



融合社交关系的轻量级图卷积协同过滤推荐方法

朱金侠, 孟祥福, 邢长征, 孙德伟, 薛琪, 关钧渤

引用本文:

朱金侠, 孟祥福, 邢长征, 孙德伟, 薛琪, 关钧渤. 融合社交关系的轻量级图卷积协同过滤推荐方法[J]. 智能系统学报, 2022, 17(4): 788–797.

ZHU Jinxia, MENG Xiangfu, XING Changzheng, SUN Dewei, XUE Qi, GUAN Junbo. Light graph convolutional collaborative filtering recommendation approach incorporating social relationships[J]. *CAAI Transactions on Intelligent Systems*, 2022, 17(4): 788–797.

在线阅读 View online: <https://dx.doi.org/10.11992/tis.202107031>

您可能感兴趣的其他文章

融合知识图谱和轻量级图卷积网络推荐系统的研究

Research on the fusion of knowledge graph and lightweight graph convolutional network recommendation system
智能系统学报. 2022, 17(4): 721–727 <https://dx.doi.org/10.11992/tis.202107016>

基于图卷积集成的网络表示学习

Network representation learning using graph convolution ensemble
智能系统学报. 2022, 17(3): 547–555 <https://dx.doi.org/10.11992/tis.202107048>

用户兴趣点耦合关系的兴趣点推荐方法

A POI recommendation approach based on user–POI coupling relationships
智能系统学报. 2021, 16(2): 228–236 <https://dx.doi.org/10.11992/tis.201907034>

面向推荐系统的分期序列自注意力网络

Recommendation system with long-term and short-term sequential self-attention network
智能系统学报. 2021, 16(2): 353–361 <https://dx.doi.org/10.11992/tis.202005028>

融合协同过滤与用户偏好的旅游组推荐方法

A tourist group recommendation method combining collaborative filtering and user preferences
智能系统学报. 2018, 13(6): 999–1005 <https://dx.doi.org/10.11992/tis.201802011>



微信公众平台



期刊网址

DOI: 10.11992/tis.202107031

网络出版地址: <https://kns.cnki.net/kcms/detail/23.1538.TP.20220420.1339.002.html>

融合社交关系的轻量级图卷积协同过滤推荐方法

朱金侠, 孟祥福, 邢长征, 孙德伟, 薛琪, 关钧渤
(辽宁工程技术大学 电子与信息工程学院, 辽宁 葫芦岛 125105)

摘要: 图卷积网络 (graph convolution network, GCN) 因其强大的建模能力得到了迅速发展, 目前大部分研究工作直接继承了 GCN 的复杂设计 (如特征变换, 非线性激活等), 缺乏简化工作。另外, 数据稀疏性和隐式负反馈没有被充分利用, 也是当前推荐算法的局限。为了应对以上问题, 提出了一种融合社交关系的轻量级图卷积协同过滤推荐模型。模型摒弃了 GCN 中特征变换和非线性激活的设计; 利用社交关系从隐式负反馈中产生一系列的中间反馈, 提高了隐式负反馈的利用率; 最后, 通过双层注意力机制分别突出了邻居节点的贡献值和每一层图卷积层学习向量的重要性。在 2 个公开的数据集上进行实验, 结果表明所提模型的推荐效果优于当前的图卷积协同过滤算法。

关键词: 协同过滤; 图卷积网络; 注意力机制; 社交关系; 推荐系统; 隐式负反馈; 图嵌入; 用户偏好

中图分类号: TP311 **文献标志码:** A **文章编号:** 1673-4785(2022)04-0788-10

中文引用格式: 朱金侠, 孟祥福, 邢长征, 等. 融合社交关系的轻量级图卷积协同过滤推荐方法 [J]. 智能系统学报, 2022, 17(4): 788-797.

英文引用格式: ZHU Jinxia, MENG Xiangfu, XING Changzheng, et al. Light graph convolutional collaborative filtering recommendation approach incorporating social relationships[J]. CAAI transactions on intelligent systems, 2022, 17(4): 788-797.

Light graph convolutional collaborative filtering recommendation approach incorporating social relationships

ZHU Jinxia, MENG Xiangfu, XING Changzheng, SUN Dewei, XUE Qi, GUAN Junbo

(School of Electronics and Information Engineering, Liaoning Technical University, Huludao 125105, China)

Abstract: Graph convolutional network (GCN) has rapidly developed due to their powerful modeling capability. However, much of the research up to now has directly inherited the complex design of GCN (e.g., feature transformation and nonlinear activation), which lacks thorough ablation analysis on GCN. Additionally, implicit feedback is not fully utilized, and data sparsity is not well resolved, which are also shortcomings of current recommendation algorithms. This paper proposes a light graph convolutional collaborative filtering recommendation approach that incorporates social relationships to address such problems (F-LightGCCF). In GCN, the model abandons the design of feature transformation and nonlinear activation. Then it can generate a series of intermediate feedback from users' implicit negative feedback by taking advantage of social networking, improving the utilization of implicit negative feedback. Lastly, the importance of the contribution values of neighboring nodes and the learning vectors of each layer of the graph convolution layer are aggregated separately using the dual attention mechanism. By conducting experiments on two publicly available datasets, the results show that the proposed model outperforms current graph convolutional collaborative filtering algorithms in the recommendation.

Keywords: collaborative filtering; graph convolution network; attention mechanism; social relationships; recommendation system; implicit negative feedback; graph embedding; user preference

移动网络的普遍应用, 为人们带来选择麻痹

的困扰, 推荐系统是解决信息过载问题的关键技术。推荐的重点在于推测用户偏好和拓展用户视野。推荐的核心在于预测用户是否会与某个项目进行交互, 例如点击、评级、购买以及其他形式的交互。现有的推荐方法^[1-2]大多单一利用可以直

收稿日期: 2021-07-17. 网络出版日期: 2022-04-21.

基金项目: 国家重点研发计划项目 (2018YFB1402901); 国家自然科学基金项目 (61772249); 辽宁省教育厅一般项目 (LJ2019QL017).

通信作者: 孟祥福. E-mail: marxi@126.com.

接反映用户偏好的显式反馈信息(如用户评分或评价)进行推荐。显式反馈的推荐模型,一般无法考虑用户对打分机制的宽容度差异,在一定程度上会造成数据误差,从而影响推荐结果。隐式反馈^[3](如用户点击或浏览)也是影响推荐结果的重要因素。研究者在利用隐式反馈时,经常忽略那些用户不点击或不浏览的项目,这类数据被称为隐式负反馈数据。通常,这类数据信息更稠密,可以间接挖掘用户的隐藏偏好,缺点是不易获取,也更容易包含噪声数据。本文利用用户社交图的拓扑结构,通过分析用户行为和朋友亲密度间接捕获这类隐式负反馈,称为中间反馈。中间反馈相比于显/隐式反馈被视为弱偏好,而相比于隐式负反馈被视为强偏好。并且,本文利用注意力机制^[4]对输入数据的噪声进行过滤,减少噪声数据对结果的消极影响,有助于选择最相关的信息,而不是所有可用的信息。

此外,数据稀疏性也影响着协同过滤推荐技术的准确性。最近,将信息网络嵌入到低维向量空间的图嵌入方法已被广泛应用于推荐领域^[5-7],这类低维表示比用户-项目交互矩阵更加稠密,有效缓解了数据稀疏性的消极影响。因此,本文模型的嵌入层利用图嵌入技术将用户、项目和朋友信息映射到低维稠密的向量的空间。图卷积网络因其强大的建模能力得到了快速发展,NGCF^[8]、LightGCN^[9]等均为典型的图卷积协同过滤技术。图卷积网络^[10](graph convolution network, GCN)最初是为图分类任务设计的,“图像”每个节点都包含丰富的语义信息作为输入。然而,在协同过滤中,每个用户/项目只有一个ID作为输入,没有具体的语义。在这种情况下,进行特征变换和非线性激活可能对推荐效果的提升没有任何好处。换句话说,模型包含太多无用的操作,可能会增加模型的训练难度,降低模型性能。基于此猜想,提出的模型摒弃了图卷积网络中特征变换和非线性激活的设计。

1 研究背景

1.1 用户社交图

本文利用用户-朋友社交图和用户-项目-朋友高阶连接图从隐式负反馈中产生一系列的中间反馈。从图1(a)可知目标用户 u_1 有4个朋友,分别为朋友 f_1 、 f_2 、 f_3 、 f_4 。从图1(b)可知路径长度 $L>1$ 表示目标用户 u_1 的高阶连接性,此类高阶连接性承载着 u_1 的显/隐式反馈以及中间反馈的偏好信息。路径 $L=1$ 表示目标用户 u_1 直接交互的

项目,路径 $L=2$ 表示目标用户与其朋友的行为相似度(即亲密度)。例如, f_2 、 f_3 与 u_1 直接交互的项目有两次交互,而 f_1 、 f_4 与 u_1 直接交互的项目仅一次交互,由此可以推断 f_2 、 f_3 与目标用户 u_1 的行为相似度更高,对 u_1 决策的影响更大。路径 $L=3$ 预测更能引起目标用户 u_1 感兴趣的项目。由路径 $L=2$ 可知, f_2 、 f_3 与目标用户 u_1 有着更高的行为相似度,因此推断 f_2 、 f_3 共同交互的 i_5 比 i_4 、 i_6 更能引起 u_1 的兴趣。

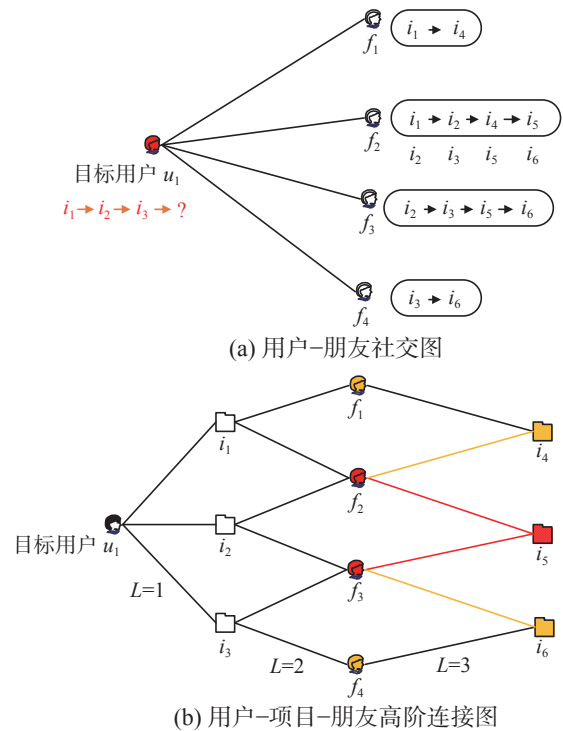


图1 用户社交图

Fig. 1 User social graph

1.2 相关工作

随着深度学习的发展,研究者将其与推荐算法^[11-13]结合,有效提高了推荐结果的准确性。图卷积网络使用卷积算子学习图结构的方法逐渐成为推荐新技术,通过平滑图上的特征来学习节点的表示。文献[14]提出了一种基于二分图的信息传递自动编码框架GC-MC,通过在用户-项目交互图上进行信息传递并产生用户/项目节点的潜在特征,但模型仅考虑了用户的一阶邻居,降低了训练数据的丰富性。文献[15]提出了一种联合矩阵分解和图卷积神经网络的推荐模型Hop-Rec,利用矩阵分解将用户-项目的交互信息因子化以获取用户偏好,显式的建模用户和项目之间的高阶偏好。此类高阶偏好尚未编码到消息传递机制中,仅仅丰富了训练数据。

注意力机制可以为不同的用户和项目分配权重,动态捕获更具代表性的用户/项目影响。文献

[16] 提出了一种引入双层注意力机制的 DAML 模型, 联合卷积神经网络的局部注意力和相互注意力学习用户和评论之间所存在的潜在特征的相关性。模型仅利用了用户的显式反馈, 忽略了隐式反馈的重要影响。文献 [17] 提出了一种联合反向传播与注意力机制的推荐模型, 利用反向传播学习目标用户与邻居节点之间的信息传播, 设计注意力机制捕获每个用户对所有最近邻居节点的总体影响。但模型尚未有效解决数据稀疏性对推荐结果产生的消极影响。

需指出的是, 以往的推荐技术在不同程度上提高了推荐结果的有效性, 但是在缓解数据稀疏性以及隐式负反馈的低利用率等方面尚有不足。本文提出的模型通过图嵌入技术将用户、项目以及朋友信息嵌入到低维向量空间中, 利用高阶图卷积层学习用户、项目、朋友之间的高阶连接信息, 从隐式负反馈中产生一系列的中间反馈, 以统一的方式缓解了数据稀疏性和隐式负反馈利用率低下的局限。

2 问题定义与解决方案

2.1 问题定义

定义 1(用户与项目集合) 用户集 $U = \{u_1, u_2, \dots, u_m\}$ 包含 M 个用户, 项目集 $I = \{i_1, i_2, \dots, i_N\}$ 包

含 N 个项目。

定义 2(用户-朋友社交图) 用户与朋友之间的交互构成了用户-朋友社交图, 记为 $G_{uf} = \{U \cup F, E_{uf}\}$, 是一个社会关系图。其中 $F = \{f_1, f_2, \dots, f_L\}$ 为朋友集包含了 L 个朋友, E_{uf} 是用户和朋友之间边的集合。

定义 3(交互矩阵) 用户与项目之间的交互构成了交互矩阵, 记为 $\mathbf{R}^{m \times n}$, 其中 m 和 n 分别为用户和项目的数量。 \mathbf{R} 中的每个元素记为 r_{mn} , 表示用户 u 与项目 i 是否交互; 若用户 u 与项目 i 之间有过交互, 则 r_{mn} 记为 1, 否则 r_{mn} 为 0。

定义 4(中间反馈) 通过分析用户行为和朋友圈密度而间接捕获的用户对项目的隐式偏好, 称为中间反馈。中间反馈相比于显/隐式反馈被视为弱偏好, 而相比于隐式负反馈被视为强偏好。

2.2 解决方案

本文设计了一种融合社交关系的轻量级图卷积协同过滤模型, 框架如图 2, 主要由 3 个模块组成。①嵌入层: 初始化用户和项目的嵌入向量。②图卷积层: 通过学习用户-朋友社交图 and 用户-项目-朋友高阶连接图的用户和项目嵌入, 从隐式负反馈中产生一系列中间反馈, 并利用高阶连接信息来细化嵌入向量。③预测层: 采用内积交互函数, 得到用户与项目之间的关联分数。




图 2 F-LightGCCF 模型框架图

Fig. 2 Framework of F-LightGCCF model

2.2.1 嵌入层

根据图嵌入模型^[5-7], 一个用户 u (朋友 f 或项目 i) 的嵌入向量表示为 $\mathbf{c}_u \in \mathbf{R}^d$ ($\mathbf{c}_f \in \mathbf{R}^d$ 或 $\mathbf{c}_i \in \mathbf{R}^d$), 其中 d 表示嵌入向量的维度, 用户、用户朋友以

及项目等嵌入向量构成的初始嵌入向量查找表为

$$\mathbf{E}_m = [\mathbf{e}_{u1} \mathbf{e}_{u2} \dots \mathbf{e}_{uM} \mathbf{e}_{f1} \mathbf{e}_{f2} \dots \mathbf{e}_{fL} \mathbf{e}_{i1} \mathbf{e}_{i2} \dots \mathbf{e}_{iN}]$$

其中, 嵌入查找表作为用户嵌入、用户朋友嵌入以及项目嵌入的初始状态, 以端到端的方式进行

传递和优化。

2.2.2 图卷积层

受 GAT^[4]、NGCF^[8]、LightGCN^[9] 等模型的启发, 在 GCN^[10] 消息传递机制的基础上, 从图结构中捕获协同过滤 (collaborative filtering, CF) 信号, 并细化嵌入向量。本文设计了由消息构建和消息聚合两部分构成的图卷积层。

1) 消息构建

从图 1(b) 可知, 当 $L=1$ 时存在连接用户-项目对 (u, i) , 从项目 i 到用户 u 的消息传递定义为

$$m_{u \leftarrow i} = f(e_i, e_u, p_{ui})$$

其中, $u \leftarrow i$ 表示从项目到用户的方向传递交互信息, m 为表示传递消息的嵌入向量, $f()$ 是一个消息编码函数, 输入为该用户-项目节点对中用户 u 和项目 i 的嵌入向量 e_u 和 e_i , 以及相关系数 p_{ui} , 相关系数 p 用来控制 (u, i) 边上每次传播时的衰减因子。

本文中, 消息编码函数 $f()$ 的具体定义为

$$m_{u \leftarrow i} = \frac{1}{\sqrt{|N_u||N_i|}} \left(\sigma \left(\sum_{i \in N_u} \alpha_{ui} e_i \right) + (e_i \odot e_u) \right)$$

其中, 本文模型不仅考虑了 e_i 的影响, 还利用哈达玛积 ($e_i \odot e_u$) 将用户与项目之间的交互信息编码到消息传递机制中, 使得消息传递取决于 e_i 与 e_u 之间的亲密度值。相关性系数 $p_{ui} = 1/\sqrt{|N_u||N_i|}$ 采用图卷积神经网络中常用的拉普拉斯范数, 其中 N_u 和 N_i 表示用户 u 与项目 i 的一阶邻居。

传统的聚合函数不能区分邻域的重要性, 在更新节点时, 所有邻域被赋予一个静态权重。因此, 本文利用图注意力网络衡量邻域的贡献值, 还使得模型更新邻域节点权重时仅依赖于节点之间的特征表达, 独立于具体的图结构 (图 2 展示了图注意力网络更新特征节点的方式), 提高了模型的泛化能力。

依据图注意力网络原理, 邻居节点 i 对目标节点 u 的影响, 可由注意力相关分数表示:

$$e_{ui} = \text{LeakyRelu}(e_u \| e_i)$$

最后, 使用 softmax 函数对输出结果进行归一化, 得到目标用户 u 的所有邻居节点 i 的注意力权重, 计算方法为

$$\alpha_{ui} = \text{softmax}(e_{ui}) = \frac{\exp(e_{ui})}{\left(\sum_{k \in N_u} \exp(e_{uk}) \right)^{\beta_1}}$$

其中, β_1 为一个平滑系数, 防止 softmax 函数对活跃用户权重的过度惩罚, 取值范围为 $[0, 1]$ 。

同理, 当 $L=2$ 时存在连接项目-用户朋友对 (i, f) , 从用户朋友 f 到用户直接交互项 i 的消息传递可定义为 $m_{i \leftarrow f}^{(2)} = f(e_f, e_i, p_{if})$, 捕获了用户与朋友

之间的亲密度。当 $L=3$ 时存在连接用户朋友-项目对 (f, i) , 从用户未交互项 i 到用户朋友 f 的消息传递可定义为 $m_{f \leftarrow i}^{(3)} = f(e_i, e_f, p_{fi})$, 从隐式负反馈中产生一系列的中间反馈。 $L=2$ 与 $L=3$ 消息构建原理与 $L=1$ 相同。图 3 展示了目标用户 u_1 的三阶图卷积传播过程, 如 $i_5 \rightarrow f_2 \rightarrow i_2 \rightarrow u_1$ 这条传播链上的交互信息被模型捕获, 使得 i_5 上的信息被编码到 $e_{u_1}^{(3)}$ 。由此, 通过堆叠 3 层图卷积层, 利用社交关系捕获隐式负反馈信息 (即, 中间反馈)。




图 3 三阶图卷积传播层

Fig. 3 Third-order graph convolution propagation layers

2) 消息聚合

经过 3 层图卷积传播后, 相应的得到了用户 u 的 3 个不同的嵌入向量表达, 它们对用户偏好有不同的影响。通过聚合目标用户 u 的所有邻居节点特征来更新用户 u 的嵌入表达 e_u , 聚合函数可定义为

$$e_u^* = m_{u \leftarrow i}^{(1)} \| m_{i \leftarrow f}^{(2)} \| m_{f \leftarrow i}^{(3)}$$

式中: $\|$ 表示拼接运算。

2.2.3 预测层

同理, 对经过 3 层图卷积传播后得到的 3 个不同的项目嵌入表达, 最终的用户和项目的嵌入表达分别如式 (1)、(2) 所示:

$$e_u = \sum_{l=1}^3 \gamma_l \times e_u^{(l)} \quad (1)$$

$$e_i = \sum_{l=1}^3 \gamma_l * e_i^{(l)} \quad (2)$$

式中: $\gamma_l \geq 0$ 表示第 l 层嵌入的重要程度, 该参数采用注意力机制自动优化。

本文采用一个多层感知机来实现注意力机制:

$$F(p_i, q_j) = \mathbf{h}^T \text{ReLU}(\mathbf{w}(p_i \odot q_j) + \mathbf{b})$$

式中: p_i 通过图嵌入技术将 one-hot 稀疏向量转换为低维稠密向量表示, $p_i \in \mathbf{R}^{d \times 1}$; d 为嵌入向量维度; q_j 为每个与用户交互过的项目嵌入表达, $q_j \in \mathbf{R}^{d \times 1}$; $j \in R_u^+$, R_u^+ 为与用户交互过的项目集合; $\mathbf{w}^{l \times d}$ 、 $\mathbf{b}^{d \times 1}$ 分别表示从输入层到隐藏层的权重矩阵和防止过拟合的偏置项; \mathbf{h}^T 表示从隐藏层到输入层的权重向量。最后使用 softmax 函数对输出结果进行归一化处理:

$$\gamma = \frac{\exp(F(\mathbf{p}_i, \mathbf{q}_i))}{\left[\sum_{j \in \mathcal{N}_i} \exp(F(\mathbf{p}_i, \mathbf{q}_j)) \right]^{\beta_2}}$$

式中: β_2 为一个平滑系数, 防止过度平滑, 取值范围为 $[0, 1]$ 。

最后, 在模型预测部分, 采用内积交互函数, 通过内积运算得到用户对目标项目的偏好为

$$\hat{y}_{ui} = \mathbf{e}_u^T * \mathbf{e}_i$$

2.2.4 模型优化

本文使用贝叶斯 (Bayesian personalized ranking, BPR) 损失函数^[18]对模型进行优化, 主要原因是贝叶斯损失函数考虑了观察到的交互和未观察到的交互之间的成对偏好比较。本文还利用用户的社交关系产生了一系列中间反馈, 与 BPR 的基本假设相比, 本文假设可以从用户的社交网络中, 在未观察到的交互中挖掘出更多的用户偏好, 优化目标为

$$L_{\text{APA}} = \sum_{u, i, j, k} -\ln \sigma(\hat{y}_u + \hat{y}_{u, i} - \hat{y}_{u, j}) + \lambda \|\Theta\|^2$$

式中: $\Theta = \{(u, i, j, k) | (u, i) \in R^+, (u, j) \in R^-, (u, k) \in R^+\}$ 表示数据集, 每一条数据都是一个四元组。 R^+ 表示观测到的用户-项目交互动作, R^- 表示未观测到的用户-项目交互动作, R^+ 表示挖掘出的中间反馈, $\sigma()$ 是 sigmoid 函数。 $\|\Theta\|^2$ 为 L2 正则化项, λ 为正则化系数, 控制 L2 正则化强度防止过拟合, $\Theta = \{E, \beta\}$ 表示所有可训练的模型参数。

Dropout 策略可以在模型训练时有效防止模型的过拟合, 本文采用节点丢弃的 Dropout 策略。随机冻结一些特定节点, 使其消息不向外传播, 对于 3 层高阶传播, 随机丢弃拉普拉斯矩阵中的 $(M+N)p$ 个节点, 其中 p 为 Dropout 率。

3 实验

3.1 数据集

实验采用 Gowalla 和 Yelp2018 两个公开的数据集来评估提出的模型, 表 1 给出了两个数据集的统计信息。

表 1 实验数据信息
Table 1 Statistics of the datasets

数据集	用户/个	项目/个	朋友/个	社交数据/条	稀疏度
Gowalla	7464	40981	22394	1027370	0.00084
Yelp2018	7958	40841	23873	1666869	0.00128

3.2 对比算法

本文提出的融合社交关系的轻量级图卷积协同过滤模型 (light graph convolutional collaborative

filtering recommendation approach incorporating social relationships, F-LightGCCF), 分别与以下 4 种先进的推荐模型比较:

1) GRMF^[19]: 该模型通过利用图拉普拉斯正则化算子来平滑矩阵分解, 设计了图正则化交替最小二乘法对算法进行优化, 利用加权核范数结构化矩阵分解框架。

2) Mult-VAE^[20]: 该模型将可变自动编码器应用于协同过滤算法, 利用非线性概率模型挖掘用户-项目之间的隐式反馈。

3) NGCF^[8]: 该模型是基于图卷积神经网络的先进推荐模型, 通过构建了 k 层嵌入传播层对交互信息进行嵌入传播学习, 最终得到用户-项目之间的关联分数。

4) LightGCN^[9]: 该模型基于 NGCF 模型, 摒弃了 NGCF 模型中特征变换和非线性激活 2 个复杂的设计, 降低了模型的训练难度。

3.3 实验设置

本文模型和算法使用 Python 语言基于 TensorFlow 框架实现, 机器配置为 GPU i7-8700K 3.7 GHz, 操作系统为 Windows 10。在实验中, 对于每一个数据集, 随机选择每个用户的 80% 的交互历史构成训练集, 剩余的 20% 作为测试集。随机选取训练集中的 10% 作为验证集, 用于参数的调试。基于以往模型^[9]的经验, 正则化系数设置为 1×10^{-4} , 每次处理的数据量大小为 1 024, 迭代次数为 100 次时模型收敛。经验证集测试后, 在 Gowalla 数据集和 Yelp2018 数据, Dropout 率分别设置为 0.3 和 0.1。学习率设置为 0.0006, 注意力网络的平滑系数 β_1 和 β_2 均设置为 0.5。参数调整好之后, 本文采用 Adam^[21] 作为优化器, 使用 Xavier 方式初始化模型参数, 嵌入大小为 64, 使用 3 个 64×64 的图卷积层。

3.4 评价指标

在本文, 每种模型均输出用户对所有项目的偏好分数, 为了评估 top- k 推荐和偏好排序的有效性, 实验使用召回率 (Recall@ k)、精确率 (Precision@ k) 和归一化折现积累收益 (NDCG@ k) 作为推荐效果方面的评价指标。默认情况下, 设置 $k=20$ 。召回率是所有“被正确推荐的项目”占有所有“应该被推荐的正确的项目”的比例, 精确率是“被正确推荐的项目”占“所有被正确推荐的项目”的比例, 分别如式 (3) 和 (4) 所示。

$$\text{Recall}@k = \frac{\sum_u |R(u) \cap T(u)|}{\sum_u |T(u)|} \quad (3)$$

$$\text{Precision}@k = \frac{\sum_u |R(u) \cap T(u)|}{\sum_u |T(u) \cap F(u)|} \quad (4)$$

式中: $R(u)$ 是为用户推荐的项目集合; $T(u)$ 为测试集上用户感兴趣的项目的集合; $F(u)$ 为测试集上用户不感兴趣的项目的集合。

NDCG 是一种基于排名的测试指标,排名靠前的项目得分更高。

$$\text{NDCG}@k = \frac{1}{n} \sum_{i=1}^k \frac{2^{\text{rel}_i} - 1}{\log_2(i+1)}$$

式中: rel_i 表示用户对第 i 个项目的评分; $\log_2(i+1)$ 是一个位置递减权重。

3.5 实验结果

3.5.1 模型推荐效果

将本文模型与对比模型分别在 2 个相同的数据集上实验,实验结果如表 2 所示。从模型推荐

效果的总体比较来看,本文提出的 F-LightGCCF 模型在 2 个数据集上的 3 方面表现优于其他方法,证明了模型的高效性和良好的泛化能力。

实验对模型的 top- k 推荐进行了 Recall@ k 、Precision@ k 和 NDCG@ k 3 方面评估以验证模型的有效性,其中 k 分别取值为 20、40、60、80、100,结果如图 4 所示。本文模型的 top- k 推荐效果在全局和局部均有明显的提升,主要原因是采用图嵌入技术将用户、项目、朋友信息映射到低维稠密的向量空间,有效缓解了数据的稀疏性。通过堆叠 3 层图卷积层,利用社交关系捕获隐式负反馈信息,从而挖掘出能够间接反映用户偏好的中间反馈。另外,通过使用图注意力网络来衡量并更新邻居节点的贡献值。最后,将图卷积层学习到的多个嵌入向量通过分层聚合机制加权聚合,并引入注意力机制自动学习第 l 层嵌入向量的重要程度,有效提高了模型推荐效果。

表 2 总体比较

Table 2 Overall performance comparison

算法	Gowalla			Yelp2018		
	Recall@20	Precision@20	NDCG@20	Recall@20	Precision@20	NDCG@20
GRMF	0.1477	0.0146	0.1205	0.0571	0.0091	0.0462
Mult-VAE	0.1641	0.0163	0.1335	0.0584	0.0100	0.0450
NGCF	0.1570	0.0157	0.1327	0.0579	0.0096	0.0477
LightGCN	0.1830	0.0183	0.1554	0.0649	0.0102	0.0530
F-LightGCCF	0.2485	0.0306	0.2800	0.1073	0.0179	0.1527
Improve/%	35.79	67.21	80.18	65.33	75.49	188.11

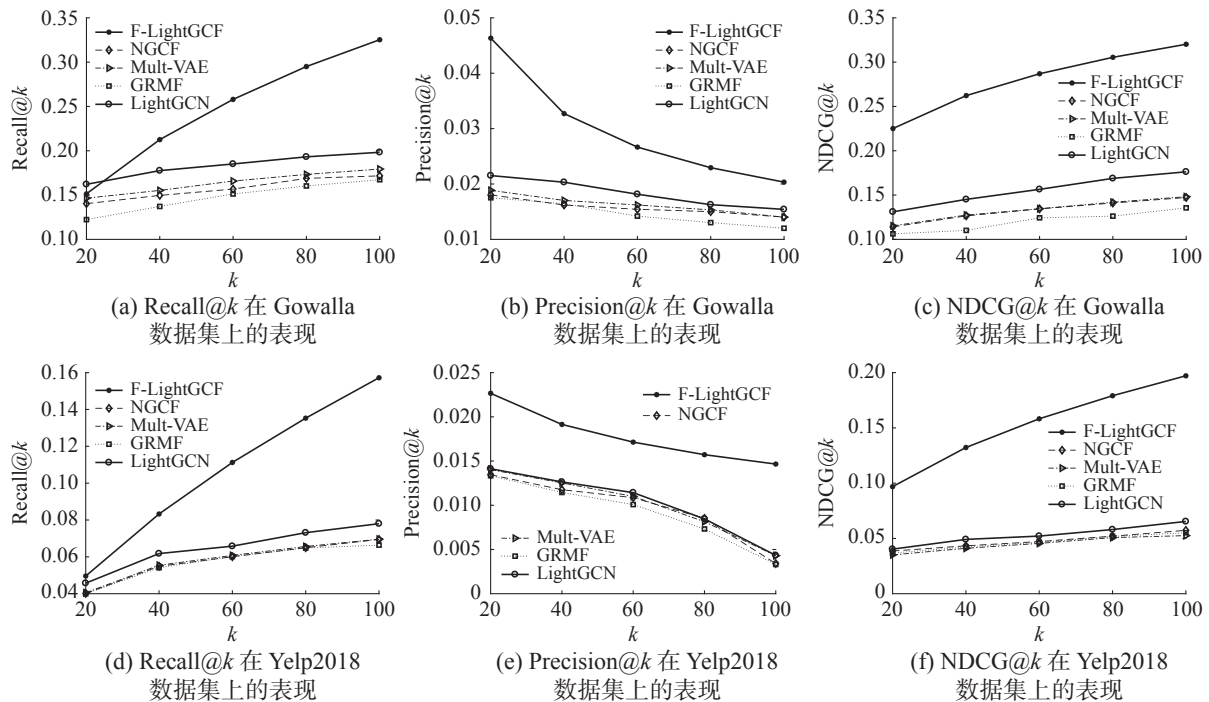


图 4 2 个不同数据集上 top- k 推荐效果

Fig. 4 Top- k recommendation performance on two different data sets

3.5.2 图卷积层的影响

图卷积层对 F-LightGCCF 模型推荐效果中起决定性作用。本文分别设计了 GC-MC 图卷积层^[14]和 Hop-Rec 图卷积层^[15], 模型的推荐效果如表 3 所示。本文设计的图卷积层的推荐效果相比于其他两种设计均有明显提高, 原因是本文图卷积层的设计使用哈达玛积 ($\mathbf{e}_i \odot \mathbf{e}_u$), 使得消息传递取决于 \mathbf{e}_i 与 \mathbf{e}_u 之间的亲密度值。在邻域聚合时, 每个邻域嵌入采用对称归一化。经以往研究^[9]证实, 对称归一化可以使模型表现良好。此外, 通过图注意力网络来衡量邻居的贡献值。而 GC-MC 和 Hop-Rec 图卷积层的设计并未对图卷积层进行简

化操作, 仅使用了线性变换, 其次, 它们的设计并没有考虑用户的社交关系, 降低了训练数据的丰富性。此外, Hop-Rec 层总体表现优于 GC-MC 层, 原因是 GC-MC 层仅考虑了用户-项目连接性的一阶邻居影响, 而 Hop-Rec 层利用高阶邻居来丰富训练数据, 对用户和项目之间的高阶偏好进行建模。

由表 2 与表 3 比较可知, 更换了图卷积层的 F-LightGCCF 模型仍表现出很好的推荐效果, 原因是本文模型设计了分层聚合机制, 考虑了嵌入向量对最终向量表达的影响, 融合注意力机制学习第 l 层嵌入的重要程度, 验证了模型设计的合理性。

表 3 不同图卷积层模型的推荐效果

Table 3 Recommendation effects of different graph convolution layer models

算法	Gowalla			Yelp2018		
	Recall@20	Precision@20	NDCG@20	Racall@20	Precision@20	NDCG@20
GC-MC	0.1811	0.0218	0.2037	0.0978	0.0163	0.1362
Hop-Rec	0.1853	0.0225	0.1967	0.0997	0.0165	0.1386
F-LightGCF	0.2485	0.0306	0.2800	0.1073	0.0179	0.1527

3.5.3 消融分析

以往的工作^[22-23]遵循标准的 GCN 设计, 包括特征变换和非线性激活。受 LightGCN 模型启发, 对本文提出的模型进行消融工作。实验结果如表 4 所示, 其中 NF-GCCF 为未消融的模型, F-

LightGCCF 为消融的模型。F-LightGCCF 模型的推荐效果有明显提高, 验证了之前的猜想。在协同过滤推荐中, 对用户/项目的 one-hot 向量进行特征变换和非线性激活无助于特征学习, 反而会增加模型的训练难度, 降低模型性能。

表 4 消融分析

Table 4 Ablation analyses

算法	Gowalla			Yelp2018		
	Recall@20	Precision@20	NDCG@20	Racall@20	Precision@20	NDCG@20
NF-GCCF	0.2316	0.0226	0.2158	0.1002	0.0167	0.1429
F-LightGCF	0.2485	0.0306	0.2800	0.1073	0.0179	0.1527

3.6 超参数学习

模型训练过程中, 超参数直接影响模型学习的结果, 为了使模型达到最佳的推荐效果, 本文对模型的超参数学习如表 5。

表 5 测试超参数


Table 5 Test hyper-parameters

超参数	测试参数值
l_r	{0.0001, 0.0003, 0.0005, 0.0006, 0.0007, 0.0008, 0.0009, 0.001, 0.0015, 0.002}
node_dropout	{0.1, 0.2, 0.3, 0.4, 0.5}
β	{0.0, 0.1, 0.2, 0.3, 0.4, 0.5, 0.6, 0.7, 0.8, 0.9, 1}


3.6.1 学习率影响

模型的学习率直接影响着神经网络模型的收敛状态, 进而影响着模型的性能表现, 因此选择

一个合适的学习率对于一个神经网络模型的影响至关重要。在神经网络模型中, 学习率可以被视为一个超参数来手动调整, 也可以看作一个学习参数自动学习。在实验中, 将其设置为一个超参数, 通过手动调整训练得到最优的学习率大小, 实验结果如图 5。当学习率 $l_r=0.0006$ 时, 模型推荐的总体效果达到最佳, 当学习率 $l_r=0.0001$ 时, 模型推荐的总体效果最差。



(a) Gowalla 数据集上学习率测试



(b) Yelp2018 数据集上学习率测试

图5 学习率测试

Fig. 5 Learning rate test

3.6.2 Dropout 率

Dropout 策略在模型训练时有效防止模型的过拟合, 本文提出了一种 Dropout 策略为节点丢弃 (node_dropout)。图6分别显示了节点丢弃率 p 取

不同值作用于2个不同的数据集上产生的不同影响。当 $p=0.3$ 时, 模型在 Gowalla 数据集上的推荐效果最佳。当 $p=0.1$ 时, 模型在 Yelp2018 数据集上的推荐效果最佳。原因是 Gowalla 数据集的稀疏度低于 Yelp2018 数据集的稀疏度, 故而 Gowalla 数据集更需要丢弃一些无用的数据节点。

3.6.3 平滑系数

注意力网络的平滑系数用于防止过度平滑对推荐结果所产生的消极影响。本文将平滑系数设置为可手动训练的超参数, 图7展示了平滑系数 β_1 和 β_2 分别作用于2个数据集上对召回率的影响。当 $\beta_1=\beta_2=0.5$ 时, 取得最佳的推荐效果。

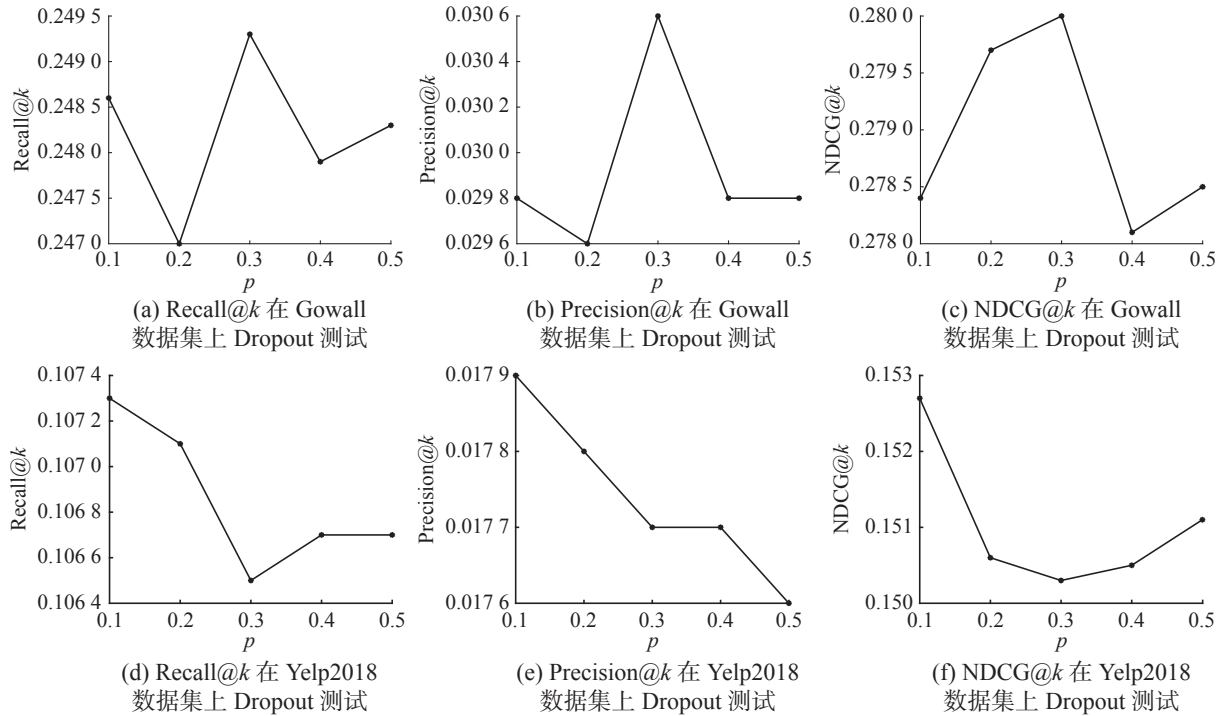


图6 Dropout 率测试

Fig. 6 Dropout test




图7 平滑系数的影响

Fig. 7 Effect of smoothing factor

4 结束语

本文提出了一种融合社交关系的轻量级图卷积协同过滤模型(F-LightGCCF模型),首先,模型在嵌入层嵌入用户、项目和朋友信息,缓解了数据稀疏性的影响;在图卷积层引入注意力机制衡量邻居节点的贡献值,摒弃了图卷积网络中特征变换和非线性激活的设计,降低了模型的训练难度,提升了模型性能;其次,设计了分层聚合机制综合考虑嵌入学习向量对最终向量表达的影响,再次融合注意力机制学习第 l 层嵌入的重要程度;最后,模型预测层,利用内积运算预测用户与项目之间的关联分数。实验结果表明,与现有的主流协同过滤推荐模型相比,本文模型取得了更好的推荐效果。本文所构建的轻量级图卷积神经网络模型,是一种简单、线性模型,它更容易实现和训练,但是模型受线性的影响,可能无法有效地捕捉初始数据中的非线性结构。在未来的工作中,将采用更为丰富的训练数据,以缓解推荐模型的冷启动问题。与此同时,考虑影响推荐效果的更多属性,如用户兴趣的动态变化等,尝试通过设计更合理的协同过滤推荐模型来缓解推荐系统中数据稀疏性和隐式反馈的低利用率等问题,进一步提升推荐的准确性。

参考文献:

- [1] TANG Weitao, YU Dunhui, WEI Shiwei. Commodity recommendation algorithm fusing with knowledge graph and user comment[J]. Computer engineering, 2020, 46(08): 93–100.
- [2] ZHANG Su, LI Hui, SHI Jun, et al. Research on recommendation algorithm combining user comments and rating information[J]. Journal of shaanxi normal university, 2020, 48(02): 84–91.
- [3] 印鉴, 王智圣, 李琪, 等. 基于大规模隐式反馈的个性化推荐[J]. 软件学报, 2014, 25(9): 1953–1966.
YIN Jian, WANG Zhisheng, LI Qi, et al. Personalized recommendation based on large-scale implicit feedback[J]. Journal of software, 2014, 25(9): 1953–1966.
- [4] PETAR V, GUIKKEM C, ARANTXA C, et al. Graph attention networks. [C]//Proceedings of the 6th International Conference on Learning Representations. Vancouver: ICLR, 2018: 1710–1722.
- [5] PEROZZI B, AL-RFOU R, SKIENA S. Deepwalk: online learning of social representations[C]//KDD '14: Proceedings of the 20th ACM SIGKDD international conference on Knowledge discovery and data mining. New York: ACM, 2014: 701–710.
- [6] 周林娥, 游进国. 一种结合聚集图嵌入的社会化推荐算法[J]. 小型微型计算机系统, 2021, 42(1): 78–84.
ZHOU Line, YOU Jinguo. Social Recommendation with Embedding of Summarized Graphs [J]Journal of Chinese computer systems. 2021, 42(1): 78–84.
- [7] 高海燕, 毛林, 窦凯奇, 等. 基于图嵌入模型的协同过滤推荐算法[J]. 数据采集与处理, 2020, 35(3): 483–493.
GAO Haiyan, MAO Lin, DOU Kaiqi, et al. Graph embedding model based collaborative filtering algorithm [J]Journal of data acquisition and processing. 2020, 35(03): 483–493.
- [8] WANG Xiang, HE Xiangnan, WANG Meng, 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.
- [9] HE Xiangnan, DENG Kuan, WANG Xiang, et al. LightGCN: simplifying and powering graph convolution network for recommendation[C]//SIGIR'20: Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2020: 639–648.
- [10] KIPF T, WELLING M. Semi-supervised classification with graph convolutional networks[EB/OL]. New York: arXiv, 2016. (2016–09–09)[2021–07–17].<https://arxiv.org/abs/1609.02907v4>.
- [11] 刘荣辉, 张敬普. 基于深度学习的正则化矩阵分解推荐系统[J]. 西南师范大学学报(自然科学版), 2021, 46(7): 103–108.
LIU Ronghui, ZHANG Jingpu. Recommender system of regularization matrix decomposition based on deep learning[J]. Journal of Southwest China Normal University (natural science edition), 2021, 46(7): 103–108.
- [12] 吴国栋, 查志康, 涂立静, 等. 图神经网络推荐研究进展[J]. 智能系统学报, 2020, 15(1): 14–24.
WU Guodong, ZHA Zhikang, TU Lijing, et al. Research advances in graph neural network recommendation[J]. CAAI transactions on intelligent systems, 2020, 15(1): 14–24.
- [13] 刘方爱, 王倩倩, 郝建华. 基于深度神经网络的推荐系统研究综述[J]. 山东师范大学学报(自然科学版), 2021, 36(4): 325–336.
LIU Fangai, WANG Qianqian, HAO Jianhua. A survey of recommendation system based on deep neural network[J]. Journal of Shandong Normal University (natural science edition), 2021, 36(4): 325–336.
- [14] RIANNE Van Den Berg, THOMAS N. KIPF M W. Graph convolutional matrix completion[EB/OL]. New York: arXiv, 2017. (2017–06–07)[2021–07–17].<https://arxiv.org/abs/1706.03531>.

- arxiv.org/abs/1706.02263.
- [15] YANG J H, CHEN C M, WANG Chuanju, et al. HOP-rec: high-order proximity for implicit recommendation[C]//RecSys'18: Proceedings of the 12th ACM Conference on Recommender Systems. New York: ACM, 2018: 140–144.
- [16] LIU Donghua, LI Jing, DU Bo, et al. DAML: dual attention mutual learning between ratings and reviews for item recommendation[C]//KDD'19: Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM, 2019:344–352.
- [17] XI Wudong, HUANG Ling, WANG Changdong, et al. BPAM: recommendation based on BP neural network with attention mechanism[C]//Proceedings of the 28th International Joint Conference on Artificial Intelligence. California: International Joint Conferences on Artificial Intelligence Organization, 2019: 3905–3911.
- [18] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback[C]//UAI'09: Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence. New York: ACM, 2009: 452–461.
- [19] RAO N, YU H F, RAVIKUMAR P, et al. Collaborative filtering with graph information: consistency and scalable methods[C]//NIPS'15: Proceedings of the 28th International Conference on Neural Information Processing Systems-Volume 2. New York: ACM, 2015: 2107–2115.
- [20] LIANG Dawen, KRISHNAN R G, HOFFMAN M D, et al. Variational autoencoders for collaborative filtering [C]//Proceedings of the 2018 World Wide Web Conference on World Wide Web. New York: ACM Press, 2018: 689–698.
- [21] KINGMA DIEDERIK, BA JIMMY. Adam: a method for stochastic optimization. [C]//Proceedings of the International Conference on Learning Representations. San Diego: [s. n.], 2015: 1412–1427.
- [22] FU Sichao, LIU Weifeng, ZHANG Kai, et al. Semi-supervised classification by graph p-Laplacian convolutional networks[J]. *Information sciences*, 2021, 560: 92–106.
- [23] 苏静, 许天琪, 张贤坤, 等. 基于图卷积与外积的协同过滤推荐模型 [J]. 计算机应用研究, 2021, 38(10): 3044–3048.
- SU Jing, XU Tianqi, ZHANG Xiankun, et al. Collaborative filtering recommendation model based on graph convolution and cross product[J]. *Application research of computers*, 2021, 38(10): 3044–3048.

作者简介:



朱金侠, 硕士研究生, 主要研究方向为推荐系统。



孟祥福, 教授, CCF 会员, 主要研究方向为 Web 数据库 top-*k* 查询, 空间数据管理, 推荐系统和大数据可视化等。主持国家自然科学基金 2 项, 主持辽宁省各类基金项目 3 项。发表学术论文 60 余篇, 出版学术专著 1 部。



邢长征, 教授, CCF 会员, 主要研究方向为分布式数据库与数据管理、流聚类、推荐系统。主持国家重点研发计划项目子课题任务 1 项, 省部级科研项目 3 项, 获辽宁省优秀教学成果一等奖 1 项。矿山安全应用类课题 10 余项。发表学术论文 40 余篇, 编写出版教材 3 部。