实验

Table 5 Results of ablation study experiment

Dataset	YELP		Books		FeiYi	
	H@ 20	N@ 20	H@ 20	N@ 20	H@ 20	N@ 20
GNN-R	0.332 4	0.214 7	0.123 9	0.049 3	0.180 3	0.211 7
GNN-D	0.328 8	0.210 9	0.121 2	0.046 8	0.177 6	0.209 6
GNN-A	0.335 9	0.217 8	0.128 9	0.050 2	0.181 2	0.212 3
GNN-AR	0.343 1	0.220 4	0.132 5	0.052 8	0.183 9	0.214 9

不同变体对模型性能的影响如图 7 所示。加入注意力机制和词向量嵌入聚合器的 GNN-A 模型明显提升了性能,说明注意力机制能够有效地捕捉节点间的重要关系,而词向量嵌入聚合器有助于更好

地理解节点的语义信息。另外,GNN-D 和 GNN-R 也表现出了不错的性能,分别体现了剪边操作在降噪和保留关键信息方面的作用,以及残差连接在防止信息丢失和加速收敛方面的优势。

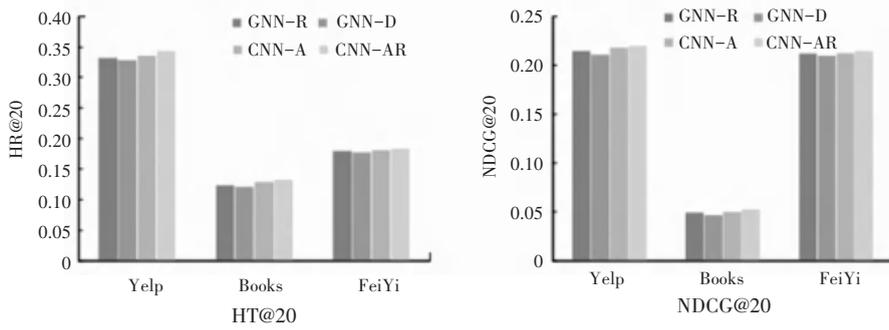


图7 不同变体实验结果对比

Fig. 7 Experimental results of different variants

5 结束语

GNN-AR 模型通过图剪边器、残差多层图卷积和词向量注意力聚合等三部分的有效结合,提升了非遗推荐系统的性能。图剪边器有效去除无关边,减少图结构中的噪声,提升了模型的效率和准确性;残差多层图卷积引入残差连接机制,缓解了深层网络中的梯度消失问题,并保证了高阶特征的充分捕捉;词向量注意力聚合将非遗文本信息与节点嵌入融合,生成更精确的节点表示,增强了用户兴趣和非遗项目特征之间的匹配。通过在三个真实数据集上进行实验测试,结果显示本文方法在提升推荐准确性方面展现了显著优势,证明了其提升在精度上的有效性。

目前,GNN-AR 模型在处理稠密图数据和和用户行为时具有显著优势。由于用户和非遗项目之间的关系可能随时间变化,未来考虑引入动态图结构建模,以便更好地捕捉这种关系的演化。

参考文献

- [1] 蒋蕙,冯顺军. 非物质文化遗产的数字化传承[J]. 文化产业, 2024,317(28):118-120.
- [2] 谷国英. 数字化技术在非物质文化遗产保护中的应用与挑战[J]. 文化月刊,2024(7):64-66.
- [3] 刘燕. 以数智技术构建非遗传播新样态[J]. 文化产业,2024,313(24):52-54.
- [4] 让冉,邢林林,张龙波,等. 面向新领域的推荐系统综述[J]. 智能计算机与应用,2023,13(5):1-8.
- [5] HU W, LI M, CHI X, et al. Intangible cultural heritage research in China from the perspective of intellectual property rights based on bibliometrics and knowledge mapping [J]. Humanities and Social Sciences Communications, 2024, 11(1): 1-11.
- [6] SHARIFANI K, AMINI M. Machine learning and deep learning: A review of methods and applications [J]. World Information Technology and Engineering Journal, 2023, 10(7): 3897-3904.
- [7] 刘铭,何利力,郑军红. 融合多源异构数据的图卷积神经网络混合推荐模型[J]. 智能计算机与应用,2024,14(2):1-8.
- [8] SCARSELLI F, GORI M, TSOI A C, et al. The graph neural network model [J]. IEEE Transactions on Neural Networks, 2008, 20(1): 61-80.
- [9] KIPF T N, WELLMING M. Semi-supervised classification with graph convolutional networks [J]. arXiv preprint arXiv, 1609.02907, 2016.
- [10] HAMILTON W, YING Z, LESKOVEC J. Inductive representation learning on large graphs [C]// Proceedings of Advances in Neural Information Processing Systems. 2017: 30.
- [11] 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. New York: ACM, 2020: 639-648.
- [12] VELICKOVIC P, CUCURULL G, CASANOVA A, et al. Graph attention networks [J]. arXiv preprint arXiv, 1710.10903, 2017.
- [13] XU K, HU W, LESKOVEC J, et al. How powerful are graph neural networks? [J]. arXiv preprint arXiv, 1810.00826, 2018.
- [14] CEN Y, ZOU X, ZHANG J, et al. Representation learning for attributed multiplex heterogeneous network [C]// Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2019: 1358-1368.
- [15] 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. New York: ACM, 2019: 165-174.
- [16] ZHANG M, CHEN Y. Link prediction based on graph neural networks [C]// Proceedings of Advances in Neural Information Processing Systems. 2018: 31.
- [17] MAHAJAN C, KRISHNAN A, NAMBIAR M, et al. Hetero-rec: Optimal deployment of embeddings for high-speed recommendations [C]// Proceedings of the Second International Conference on AI-ML Systems. 2022: 1-9.
- [18] YANG L, WANG S, TAO Y, et al. Dgrec: Graph neural network for recommendation with diversified embedding generation [C]// Proceedings of the Sixteenth ACM International Conference on Web Search and Data Mining. New York: ACM, 2023: 661-669.
- [19] ZHENG Q, ZHANG Y. TAGnn: Time adjoint graph neural network for traffic forecasting [C]// Proceedings of the International Conference on Database Systems for Advanced Applications. Cham: Springer, 2023: 369-379.
- [20] KANG W C, MCAULEY J. Self-attentive sequential recommendation [C]// Proceedings of the 2018 IEEE International Conference on Data Mining (ICDM). Piscataway, NJ: IEEE, 2018: 197-206.

-
- [21] XU H, BAO J, LIU W. Double-branch multi-attention based graph neural network for knowledge graph completion[C]// Proceedings of the 61st Annual Meeting of the Association for Computational Linguistics. 2023; 15257-15271.
- [22] HAN K, WANG Y, GUO J, et al. Vision gnn: An image is worth graph of nodes[C]// Proceedings of Advances in Neural Information Processing Systems. 2022; 8291-8303.
- [23] BERA A, WHARTON Z, LIU Y, et al. Sr-gnn: Spatial relation-aware graph neural network for fine-grained image categorization[J]. IEEE Transactions on Image Processing, 2022 (31): 6017-6031.
- [24] QIAN C, RATTAN G, GEERTS F, et al. Ordered subgraph aggregation networks[C]// Proceedings of Advances in Neural Information Processing Systems. 2022; 21030-21045.
- [25] KONG L, CHEN Y, ZHANG M. Geodesic graph neural network for efficient graph representation learning[C]// Proceedings of Advances in Neural Information Processing Systems. 2022; 5896-5909.
- [26] JIN W, WOHLWEND J, BARZILAY R, et al. Iterative refinement graph neural network for antibody sequence-structure co-design[J]. arXiv preprint arXiv,2110.04624, 2021.
- [27] FENG J, CHEN Y, LI F, et al. How powerful are k-hop message passing graph neural networks[C]// Proceedings of Advances in Neural Information Processing Systems. 2022; 4776-4790.
- [28] LIU X, DING J, JIN W, et al. Graph neural networks with adaptive residual[C]// Proceedings of Advances in Neural Information Processing Systems. 2021; 9720-9733.
- [29] ASGHAR N. Yelp dataset challenge: Review rating prediction[J]. arXiv preprint arXiv,1605.05362, 2016.
- [30] 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.
- [31] YU B, YIN H, ZHU Z. Spatio-temporal graph convolutional networks: A deep learning framework for traffic forecasting[J]. arXiv preprint arXiv,1709.04875, 2017.
- [32] BERG R, KIPF T N, WELLING M. Graph convolutional matrix completion[J]. arXiv preprint arXiv,1706.02263, 2017.
- [33] CHEN L, WU L, HONG R, et al. Revisiting graph based collaborative filtering: A linear residual graph convolutional network approach[C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2020; 27-34.
- [34] XU Z, LIU H, LI J, et al. KGAT: Collaborative knowledge-aware graph attention network for top-n recommendation[J]. Applied Sciences, 2022, 12(3): 1669.
- [35] YANG T, HU L, SHI C, et al. HGAT: Heterogeneous graph attention networks for semi-supervised short text classification[J]. ACM Transactions on Information Systems (TOIS), 2021, 39(3): 1-29.