

引用格式:丁苍峰,雷萍,韩雪琴.基于知识图谱和图神经网络的电影推荐系统[J].延安大学学报(自然科学版),2026,45(1):119-126. [DING C F, LEI P, HAN X Q. Knowledge Graph and Graph Neural Network-based movie recommendation system [J]. Journal of Yan'an University(Natural Science Edition), 2026, 45(1): 119-126.] DOI:10.13876/J.cnki.ydse.250083

基于知识图谱和图神经网络的电影推荐系统

丁苍峰,雷萍,韩雪琴

(延安大学 数学与计算机科学学院,陕西 延安 716000)

摘要:互联网影视资源的迅速增长,使用户面临信息过载与选择的困境,而传统推荐系统因数据稀疏性、冷启动及可解释性不足等问题,难以满足实际需求。尽管知识图谱与图神经网络为推荐系统优化提供了新路径,但现有研究在图谱构建质量、模型选择及协同机制方面仍存在不足,尤其缺乏对主流图神经网络模型的系统性对比分析。为此,本文构建了融合用户、电影及标签信息的知识图谱,并在3个不同规模的MovieLens数据集上,对图卷积网络、GraphSAGE、图注意力网络及异构图神经网络(Heterogeneous Graph Neural Network, HGNN)进行对比。实验结果表明, HGNN在评分预测与Top-K推荐任务中均展现出最优性能,其在ml-10m数据集上的均方误差与平均绝对误差分别低至0.8613与0.7197,同时Precision@5与NDCG@5分别为0.3351与0.4295。研究结果证实了HGNN在建模异构语义关系上的优势,为知识图谱增强推荐系统的模型选型提供了关键的实证依据。

关键词:知识图谱;图神经网络;电影推荐系统;异构图神经网络

中图分类号:TP391.1 **文献标志码:**A **文章编号:**1004-602X(2026)01-0119-08

随着互联网技术的快速发展和数字内容的爆炸式增长,电影产业迎来了前所未有的繁荣,同时引发了严重的信息过载现象,使用户难以找到真正感兴趣的影片。传统的推荐系统如协同过滤和基于内容的推荐方法,在冷启动场景下面临显著挑战^[1]。近年来,知识图谱(Knowledge Graph, KG)和图神经网络(Graph Neural Network, GNN)的迅猛发展为解决这一难题提供了新的思路^[2-5]。KG将电影领域的多源异构信息进行结构化表示,有助于缓解冷启动问题并提升推荐的可解释性^[2-3];GNN则能挖掘图的结构和连接模式,在捕获复杂关系和语义信息方面展现出明显优势^[4-5]。

现有研究表明,将KG与GNN相融合,能够显著提升推荐系统的性能。目前已发展出多种GNN架构,如图卷积网络(Graph Convolutional Network, GCN)^[6]、

GraphSAGE(Graph Sample and Aggregate)^[7]、图注意力网络(Graph Attention Network, GAT)^[8]以及异构图神经网络(Heterogeneous Graph Neural Network, HGNN)^[9]等,并将其应用于KG增强的推荐任务中。GNN不仅在知识图谱嵌入方面表现出色,还广泛应用于关系抽取、实体对齐、知识补全和问答等任务^[10-11],这些研究成果为电影推荐系统中的KG构建、嵌入学习与推理模块设计提供了坚实的理论支撑与方法借鉴。例如,刘映宏^[12]提出了一种基于多模态知识图谱的图神经网络推荐算法,通过图注意力机制捕捉节点间的高阶交互模式,在推荐效果上实现了显著提升。

尽管已有诸多探索,但在知识图谱的构建质量、图神经网络模型的适配性选择以及两者协同优化机制等方面的研究仍存在不足,尤其缺乏对不同

收稿日期:2025-08-04

基金项目:国家自然科学基金项目(62262067);陕西省大学生创新创业训练计划项目(S202410719171)

作者简介:丁苍峰(1978—),男,教授,博士,主要从事多层复杂网络和图神经网络方面的研究。E-mail:dcf@yau.edu.cn

图神经网络模型在知识图谱增强型电影推荐场景下的系统性比较。基于此,本文以电影推荐任务为研究对象,构建融合用户、电影及标签等多源异构信息的知识图谱,并在3个不同规模的MovieLens公开数据集上,对GCN、GraphSAGE、GAT及HGNN 4种典型的图神经网络模型进行系统比较。实验结果表明,HGNN凭借处理异构关系的优势,在各项任务中展现最佳的综合性能与稳健性。本研究的主要贡献在于设计了融合多源异构信息的知识图谱,为图神经网络提供高质量输入,并在统一框架下对4种主流模型进行系统性评估,揭示各模型在不同数据规模下的性能差异,为模型的选择提供了实证依据。

1 相关工作

知识图谱与图神经网络为解决推荐系统中的数据稀疏性和冷启动问题提供了新思路,并提升了推荐的准确性和可解释性。通过利用知识图谱和图神经网络,分别捕捉项目之间的语义关联及用户与项目之间的复杂交互模式,使研究者们开发了多种创新模型以增强推荐效果。

在基于知识图谱的推荐系统研究中,牛妍辉^[13]提出了融合知识图谱的偏好传播推荐模型,通过将项目知识图谱与用户-项目交互矩阵结合来推导用户偏好。刘英东^[14]设计了自适应知识图卷积网络,通过路径隐藏技术降低知识图谱复杂度,并引入注意力机制以提升推荐准确度。此外,MISHRA等^[15]提出采用纵向电子健康记录知识图谱并结合GNN进行嵌入学习的药物推荐系统。同时,NGUYEN等^[16]提出的HybridGCN(Hybrid Graph Convolutional Network)框架则将领域特定知识图谱与交互图结合,在大规模数据集上展现出良好的可扩展性。

在图神经网络推荐研究中,史艳翠等^[17]提出了基于图神经网络与对比学习的会话推荐模型,通过构建局部会话图及注意力机制来增强会话表示。王艳^[18]提出的序列图神经网络模型融合了序列网络与图神经网络,在会话推荐任务中相较于主流模型具有更高的推荐准确性。此外,NESMAOUI等^[19]基于轻量级图卷积网络通过构建电影-评分图来学习节点表示,实现了个性化推荐。LI等^[20]则提出了一种结合残差网络与注意力机制的知识图谱增强推荐系统,利用资源分配方法评估路径可靠性,显著提升了推荐效果。

随着图神经网络在关系建模上的成功应用,研究者们开始进一步探索其与知识图谱结合的潜力。刘松^[21]提出一种基于异构图神经网络的推荐算法,通过将用户与属性群体建模为图结构,有效融合了知识图谱中的语义关系。SUN等^[22]提出了一种多模态知识图谱注意力网络模型,通过在图结构中融合图像、文本等多源异构特征,提高了推荐系统的表示能力与预测准确性。BACHIRI等^[23]提出了一种多模态表征学习异构图神经网络模型,在异构图结构中联合多模态特征与关系语义,实现了知识图谱与图神经网络的深度融合,在多领域推荐任务中取得了较好的效果。

2 模型构建与实现

图1为系统整体框架图。在知识图谱构建部分,详细说明了数据预处理流程和图谱的结构化存储过程;在图神经网络建模部分,具体介绍了各网络架构的设计逻辑,包括基于知识图谱特征的节点嵌入方式和层间消息传递机制的选择,以确保模型能有效捕捉图谱中的语义关联与结构特征;在推荐生成部分,介绍了评分预测和Top-K推荐的实现方法。

2.1 知识图谱构建

为保证后续使用图神经网络模型训练时可以得到高质量的数据,本研究基于图2所示的流程,系统地完成了数据预处理与特征工程。从每个数据集的评分文件中提取用户ID、电影ID和评分3项核心数据,通过对用户-电影组合进行分组聚合,计算每个用户对每部电影的平均评分,处理后的数据集按照8:2的比例划分成训练集和测试集。

首先,在特征工程部分,对电影类型特征采用多标签编码技术进行数值化转换,准确表征每部电影的多类型归属特性;同时基于用户历史评分数据,构建包含平均评分、评分标准差和评分数量3个维度的用户特征向量,全面刻画用户的评分行为特征。为确保模型训练稳定性,对所有用户特征进行标准化处理,使其符合标准正态分布。

其次,将处理好的电影特征和用户特征以结构化的方式存入知识图谱实例中。本研究定义了数据模型,包含User、Movie、Tag 3种节点类型。User节点表示用户的信息,包含用户ID、平均评分、评分数量、最喜爱电影类型等;Movie节点表示电影信息,包含电影ID、电影标题、上映年份等信息;Tag节点表示用户对电影的标签标注信息,每条标签记录

包含用户 ID、电影 ID、标签内容等,反映了用户对电影的主观认知和语义描述。关系类型为用户与电影的评分关系,表示用户对电影的评分,电影与标

签的属于关系,表示电影被标注了某个标签,以及用户与标签的使用关系,表示用户使用过某个标签,反映用户的兴趣偏好。

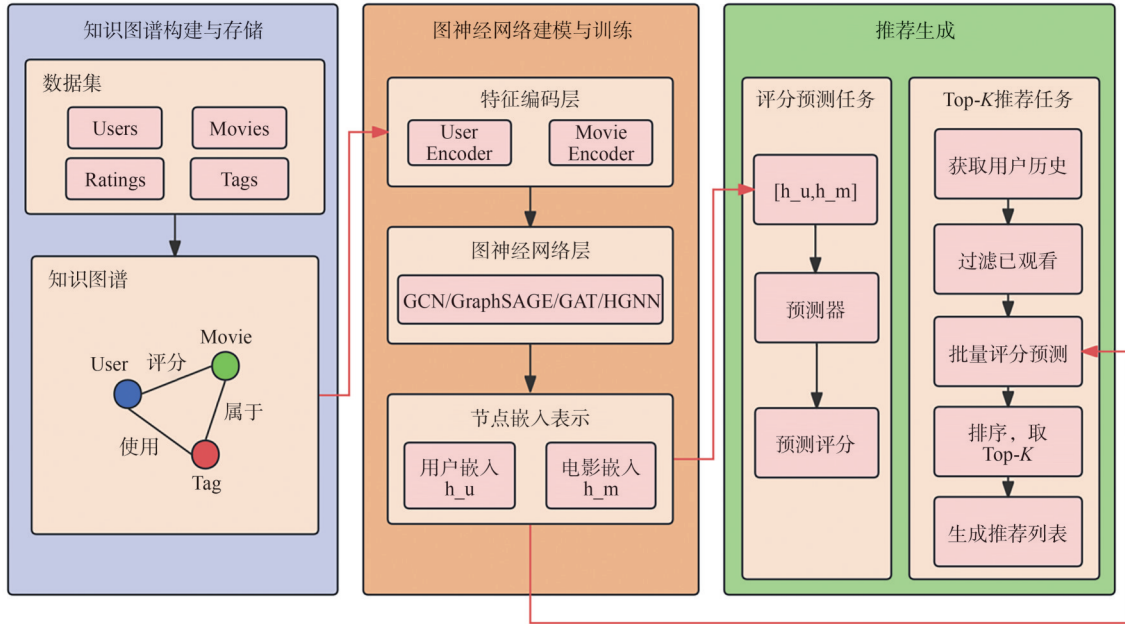


图 1 系统整体框架图

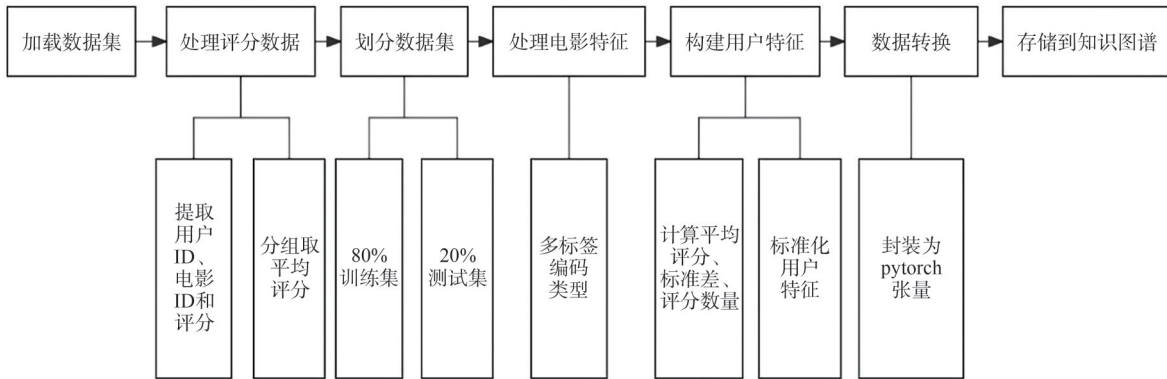


图 2 数据处理流程图

最后,将处理好的节点与关系数据存入内存中的图结构,形成一个富含语义信息的异构信息网络,为图神经网络提供高质量的输入,便于后续模型进行前向传播和训练。

2.2 图神经网络模型架构

在构建好的知识图谱基础上,本研究提出一种集特征提取、信息传播和评分预测为一体的图神经网络模型架构。

在模型初始化阶段,构建双通道特征编码网络,通过两层全连接层(使用 ReLU 激活)分别处理用户和电影特征。具体而言,用户特征和电影特征首先被输入到各自的编码器中,经过两层全连接层的非线性变换后,生成用户嵌入和电影嵌入,这一

过程形式化如下:

$$h_u^{(0)} = MLP_{user}(x_u), \tag{1}$$

$$h_m^{(0)} = MLP_{movie}(x_m), \tag{2}$$

其中, x_u 和 x_m 分别为原始用户和电影特征向量, $h_u^{(0)}$ 和 $h_m^{(0)}$ 为对应的初始节点嵌入,这确保原始特征能被有效地转化成高维空间中的表示。

在消息传递层引入图神经网络机制,实现节点间邻域信息的动态聚合。利用 GCN、GraphSAGE、GAT 及 HGNN 对更新后的电影嵌入进行进一步处理之后,可以准确刻画出节点之间的复杂交互关系,并且高效地把局部特征整合到目标节点表示中,从而增强特征的表达能力。具体的技术实现如下。

1)图卷积网络:GCN 对邻接矩阵进行对称归一

化处理,使特征传播时保持数值稳定性,接着通过可学习的权重矩阵对节点特征进行线性变换,并行邻域加权求和操作,聚合邻居节点的特征信息,其层间传递方式如下式(3)所示:

$$\mathbf{H}^{(l+1)} = \sigma \left(\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}} \mathbf{H}^{(l)} \mathbf{W}^{(l)} \right), \quad (3)$$

其中, $\tilde{\mathbf{A}} = \mathbf{A} + \mathbf{I}$, \mathbf{I} 为单位矩阵, $\tilde{\mathbf{A}}$ 表示自连的邻接矩阵, $\tilde{\mathbf{D}}$ 是 $\tilde{\mathbf{A}}$ 的度矩阵, $\mathbf{H}^{(l)}$ 指第一层的输入特征 X , $\mathbf{H}^{(l+1)}$ 为输出特征, $\mathbf{W}^{(l)}$ 为权重矩阵, $\sigma(\cdot)$ 为非线性激活函数, $\tilde{\mathbf{D}}^{-\frac{1}{2}} \tilde{\mathbf{A}} \tilde{\mathbf{D}}^{-\frac{1}{2}}$ 表示对矩阵 \mathbf{A} 做标准化处理。

2) GraphSAGE: GraphSAGE 从每个节点的邻域随机采样固定数量的邻居节点,本实验用均值聚合策略对邻居节点的特征进行平均化处理,生成局部邻域的概括性表示,聚合后的特征通过非线性变换激活更新当前节点的嵌入表示,其中使用的公式如下:

$$\mathbf{h}_{\mathcal{N}(v)} = \text{MEAN} \{ \mathbf{h}_u, u \in \mathcal{N}_k(v) \}, \quad (4)$$

$$\mathbf{h}_v^{(l+1)} = \sigma \left(\mathbf{W} \cdot \text{CONCAT} \left(\mathbf{h}_v^{(l)}, \mathbf{h}_{\mathcal{N}(v)} \right) \right), \quad (5)$$

其中, $\mathbf{h}_{\mathcal{N}(v)}$ 是节点的邻居特征均值, $\mathcal{N}_k(v)$ 是节点 v 的 k 个邻居集合, $\mathbf{h}_v^{(l)}$ 是节点 v 在第 l 层的特征,通过聚合邻居信息及非线性变换更新节点特征。

3) 图注意力网络: GAT 引入自注意力机制,允许节点为不同的邻居分配不同的权重,能更精细地捕捉图中节点间的重要性差异。其中注意力系数计算如下:

$$e_{ij} = \text{LeakyReLU} \left(\mathbf{a}^T \left[\mathbf{W} \mathbf{h}_i \parallel \mathbf{W} \mathbf{h}_j \right] \right), \quad (6)$$

$$\alpha_{ij} = \text{softmax}_j(e_{ij}) = \frac{\exp(e_{ij})}{\sum_{k \in \mathcal{N}_i} \exp(e_{ik})}, \quad (7)$$

其中, \mathbf{a} 是可学习的向量, \mathbf{h}_i 和 \mathbf{h}_j 分别是节点 i 和节点 j 的特征向量,用于衡量节点之间的相关性。本实验采用 4 个并行的注意力头以稳定学习过程并捕获不同的语义子空间。

4) 异构图神经网络: 通过元路径与语义注意力机制建模异构关系,本研究定义了 3 条核心元路径: 用户-评分-电影,用来捕获直接交互; 电影-属于-标签,用来捕获高阶语义关联; 用户-使用-标签,用来捕获用户的兴趣偏好特征。对于每条元路径, HGNN 使用独立的图注意力网络生成节点嵌入,学习邻居权重,模型通过一个可学习的语义注意力向量,自适应地融合不同元路径下的节点表示,形成最终的节点嵌入,从而更精准地捕捉图中的复杂语义信息。

所有模型均堆叠两层图卷积层,隐藏层维度统一设置为 64。经过两层图卷积后,可以得到最终的用户嵌入 $\mathbf{h}_u^{(2)}$ 和电影嵌入 $\mathbf{h}_m^{(2)}$ 。将它们拼接后输入到一个多层感知机中,通过 Sigmoid 函数将输出映射到 $[0, 1]$ 区间内,再经过线性缩放得到评分预测结果,完成从特征提取到最后预测结果的端到端的训练过程。

2.3 推荐生成

推荐流程如图 3 所示,具体分为以下两部分。

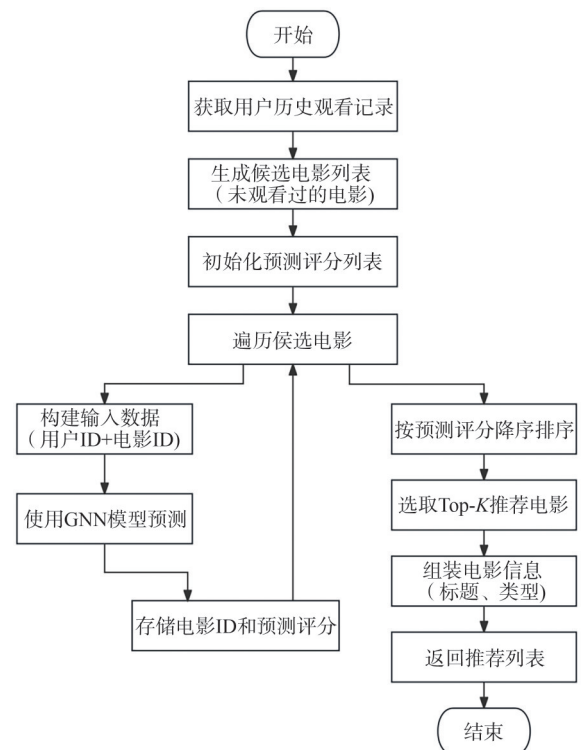


图 3 推荐流程图

1) 对于评分预测,系统直接使用训练好的模型对给定的用户-电影对进行预测。

2) 针对 Top-K 推荐,系统会从用户的观看历史来获取数据,这些数据包含用户以前观看过的电影及对这些电影的评分,系统会过滤掉用户已经评分过的电影,进而得到一个未被观看过的候选推荐电影列表。对于每个候选电影,系统利用预训练的图神经网络模型进行评分预测,该模型通过整合知识图谱中的多源异构信息,如用户、电影与标签等实体及其复杂关系,来学习用户和电影的深层表征,从而捕捉用户的兴趣偏好。在模型推理阶段,为了提升效率,系统禁用梯度计算,将所有候选电影的预测评分收集并按降序排序,最后选取前 Top-K 个高分电影作为推荐结果。

3 实验结果与分析

3.1 数据集

为测试本文提出的图神经网络模型的效果,本研究选择公开的 MovieLens 电影评分数据集来完成,该数据集被广泛用于推荐系统方面的研究,包含用户对于电影的评分数据。在此为验证实验结果的可靠性,选择3个不同规模的 MovieLens 数据集来进行实验,即 ml-latest-small、ml-100 k 及 ml-10 m,这3个数据集中涵盖不同的用户数、电影数以及评分数量,经过数据处理后的数据集信息如下表1所示。

表1 数据集信息

数据集	用户数	电影数	评分数
ml-latest-small	610	9 742	100 836
ml-100 k	943	1 682	100 000
ml-10 m	71 000	10 681	10 000 000

所有数据集均遵循2.1节所述的流程进行预处理,包括用户-电影交互记录的分组聚合与8:2的训练集与测试集划分。

3.2 实验设置

本实验在 PyTorch 框架下实现,所有模型采用相同的训练策略。训练周期上限为500轮,早停耐心值设为15轮以防止过拟合,批处理大小统一为256,每个实验使用5个不同随机种子独立运行。超参数通过预实验确定:隐藏层维度在{32, 64, 128}中选择64,过大的维度在小数据集上易过拟合;图卷积层数设为2层,过深的网络会导致过平滑问题;学习率在{0.01, 0.001, 0.000 5}中选择0.001, HGNN 因参数量较大,采用更小的0.000 5为学习率以保证训练稳定。推荐评估中,正样本阈值设为3.5,该阈值依据 MovieLens 数据集中评分分布及常见研究设定,即评分不低于3.5的交互记录视为用户感兴趣的物品。

3.3 评价指标

为全面评估模型性能,本实验从评分预测和 Top-K 推荐两个维度进行评估。

1) 评分预测

评分预测时采用均方误差(Mean Squared Error, MSE)和平均绝对误差(Mean Absolute Error, MAE)作为评价指标。计算公式如下:

$$\delta_{\text{MSE}} = \frac{1}{n} \sum_{i=1}^n (y_i - \hat{y}_i)^2, \quad (8)$$

$$\delta_{\text{MAE}} = \frac{1}{n} \sum_{i=1}^n |y_i - \hat{y}_i|, \quad (9)$$

其中, y_i 是第 i 个样本的真实值,表示用户对电影的实际评分, \hat{y}_i 是对应的预测值,表示模型预测的用户对电影的评分, n 是样本数量, δ_{MSE} 和 δ_{MAE} 这两个指标值越小,模型性能越好。

2) Top-K 推荐

Top-K 推荐是指从海量的电影中,为用户推荐最可能喜欢的前 K 部电影,其中, K 表示一个正整数(如 $K=5, 10, 15$ 等)。例如, Top-5 推荐:为用户推荐最可能喜欢的前5部电影。Top-K 推荐任务中采用精确度 Precision@K 和归一化折损累计增益 NDCG@K (Normalized Discounted Cumulative Gain at K) 作为评价指标。

Precision@K 主要用来表示在前 K 个推荐结果中,与测试集中用户有过交互的电影所占的比例,计算公式如下:

$$\delta_{\text{precision}}@K = \frac{TP@K}{TP@K + FP@K}, \quad (10)$$

其中, $TP@K$ 表示出现在用户测试集交互记录中的电影数量, $FP@K$ 表示未出现在用户测试集交互记录中的电影数量。该指标值越大,推荐效果越好。

NDCG@K 是一个综合考虑用户兴趣和排名位置的指标,其计算公式为

$$\delta_{\text{NDCG}}@K = \frac{\delta_{\text{DCG}}@K}{\delta_{\text{IDCG}}@K}, \quad (11)$$

其中, $\delta_{\text{DCG}}@K$ (Discounted Cumulative Gain at K) 用来衡量前 K 个推荐项的质量,排名越靠前的用户感兴趣项,对得分的贡献越大; $\delta_{\text{IDCG}}@K$ (Ideal DCG at K) 是理论上能达到的最大 $\delta_{\text{DCG}}@K$ 值,来源于按用户真实感兴趣项降序排列的理想列表。同样,该指标值越大,表示推荐列表的质量越高。

3.4 结果与分析

3.4.1 评分预测任务

如表2所示为4种图神经网络模型在评分预测任务中的评估指标,以“均值±标准差”的形式表示。从预测精度上看,所有模型在数据量最大的 ml-10 m 数据集上的整体表现最佳,其中, HGNN 的 MSE 为 0.861 3、MAE 为 0.719 7 表现最好,而在 ml-100 k 数据集上表现最差,各模型 MSE 约在 1.071 6~1.072 1 之间,这一趋势体现了数据规模对性能的关键影响,即数据规模越大,模型对用户行为模式的挖掘也就越充分,预测准确率越高。

从稳定性看,所有模型在 ml-10 m 上标准差最小, HGNN 的 MSE 标准差仅为 0.001 2, HGNN 在保

持最低误差的同时标准差也最小,说明异构图结构不仅可以提高准确性,还可以增强稳定性,ml-100 k

上各模型性能差异极小,说明数据规模不足时模型选择影响有限。

表2 评分预测评估指标

模型	ml-latest-small		ml-100 k		ml-10 m	
	δ_{MSE}	δ_{MAE}	δ_{MSE}	δ_{MAE}	δ_{MSE}	δ_{MAE}
GCN	0.932 8±0.009 8	0.732 0±0.006 5	1.072 1±0.004 5	0.826 7±0.003 2	0.868 9±0.001 8	0.724 9±0.001 2
GraphSAGE	0.927 8±0.006 7	0.731 7±0.005 0	1.071 8±0.004 0	0.826 5±0.002 8	0.868 9±0.001 6	0.725 3±0.001 1
GAT	0.933 2±0.004 8	0.730 4±0.003 1	1.071 7±0.003 6	0.826 4±0.002 5	0.865 2±0.001 4	0.723 1±0.000 9
HGNN	0.923 0±0.003 8	0.729 8±0.002 9	1.071 6±0.003 2	0.826 2±0.002 2	0.861 3±0.001 2	0.719 7±0.000 8

注:最优性能采用加粗标注。

3.4.2 推荐任务

表3展示了4种图神经网络模型在推荐任务中的Precision@5和NDCG@5值。可以看到,数据规模仍是关键影响因素,所有模型在最大的ml-10 m数据集上取得了最佳的Precision@5和NDCG@5,以HGNN的0.335 1和0.429 5为最优,而在较小规模的

ml-100 k数据集上表现最差。ml-latest-small数据集的评分与ml-100 k相近,但其推荐性能却更优,这一现象表明,在推荐任务中数据所覆盖的用户与物品的多样性(用户数和电影数)对于模型学习泛化性强的用户兴趣模式非常重要,其影响力可能超过了单纯的评分数量。

表3 推荐阶段评估指标

模型	ml-latest-small		ml-100 k		ml-10 m	
	$\delta_{precision@5}$	$\delta_{NDCG@5}$	$\delta_{precision@5}$	$\delta_{NDCG@5}$	$\delta_{precision@5}$	$\delta_{NDCG@5}$
GCN	0.312 6±0.001 5	0.401 2±0.002 0	0.285 4±0.000 8	0.372 8±0.001 0	0.334 5±0.000 2	0.428 9±0.000 3
GraphSAGE	0.315 8±0.001 4	0.405 7±0.001 8	0.286 1±0.001 1	0.373 5±0.001 5	0.334 2±0.000 3	0.428 3±0.000 4
GAT	0.317 2±0.001 1	0.407 5±0.001 5	0.285 9±0.000 9	0.373 1±0.000 9	0.333 8±0.000 4	0.427 6±0.000 5
HGNN	0.319 2±0.000 9	0.409 6±0.001 2	0.287 3±0.000 7	0.375 0±0.000 8	0.335 1±0.000 1	0.429 5±0.000 2

注:最优性能采用加粗标注。

从模型性能的横向对比来看,HGNN在3个数据集的所有指标上均保持领先,尤其是在ml-latest-small数据集上,其Precision@5为0.319 2,NDCG@5为0.409 6,优于其他模型,这说明异构图神经网络通过融合多种类型的节点与关系,能够更精准地捕捉用户兴趣,从而生成更高质量的推荐列表,而GAT在ml-latest-small上表现次优,再次证明了注

意力机制在权衡邻域信息方面的有效性。

图4和图5分别展示了Precision@5和NDCG@5的对比,HGNN在所有设置中均表现最优,GAT在ml-latest-small上表现次优,但在ml-10 m上略有下降,推测是注意力机制面临过拟合与计算开销的挑战。综上所述,HGNN的异构关系建模在有效融合复杂图结构信息方面具有优势。




图4 Precision@5对比图

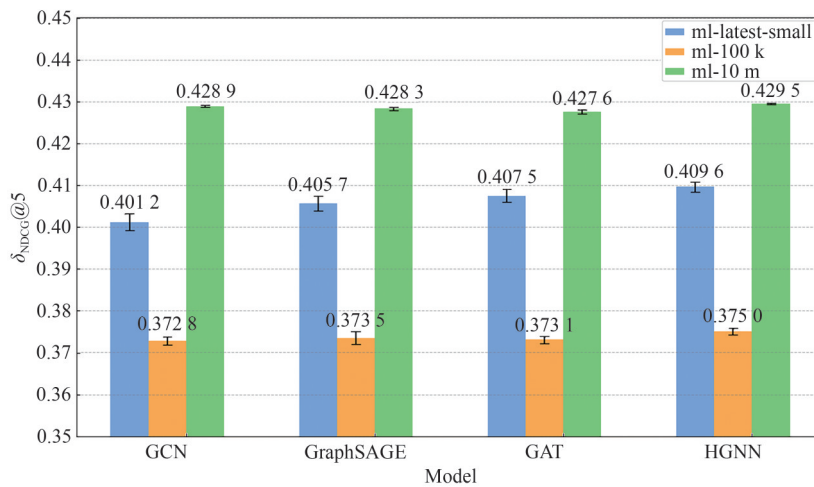


图5 NDCG@5对比图

3.4.3 HGNN 优势机制分析

HGNN在各项任务中均取得最优结果,这主要得益于其异构图建模机制。GCN、GraphSAGE和GAT在处理知识图谱时将所有节点和边视为同构结构,无法区分不同类型关系的语义差异。而HGNN通过HeteroConv为用户-电影、电影-标签、用户-标签3种边类型分别设置独立的消息传递函数,使模型能够针对不同关系学习特定的聚合权重。此外,HGNN能同时建模用户与电影的直接交互路径及经由标签节点的高阶语义路径,从而捕获更丰富的用户偏好信息。本研究构建的知识图谱包含3种节点类型和3种关系类型,这种异构结构正好发挥了HGNN的建模优势,而同构GNN模型在处理时会损失部分结构信息,这解释了HGNN在实验中表现更优的原因。

4 结论与展望

本研究构建融合用户、电影及标签信息的知识图谱,在多个MovieLens数据集上对GCN、GraphSAGE、GAT及HGNN进行对比实验,结果表明HGNN在评分预测与Top-K推荐任务中综合表现最优,尤其是在大规模数据集上预测误差更低、推荐精度更高,且跨数据规模稳定性良好,这验证了异构图神经网络在知识图谱增强推荐任务中的有效性,为后续模型选型提供实证参考。

本研究不仅验证了图神经网络在推荐系统中的优势,也为个性化推荐服务提供了可扩展的解决方案,未来可通过深化图结构学习机制,并融合时序特征,多模态数据等动态辅助信息来进一步提升系统的适配程度和可解释性。

参考文献:

- [1]毛骞,谢维成,乔逸天,等.推荐系统冷启动问题解决方法研究综述[J].计算机科学与探索,2024,18(5):1197-1210.
- [2]刘世侠,李卫军,刘雪洋,等.基于强化学习的知识图谱推理研究综述[J].计算机应用研究,2024,41(9):2561-2572.
- [3]WANG Z, WANG Z L, LI X, et al. Exploring multi-dimension User-item interactions with attentional knowledge graph neural networks for recommendation [J]. IEEE Transactions on Big Data, 2022, 9(1):212-226.
- [4]BHATTI U A, TANG H, WU G, et al. Deep learning with Graph Convolutional Networks: An overview and latest applications in computational intelligence [J]. International Journal of Intelligent Systems, 2023, 2023:8342104.
- [5]侯映鑫.基于图神经网络的电影推荐系统设计与实现[D].兰州:西北民族大学,2022.
- [6]KIPF T N, WELING M. Semi-Supervised classification with graph convolutional networks [C]//Proceedings of the International Conference on Learning Representations (ICLR). Toulon:ICLR, 2017:1-9.
- [7]HAMILTON W L, YING R, LESKOVEC J. Inductive representation learning on large graphs [C]//Proceedings of the 31st International Conference on Neural Information Processing Systems (NIPS 2017). Long Beach: Curran Associates Incorporated, 2017:1025-1035.
- [8]VELIČKOVIĆ P, CUCURULL G, CASANOVA A, et al. Graph attention networks [R]. Ithaca: Cornell University Library, 2017.
- [9]ZHANG J, SHI X, XIE J, et al. Heterogeneous graph neural network [C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. Anchorage: ACM, 2019:793-803.
- [10]BASTOS A, NADGERI A, SINGH K, et al. RECON: Rela-

- tion extraction using knowledge graph context in a graph neural network [C]//Proceedings of the Web Conference. Ljubljana: ACM, 2021: 1673–1685.
- [11] YE R, LI X, FANG Y, et al. A vectorized relational graph convolutional network for multi-relational network alignment [C]//2019 IEEE International Conference on Data Mining (ICDM). Beijing: IEEE, 2019: 4135–4141.
- [12] 刘映宏. 基于知识图谱与图神经网络的电影推荐系统设计[实现][D]. 成都: 电子科技大学, 2025.
- [13] 牛妍辉. 基于知识图谱的个性化电影推荐系统的研究与实现[D]. 石河子: 石河子大学, 2023.
- [14] 刘英东. 基于知识图谱的电影推荐系统研究[D]. 太原: 山西大学, 2023.
- [15] MISHRA R, SHRIDEVI S. Knowledge graph driven medicine recommendation system using graph neural networks on longitudinal medical records[J]. Scientific Reports, 2024, 14(1): 25449.
- [16] NGUYEN D A, KHA S, LE T V. HybridGCN: An integrative model for scalable recommender systems with knowledge graph and graph neural networks[J]. International Journal of Advanced Computer Science and Applications, 2024, 15(5): 1327–1337.
- [17] 史艳翠, 郑洁. 基于图神经网络和对比学习的会话推荐[J]. 计算机技术与发展, 2025, 35(8): 128–135.
- [18] 王艳. 基于图神经网络的会话型推荐系统方法研究与应用[D]. 沈阳: 沈阳工业大学, 2024.
- [19] NESMAOUI R, LOUHICHI M, LAZAAR M. A collaborative filtering movies recommendation system based on graph neural network[J]. Procedia Computer Science, 2023, 220: 456–461.
- [20] LI W, ZHONG H, ZHOU J, et al. An attention mechanism and residual network based knowledge graph-enhanced recommender system[J]. Knowledge-Based Systems, 2024, 299: 112042.
- [21] 刘松. 基于异质图神经网络的电影推荐系统研究[D]. 重庆: 重庆邮电大学, 2022.
- [22] SUN R, ZHANG W, MA Y, et al. MKGAT: Multi-modal knowledge graph attention network for recommendation [C]//Proceedings of the 29th ACM International Conference on Information and Knowledge Management (CIKM 2020). New York: ACM, 2020: 1483–1492.
- [23] BACHIRI K, AL SAREM M, ALJOHANI N R. MM-HGNN: Multimodal representation learning heterogeneous graph neural network [J]. Cognitive Computation, 2025, 17(2): 1–15.

[责任编辑 毕 伟]

Knowledge Graph and Graph Neural Network-based movie recommendation system

DING Cangfeng, LEI Ping, HAN Xueqin

(College of Mathematics and Computer Science, Yan'an University, Yan'an 716000, China)

Abstract: The explosive growth of Internet film and television resources has caused users to fall into information overload and selection dilemma. However, the traditional recommendation system is difficult to meet the actual needs due to data sparsity, cold start and insufficient interpretability. Although knowledge graph and graph neural network technology provide a new path for recommendation system optimization, the existing research still has deficiencies in the quality of graph construction, model selection and coordination mechanism, especially the lack of systematic comparative analysis of mainstream graph neural network models. To this end, this paper constructs a knowledge graph that integrates user, movie and type information, and compares graph convolutional network, GraphSAGE, graph attention network and Heterogeneous Graph Neural Network (HGNN) on three MovieLens datasets of different sizes. The experimental results show that HGNN exhibits optimal performance in both rating prediction and Top- K recommendation tasks. Its mean square error and mean absolute error on the ml-10 m dataset are as low as 0.861 3 and 0.719 7, respectively. Precision@5 and NDCG@5 are 0.335 1 and 0.429 5, respectively. The research results confirm the advantages of HGNN in modeling heterogeneous semantic relations, and provide a key empirical basis for the model selection of knowledge graph enhancement recommendation system.

Key words: Knowledge Graph; Graph Neural Network; movie recommendation system; Heterogeneous Graph Neural Network