



研究与开发

基于用户多特征融合的个性化推荐模型

卢敏¹, 胡娟^{1,2}, 张先超², 丁伟健^{1,2}, 乐光学²

(1. 江西理工大学理学院, 江西 赣州 341000;

2. 浙江省医学电子与数字健康重点实验室, 浙江 嘉兴 314001)

摘要: 个性化推荐是提取特定信息的有效手段之一, 针对传统推荐法中缺少用户特征问题, 提出一种基于多特征融合的广义矩阵分解与深度长短期记忆网络混合推荐模型 (hybrid recommendation model of generalized matrix factorization and deep long short-term memory network based on multi-features fusion, HMF)。该模型利用潜在特征向量维度表征年龄、职业对项目的选择性影响, 凸显用户个性化; 利用长短期记忆 (long short-term memory, LSTM) 获取用户与项目间的时序特征, 再通过多层感知机挖掘其深层次的时序非线性高阶交互关系; 将广义矩阵分解 (generalized matrix factorization, GMF) 获得的简单非线性低阶交互关系与复杂时序非线性高阶交互关系融合, 经全连接层得出最终预测评分。HMF 有效地利用用户多特征和用户-项目交互信息, 实现个性化动态精准推荐。为验证模型的有效性和可行性, 在公开数据集 MovieLens-1M 上进行测试。仿真实验表明, 当 HMF 的潜在特征向量维度为 50、MLP 层数为 7 时, HR@10 和 NDCG@10 分别为 0.983 1、0.974 9, 相比传统单特征模型 NCF 最优解分别提高了 27.61%、54.29%。

关键词: 个性化推荐; 多特征融合; 深度学习

中图分类号: TP391.3

文献标志码: A

doi: 10.11959/j.issn.1000-0801.2023111

Personalized recommendation model based on users multi-features fusion

LU Min¹, HU Juan^{1,2}, ZHANG Xianchao², DING Weijian^{1,2}, YUE Guangxue²

1. School of Science, Jiangxi University of Science and Technology, Ganzhou 341000, China

2. Key Laboratory of Medical Electronics and Digital Health of Zhejiang Province, Jiaxing 314001, China

Abstract: Personalized recommendation is one of the most effective means to extract specific information. Aiming at the problem that lacking of users feature in traditional recommendation methods, a hybrid recommendation model of generalized matrix factorization and deep long short-term memory network based on multi-features fusion (HMF) was proposed. The model used potential eigenvector factors to characterize the selective impact of age and occupation on the project, highlighting user personalization. Long short-term memory (LSTM) was used to obtain the temporal characteristics between users and projects, and then the deep temporal nonlinear higher-order interaction rela-

收稿日期: 2023-01-31; 修回日期: 2023-05-11

通信作者: 乐光学, gxyue@zjxu.edu.cn

基金项目: 国家自然科学基金资助项目 (No.11704163)

Foundation Item: The National Natural Science Foundation of China (No.11704163)



tionship was mined by multi-layer perceptron. The simple nonlinear low-order interaction obtained by generalized matrix factorization (GMF) was fused with the complex time-series nonlinear high-order interaction, and the final prediction score was obtained through the full connection layer. HMF effectively utilized the user's multi-feature and user-project interaction information to realize personalized dynamic and accurate recommendation. In order to verify the validity and feasibility of the model, the test was conducted on the public dataset MovieLens-1M. The simulation experiment shows that when the potential eigenvector factors of HMF is 50 and the MLP layer is 7, HR@10 and NDCG@10 are 0.983 1 and 0.974 9 respectively, which are 27.61% and 54.29% higher than the optimal solution of the traditional single feature model NCF.

Key words: personalized recommendation, multi-features fusion, deep learning

0 引言

随着智能化、网络化、数字化等现代信息技术的快速发展,推荐系统需从大量数据中提取用户感兴趣的信息。个性化推荐就是根据用户特征及用户与项目间的历史交互信息^[1]进行推荐,已广泛应用于各种场景。例如旅游业,利用个人历史旅游数据为用户推荐经济适应性的旅游信息^[2];电子商务,利用用户评分和产品图像为用户推荐商品信息^[3];居住环境,利用机器学习和建筑物的自然时空温度变化为每个居住者开发个人舒适模型,以减少响应时间、个人偏好冲突和能源使用^[4];高校图书借阅,利用借阅历史信息挖掘读者潜在的信息需求,提高图书借阅率^[5]。传统推荐算法一般分为基于协同过滤(collaborative filtering, CF)推荐和基于内容(content-based, CB)推荐。Afoudi等^[6]提出一种将CB和CF推荐算法与深度学习技术结合的混合推荐方法,传统推荐方法的效率得到提高,推荐性能明显提升,但模型组合需要大量的训练时间。

深度学习技术利用深层次非线性网络结构学习大量历史交互数据以挖掘用户和项目间的相关性。He等^[7]提出多层感知机(multilayer perceptron, MLP)与广义矩阵分解(generalized matrix factorization, GMF)结合的神经协同过滤(neural collaborative filtering, NCF)模型,利用嵌入函数将身份号(ID)创建为潜在特征向量,该模型的推荐性能相比传统方法得到很大提升,但在捕捉

用户—项目深层次复杂关系时会产生过拟合现象,无法捕获随时间变化的用户动态偏好。Do等^[8]提出语义增强的NCF模型,将NCF与用户表示和语义项目表示结合,利用长短期记忆(long short-term memory, LSTM)网络模型捕获随时间变化的用户动态偏好,该模型性能优于原始NCF的性能。深度学习技术融合传统方法可有效地获取用户和项目之间的非线性和复杂性关系,大部分缺乏对用户特征以及用户长短期偏好的研究。知识图谱(knowledge graph, KG)是用户和项目间的不同类型关系路径;深度学习结合KG技术可有效利用用户和项目特征,加强用户与项目间的关联性,增强推荐结果的可解释性。以libFM^[9]为代表的基于特征的推荐算法,将知识图谱弱化为用户和项目特征,统一将用户和项目的特征作为模型输入,但无法高效利用知识图谱的全部信息。KG的建模工作量较大,大部分知识图谱研究方法是静态的,而知识图谱间的关系是具有时效性的,不能实时更新用户与项目的关系。本文提出一种基于多特征融合的广义矩阵分解与深度长短期记忆网络混合推荐模型(hybrid recommendation model of generalized matrix factorization and deep long short-term memory network based on multi-features fusion, HMF),通过融合用户的多个特征,提高推荐准确性。本文主要工作如下。

- 利用LSTM学习用户的多个特征,即从多维度(ID、年龄、职业)获取用户和项目间的时序关系,将时序特征融合后,通过

MLP 挖掘用户与项目间的深层次非线性高阶交互关系, 得到细粒度动态特征。

- 利用 GMF 将用户矩阵与项目矩阵点乘, 保留原来的信息, 获取用户与项目间的非线性低阶交互关系和潜在特征。
- 利用融合 (concatenate) 层将细粒度动态特征与原始特征融合, 得到用户动静结合的真实特征; 最后通过激活函数为 Sigmoid 的一个全连接层输出最终预测评分, 该方法大大提高了模型预测精度。

1 相关工作

CF 推荐算法可分为基于用户 (Users-CF)、基于项目 (Items-CF) 和基于模型 (Models-CF)。

- Users-CF 算法可利用不同相似性度量指标计算用户间的相似度, 如皮尔逊相关系数、余弦相似度等, 进行推荐。Singh 等^[10]考虑通过项目特征来增大相似用户的比例, 与其他传统 CF 算法相比, 使用项目的分类属性的相似度度量取得了显著增强的推荐效果, 但在评级预测中做出了较多假设并只考虑“最”相似的邻居。
- Items-CF 算法计算项目间的相似性。Wang 等^[11]提出一种利用 Hellinger 距离设计的基于项目标签的相似性度量法, 以及利用邻居用户评分最相似的项目代替目标项目的预测方法, 解决了依赖共同评分项目的问题, 但仍存在“冷启动”问题。
- Models-CF 算法常用矩阵分解 (matrix factorization, MF) 法抽取隐含信息, 以缓解稀疏性问题。该方法将用户评分矩阵拆分成用户子矩阵和项目子矩阵, 表征用户和项目的潜在特征向量, 利用子矩阵内积拟合用户—项目的交互关系, 其过拟合问题较严重。Duan 等^[12]提出基于评论的矩阵分解 (review-based matrix factorization,

RMF) 方法, 通过项目—主题评分矩阵计算项目间的相似度, 推导未知用户对项目的评分, 有效解决 MF 的过拟合问题, 提高推荐准确性, 但该矩阵仍需评分填充。CF 推荐算法善于从评分数据中挖掘用户喜好, 但仅限于学习用户和项目 ID 的线性潜在特征, 缺乏对项目 and 用户自身的特征研究, 存在“冷启动”和数据稀疏性问题。

CB 推荐算法利用用户和项目的内容信息, 如用户性别、兴趣偏好、项目的描述信息等, 为用户推荐类似的项目, 可缓解“冷启动”问题。Sejwal 等^[13]针对“冷启动”和有限内容问题提出一种基于上下文的项目评分预测推荐系统 CRecSys, 通过资源描述框架图对项目上下文特征建模, 利用 Items-CF 算法计算项目间的相似度, 推荐性能明显提升。Nguyen 等^[14]结合矩阵分解和 CB 推荐算法, 提出一种用于特征混合系统的增量算法, 其模型训练时间和推荐准确性都取得较好的结果, 研究证明特征混合系统是未来研究发展的方向。CB 推荐算法主要通过向量空间模型、线性分类、线性回归等方法对用户和项目特征进行建模, 但受限于特征信息的提取能力, 存在新用户“冷启动”问题。

深度神经网络能有效提取特征, 在推荐系统中应用越来越广泛。Kim 等^[15]提出卷积矩阵分解 (ConvMF) 推荐模型, 将卷积神经网络 (convolutional neural network, CNN) 集成到概率矩阵分解 (probabilistic matrix factorization, PMF) 中, 捕获文档的上下文信息, 提高评级预测的准确性, 但未考虑数据间的序列影响。田震等^[16]提出一种融合 GMF 和 MLP 的深度矩阵分解 (deep matrix factorization, DMF) 模型, 在 GMF 模型上添加多层神经网络, 将 GMF 的输出预测评分通过 MLP 捕捉用户和项目之间的抽象特征, 模型的非线性高阶学习能力和鲁棒性得到提升。王骏等^[17]提出将 MLP 与贝叶斯排序算法融合, 获取所需排



序信息,使得模型推荐更加准确。针对长短期偏好问题,李浩等^[18]提出一种基于循环知识图谱和协同过滤的模型 RKGE-CF,通过协同过滤发现用户的现有兴趣,利用知识图谱结合 LSTM 网络挖掘用户的潜在兴趣,将两种结果融合,得到较好的个性化推荐效果,但结果存在融合比例的问题。高茂庭等^[19]针对用户和项目动态属性提出一种推荐算法 R-RNN,该算法通过两个 LSTM 分别捕捉用户和项目的潜在特征向量,获取长序列数据的动态偏好信息,将用户特征向量和项目特征向量的内积作为预测评分,通过模型训练降低损失,从而更接近真实评分。李利杰等^[20]提出一种基于循环神经网络与全局化领域的推荐算法, LSTM 网络结合全局化领域框架获得用户的隐藏偏好,有效提升推荐准确性。田晓婧等^[21]提出将 LSTM 和 GMF 进行融合,同时捕捉用户的长短期偏好、非线性和线性特征,有效提升推荐性能。针对 MF 和以上模型仅限于学习用户和项目 ID 的线性和非线性潜在特征问题, Kiran 等^[22]提出一种深度混合推荐算法,利用嵌入层描述用户和项目特征,以学习非线性潜在因素,通过深度神经网络学习潜在特征向量,推荐性能大大提升。

越来越多学者利用知识图谱来补偿稀疏性和可解释性,并提高推荐的性能。大部分基于 Trans 系列的图谱嵌入方法,利用学习得到实体、关系的表征来扩充原有推荐系统中项目、用户的表征。Tang 等^[23]利用 TransR 得到用户的关联实体表征,并通过自注意力机制解决加权和问题,更有效地获得用户特征。Trans 系列方法更适合补全任务或边预测任务,而不是推荐任务^[24]。基于异质信息网络的图嵌入方法,从网络图中抽取用户节点相连的 N -hop 实体节点。Wang 等^[25]提出 RippleNet 模型,通过 KG 的链接自动迭代扩展用户的潜在兴趣,刺激用户偏好在知识实体集合上的传播,利用用户和项目表征的点积得到推荐结果,但知识实体集的大小会随着 KG 大小的增加而不可预

测,导致计算和存储开销较大。Ma 等^[26]针对用户-项目单一交互问题,提出一种融合社交关系的图卷积协同过滤推荐模型,该模型利用社会关系推荐算法 (social relations recommendation algorithm, SRRA) 更新用户表示,在召回率 Recall@10 和归一化折损累计增益 (normalized discounted cumulative gain, NDCG) @10 上的性能优于现有的基线模型;该方法受限于图神经网络本身的缺点,如多次迭代后过度平滑,实体表示可能无法完全学习。

基于深度学习的推荐算法可有效学习用户与项目间的非线性交互关系、隐含特征和时序数据等方面的能力,极大提升了模型推荐性能。现有的深度学习模型在一定程度上缓解了数据稀疏性,大部分只利用用户和项目的编号信息,没有充分利用用户的显性特征。在真实场景中,用户年龄和职业等特征与项目间存在时间上的选择性影响因素,推荐具有一定的局限性。利用神经网络结合知识图谱的推荐方法相对深度学习融入更多用户和项目信息,但计算开销较大。多特征融合系统是未来的一种发展趋势,可有效缓解数据稀疏性和“冷启动”问题。本文提出 HMF,利用 LSTM 和 GMF 融合用户多个特征,挖掘用户与项目交互数据的潜在特征,通过 MLP 学习用户与项目间的非线性高阶交互关系,模型推荐性能得到明显提高。

2 HMF 模型

2.1 问题表述

经数据预处理后,假设用户 ID 集合为 U 、用户年龄段集合为 A 、用户职业集合为 J 和项目 ID 集合为 I 。现给定用户 $u_k \in U$ 、用户年龄段 $a_r \in A$ 、用户职业 $j_s \in J$ 、项目 $i_w \in I$,其中,用户 u 未与项目 i 产生交互,根据评分矩阵中的用户评分数据历史记录,利用 LSTM 网络和 MLP 融合用户的多个特征,分别挖掘用户的长短期偏好、用户与

项目间的非线性高阶交互关系, 预测用户 u 对项目 i 的评分 $\tilde{Y}$, 根据预测值对前 K 个推荐项目进行排序。主要数学标识符号定义见表 1。

表 1 主要数学标识符号定义

符号	描述
$U = \{u_1, u_2, \dots, u_K\}$	用户 ID 集合
$I = \{i_1, i_2, \dots, i_W\}$	项目 ID 集合
$A = \{a_1, a_2, \dots, a_7\}$	用户年龄集合
$J = \{j_1, j_2, \dots, j_{21}\}$	用户职业集合
K	用户 ID 数目
W	项目 ID 数目
Y	真实评分
$\tilde{Y}$	预测评分
m_u	用户 ID 潜在特征向量
m_a	用户年龄段潜在特征向量
m_j	用户职业潜在特征向量
l_i	项目 ID 潜在特征向量
m_{ui}, m_{ur}	LSTM+MLP、GMF 模块的用户 ID 特征向量
m_{ai}, m_{ar}	LSTM+MLP、GMF 模块的用户年龄段特征向量
m_{ji}, m_{jr}	LSTM+MLP、GMF 模块的用户职业特征向量
l_{ii}, l_{ir}	LSTM+MLP、GMF 模块的项目 ID 特征向量
N	潜在特征向量维度
$U_{K \times N}$	用户 ID 潜在特征矩阵
$I_{W \times N}$	项目 ID 潜在特征矩阵
$A_{7 \times N}$	用户年龄段潜在特征矩阵
$J_{21 \times N}$	用户职业潜在特征矩阵

2.2 模型设计

2.2.1 长短期记忆网络

LSTM 可有效对时序数据的长短期依赖关系建模。对于推荐电影, LSTM 利用用户特征捕捉用户和项目间的时序关系, 挖掘特征数据的上下文关系, 创建用户状态和项目状态的自回归运算。LSTM 结构如图 1 所示。

LSTM 状态更新满足以下计算式^[21]:

$$F_t = \sigma(W_f[h_{t-1}, X_t] + b_f) \quad (1)$$

$$I_t = \sigma(W_i[h_{t-1}, X_t] + b_i) \quad (2)$$

$$\tilde{C}_t = \tanh(W_c[h_{t-1}, X_t] + b_c) \quad (3)$$

$$C_t = F_t \cdot C_{t-1} + I_t \cdot \tilde{C}_t \quad (4)$$

$$O_t = \sigma(W_o[h_{t-1}, X_t] + b_o) \quad (5)$$

$$h_t = O_t \cdot \tanh(C_t) \quad (6)$$




图 1 LSTM 结构

其中, F_t 、 I_t 和 O_t 分别表示遗忘门、输入门和输出门, $\cdot$ 为哈达玛积, C_t 表示 t 时刻隐藏层神经状态, X_t 表示 t 时刻输入, σ 为 Sigmoid 激活函数, $[h_{t-1}, X_t]$ 表示 $t-1$ 时刻隐藏层输出和 t 时刻输入的连接向量, W_f 、 W_i 、 W_c 、 W_o 表示连接权重矩阵, b_f 、 b_i 、 b_c 、 b_o 表示连接偏置向量。

2.2.2 多层感知机

对于推荐电影, MLP 可挖掘更深层次的抽象高阶交互信息; 利用多层隐藏层建模用户和项目间的高阶交互关系, 定义为^[7]:

$$\begin{cases} X_1 = \theta_1(U_N, l_{ii}) \\ X_2 = \theta_2(X_1) = a_2(X_1 W_2^T + b_2) \\ \dots \\ X_L = \theta_L(X_{L-1}) = a_L(X_{L-1} W_L^T + b_L) \end{cases} \quad (7)$$

$$\tilde{Y}_t = \delta(h^T X_L) \quad (8)$$

其中, l_{ii} 、 U_N 分别表示项目 ID 特征向量、用户特征融合矩阵; a_L 、 W_L^T 、 b_L 分别表示第 L 层激活函数、权重矩阵和偏置向量; X_L 表示第 L 层的输出; $\tilde{Y}_L$ 、 δ 、 h^T 分别表示第 L 层最终输出预测评分、输出层激活函数和权重矩阵。为了防止模



型过拟合并解决数据稀疏问题, 将所有隐藏层的激活函数均设置为 ReLU 函数。

2.2.3 广义矩阵分解

对于推荐电影, GMF 可有效捕捉用户与项目间的二阶交互低层特征, 但缺乏高阶交互信息的捕捉能力。GMF 利用已 one-hot 编码的用户 ID、用户年龄段、用户职业和项目 ID 数据, 分别与用户 ID、用户年龄段、用户职业、项目 ID 潜在特征矩阵相乘得到用户 ID 特征向量 m_{ur} 、用户年龄段特征向量 m_{ar} 、用户职业特征向量 m_{jr} 和项目 ID 特征向量 l_{ir} , 融合用户特征得到 $U_{N/2}$, 利用点乘算法映射到神经网络输出层, 映射关系定义为^[7]:

$$\theta_1 = (U_{N/2}, l_{ir}) = U_{N/2} \odot l_{ir} \quad (9)$$

$$\tilde{Y}_1 = a_{out}(\mathbf{h}^T(U_{N/2} \odot l_{ir})) \quad (10)$$

其中, l_{ir} 表示项目 ID 特征向量, $U_{N/2}$ 表示用户特征融合矩阵, $\odot$ 表示向量点乘, a_{out} 表示输出层激活函数, $\mathbf{h}^T$ 表示权重矩阵。

2.2.4 HMF 框架设计

针对真实电影推荐场景, 利用以上模型特点,

构建一种基于多特征融合的广义矩阵分解与深度长短期记忆网络混合推荐模型 (HMF), 实现电影精准推荐。该模型由 LSTM、GMF 和 MLP 构成, 利用 LSTM 学习用户多个特征, 挖掘用户对项目的长短期动态偏好信息, 通过多层 MLP 和 GMF 分别提取用户与项目的非线性高阶和低阶交互潜在特征。HMF 模型框架如图 2 所示。

(1) 输入层

利用 one-hot 编码方式为输入层用户 ID (U-ID)、用户年龄段 (U-age)、用户职业 (U-job) 和项目 ID (I-ID) 分别创建二值表示, 即在任意时刻只有一个有效位 1, 其他均为 0, 表示为 00100...、01000..., 编码长度分别为用户数目 K 、用户年龄段数目 7、用户职业数目 21 和项目数目 W 。

(2) 嵌入层

将 U-ID、I-ID 稀疏高维 one-hot 编码分别与用户 ID、项目 ID 潜在特征矩阵相乘, 映射成稠密低维的数据; 将 U-age、U-job 稀疏低维 one-hot 编码分别与用户年龄段潜在特征矩阵、用户职业




图 2 HMF 模型框架

潜在特征矩阵相乘, 映射成与用户 ID、项目 ID 具有相同维度 N 的数据。具体定义为^[16]:

$$\begin{cases} \mathbf{m}_u = O_{\text{U-ID}} \mathbf{U}_{K \times N} \\ \mathbf{m}_a = O_{\text{U-age}} \mathbf{A}_{7 \times N} \\ \mathbf{m}_j = O_{\text{U-job}} \mathbf{J}_{21 \times N} \\ \mathbf{l}_i = O_{\text{I-ID}} \mathbf{I}_{W \times N} \end{cases} \quad (11)$$

其输入是输入层中的 U-ID、U-age、U-job、I-ID 的 one-hot 编码, 输出是用户 ID 潜在特征向量 $\mathbf{m}_u$ 、用户年龄段潜在特征向量 $\mathbf{m}_a$ 、用户职业潜在特征向量 $\mathbf{m}_j$ 和项目 ID 潜在特征向量 $\mathbf{l}_i$ 。其中, $\mathbf{U}_{K \times N}$ 表示用户 ID 潜在特征矩阵, $\mathbf{A}_{7 \times N}$ 表示用户职业潜在特征矩阵, $\mathbf{J}_{21 \times N}$ 表示用户年龄段潜在特征矩阵, $\mathbf{I}_{W \times N}$ 表示项目 ID 潜在特征矩阵。

(3) 网络层

将 $\mathbf{m}_u$ 、 $\mathbf{m}_a$ 、 $\mathbf{m}_j$ 、 $\mathbf{l}_i$ 分别输入 LSTM, 学习用户的多个特征和项目 ID 序列, 通过融合层融合用户的多个特征, 根据用户特征捕获用户的长短期偏好, 定义为:

$$F_t = \{F(\mathbf{m}_u)_t, F(\mathbf{m}_a)_t, F(\mathbf{m}_j)_t, F(\mathbf{l}_i)_t\} \quad (12)$$

在遗忘门 F_t 决定遗忘哪些用户特征记忆信息之后, 输入门 I_t 指定神经元状态 $\tilde{C}_t$ 更新:

$$\begin{cases} I_t = \{I(\mathbf{m}_u)_t, I(\mathbf{m}_a)_t, I(\mathbf{m}_j)_t, I(\mathbf{l}_i)_t\} \\ \tilde{C}_t = \{\tilde{C}(\mathbf{m}_u)_t, \tilde{C}(\mathbf{m}_a)_t, \tilde{C}(\mathbf{m}_j)_t, \tilde{C}(\mathbf{l}_i)_t\} \end{cases} \quad (13)$$

经过 F_t 和 I_t , 旧的神经元状态 C_{t-1} 被更新为新的神经元状态 C_t :

$$C_t = \{C(\mathbf{m}_u)_t, C(\mathbf{m}_a)_t, C(\mathbf{m}_j)_t, C(\mathbf{l}_i)_t\} \quad (14)$$

最后基于神经元状态 C_t , 输出门 O_t 得到 h_t :

$$\begin{cases} O_t = \{O(\mathbf{m}_u)_t, O(\mathbf{m}_a)_t, O(\mathbf{m}_j)_t, O(\mathbf{l}_i)_t\} \\ h_t = \{h(\mathbf{m}_u)_t, h(\mathbf{m}_a)_t, h(\mathbf{m}_j)_t, h(\mathbf{l}_i)_t\} \end{cases} \quad (15)$$

h_t 通过展开 (flatten) 层输出各特征向量:

$$\{\mathbf{m}_{ui}, \mathbf{m}_{ai}, \mathbf{m}_{ji}, \mathbf{l}_{ii}\} = Fl(h_t) \quad (16)$$

将获取的用户特征向量 $\mathbf{m}_{ui}$ 、 $\mathbf{m}_{ai}$ 、 $\mathbf{m}_{ji}$ 通过融合层融合得到用户特征融合矩阵 $\mathbf{F}_{K \times 3i}$, 通过一层神经元数为 N 的全连接层得到用户特征融合矩

阵 $\mathbf{U}_N$, 其中 N 是潜在特征向量维度, 将 $\mathbf{U}_N$ 和 $\mathbf{l}_{ii}$ 通过 MLP 挖掘用户与项目间的非线性高低阶交互关系, 捕捉更抽象的特征^[7,16]。MLP 层的神经元个数设置为 $2^i \times N$, 其中 i 是 MLP 层数, N 是潜在特征向量维度。MLP 的输出 φ_{MLP} 为:

$$\varphi_{\text{MLP}} = a_L(\mathbf{W}_L^T(a_{L-1}(\cdots(\mathbf{W}_2^T(\mathbf{F}_{K \times 3i}, \mathbf{l}_{ii}) + \mathbf{b}_2) \cdots) + \mathbf{b}_{L-1}) + \mathbf{b}_L) \quad (17)$$

将 $\mathbf{m}_u$ 、 $\mathbf{m}_a$ 、 $\mathbf{m}_j$ 、 $\mathbf{l}_i$ 分别输入展开层得到用户特征向量 $\mathbf{m}_{ur}$ 、 $\mathbf{m}_{ar}$ 、 $\mathbf{m}_{jr}$ 和项目特征向量 $\mathbf{l}_{ir}$, 将用户特征向量通过融合层融合得到用户特征融合矩阵 $\mathbf{F}_{K \times 3r}$, 利用一层神经元数为 $N/2$ 的全连接层得到多特征融合潜在向量 $\mathbf{U}_{N/2}$, 将 $\mathbf{U}_{N/2}$ 和 $\mathbf{l}_{ir}$ 通过点映射到神经网络得到预测评分:

$$\varphi_{\text{GMF}} = \mathbf{U}_{N/2} \odot \mathbf{l}_{ir} \quad (18)$$

利用融合层将 φ_{MLP} 与 φ_{GMF} 进行特征融合。

(4) 输出层

通过一个全连接的隐藏层, 得到用户对项目的最终预测评分。

$$\tilde{Y} = a_{\text{FC}}(\mathbf{W}_{\text{FC}}^T[\varphi_{\text{MLP}}, \varphi_{\text{GMF}}] + \mathbf{b}_{\text{FC}}) \quad (19)$$

其中, φ_{MLP} 表示 MLP 网络模块的输出, φ_{GMF} 表示 GMF 网络模块的输出, $\mathbf{W}_{\text{FC}}^T$ 和 $\mathbf{b}_{\text{FC}}$ 分别为全连接层的连接权重和偏置, a_{FC} 为全连接层激活函数 Sigmoid。Sigmoid 函数将输入映射到区间 $[0, 1]$, 所以如果输出大于 0.5, 预测评分将为“1”, 否则为“0”, “1”表示评分 ≥ 3 分, “0”表示评分 < 3 分。

3 实验与性能分析

3.1 实验设置

实验使用 MovieLens-1M 公开数据集, MovieLens-1M 包含用户信息表 users.dat、评分信息表 ratings.dat 和电影信息表 movies.dat。电影评分信息表由 3 个表结合而成, 该表含有 6 040 名用户对 3 952 部电影的 100 万余条评分数据, 评级分数为 1~5, 数据稀疏度为 95.53%。用户年龄段 ID 信息见表 2, 职业 ID 信息见表 3。



表2 年龄段 ID 信息

ID	年龄段
0	<18
1	18~24
2	25~34
3	35~44
4	45~49
5	50~55
6	>56

表3 职业 ID 信息

ID	名称
0	other or not specified (其他或未指定)
1	academic/educator (学术/教育工作者)
2	artist (艺术家)
3	clerical/admin (文书/行政)
4	college/grad student (大学/研究生)
5	customer service (客户服务)
6	doctor/health care (医生/医疗保健)
7	executive/managerial (执行/管理)
8	farmer (农民)
9	homemaker (操持家务者)
10	K-12 student (K-12 学生)
11	lawyer (律师)
12	programmer (程序员)
13	retired (已退休人员)
14	sales/marketing (销售/营销)
15	scientist (科学家)
16	self-employed (个体经营者)
17	technician/engineer (技术员/工程师)
18	tradesman/craftsman (商人/工匠)
19	unemployed (失业人员)
20	writer (作家)

- 实验采用留一法^[27]进行模型训练评估, 将评分矩阵 $Y_{K \times W}$ 中所有评分大于或等于 3 的交互项标记为 1, 其余交互项标记为 0。采用一般策略^[28]划分训练集和测试集, 解决预测未交互项目收敛速度较慢的问题。该策略的核心思想是选取每个用户最近一次的评分交互记录作为测试正样本, 随机抽取所有项目样本中 99 个未交互记录作为测试负样本, 即测试集是每个用户的 100 个项目列表, 将用户其余交互信息作为训练

集。实验对每个用户的 100 个项目进行用户动态偏好预测, 将验证项目的预测值根据 Top- k 推荐列表排序。

- HMF 和对比模型均基于 TensorFlow2.5.0 实现。模型通过二元交叉熵损失函数和 Adam 梯度下降算法进行模型优化并反向更新参数, 批处理大小为 2^{13} , 初始学习率为 0.001, 输出层激活函数为 Sigmoid 函数, 将推荐预测问题作为二分类问题进行求解。

3.2 评价指标

模型推荐性能由归一化折损累计增益 (normalized discounted cumulative gain, NDCG) 和命中率 (hit ratio, HR)^[29]来衡量。

HR 是所有用户的平均值, 强调模型预测的准确性, 表示预测项目是否包含在 Top- k 推荐列表中, 即用户偏好的命中概率, 其计算式如下^[29]:

$$HR = \frac{1}{K} \sum_{i=1}^K \text{hits}(i) \quad (20)$$

其中, K 表示用户总数, 如果测试项目 i 在推荐列表中, $\text{hits}(i)$ 就为 1, 否则为 0。

NDCG 表示利用位置信息 i 进行计算的前 p 个位置, 累计得到的归一化增益, 强调预测项目的顺序性, i 小则值大, 预测项目在列表中的位置越靠前。其值由式 (21) 计算得到^[29]:

$$NDCG = \frac{1}{K} \sum_{i=1}^K \frac{1}{\text{lb}(p_i + 1)} \quad (21)$$

其中, K 表示用户总数, p_i 表示预测项目 i 在 Top- k 中的位置。

3.3 对比模型

实验将 HMF 与以下 5 种基准模型, 利用上述评价指标从模型综合性能、不同负样本采样数、不同潜在特征向量维度和不同 Top- k 4 个方面进行对比分析, 验证模型的可行性和有效性。

- MF^[7]是矩阵分解算法, 利用潜在特征向量维度将评分矩阵分解成用户子矩阵和项目子矩阵, 通过将子矩阵映射到潜在向量空间中

得到项目和用户的潜在向量,使用简单内积的方法拟合用户和项目间的交互关系。

- GMF^[7]是一种改进的矩阵分解算法,通过一层神经网络泛化矩阵分解模型,模型可有效获取用户和项目间的二阶非线性交互关系。
- MLP^[7]是由多层神经网络构成的模型,通过神经网络的非线性激活函数和深层网络结构挖掘用户和项目间的高层次交互特征。
- NCF^[7]是一种神经网络协同过滤模型,利用GMF和MLP学习用户和项目间的非线性交互关系,通过一个全连接层进行评分预测结果拼接。
- DMF^[16]是一种基于深度神经网络的矩阵分解算法,利用GMF非线性建模用户和项目间的交互,评分预测结果再通过MLP学习深层次交互特征,最后经隐藏层输出最终预测评分。

HMF是本文提出的模型,是多种神经网络融合传统协同过滤的混合模型,实现用户多层次潜在特征提取。通过GMF非线性构建用户和项目间的低阶交互,利用LSTM和MLP学习非线性深层次高阶交互特征,最后将高低阶交互结果进行融合输出评分。该模型由NCF^[7]、LSMF^[21]和基于多特征深度混合推荐模型DNNRec^[22]的思想结合而成。

3.4 实验结果与分析

为评估HMF模型性能、验证模型的有效性和鲁棒性,实验以训练损失(training loss)、HR@ k 和NDCG@ k 为评价指标,其中 $k=10$ 。基于MovieLens-1M数据集将HMF模型与MF、GMF、MLP、NCF、DMF模型进行比较,主要对比如下。

- 模型综合性能。
- 在不同潜在特征向量维度下多特征模型HMF、DMF与单特征模型的性能。
- 在不同负样本采样数下多特征模型HMF、DMF与单特征模型的性能。
- 在不同推荐列表参数 k 下多特征模型HMF、DMF与单特征模型的性能。

- 多特征HMF模型中不同MLP层数对模型性能的影响。

实验一 模型综合性能对比

为验证HMF模型性能,实验将HMF和MF、GMF、MLP、NCF、DMF在潜在特征向量维度为10的情况下进行综合性能对比分析,模型的综合性能对比如图3所示,多特征融合模型HMF、DMF与单特征模型综合性能对比如图4所示。






图3 模型的综合性能对比






图4 多特征融合模型 HMF、DMF 与单特征模型综合性能对比

(1) 多特征融合模型对比

当用户 ID、用户年龄段、用户职业和项目 ID 同时输入各模型时, 模型的综合性能对比如图 3 所示。由图 3 可以得出如下结论。

- MF 性能表现最差, HR@10 和 NDCG@10 都呈下降的趋势。GMF 在 MF 的基础上通过增加神经网络结构赋予模型学习非线性

交互关系的能力, 使得 GMF 模型性能优于 MF 模型, GMF 增长趋势缓慢, 收敛速度也较慢, 在第 50 次迭代 (iteration) 时得到较好的收敛。

- MLP 性能优于 MF。在第 10 次迭代之前, 训练损失呈下降趋势, 随着迭代次数的增加, HR@10 和 NDCG@10 都呈波动上升趋势。其模型收敛速度很慢, 抖动性较大, 模型性能不稳定。
- NCF 性能优于 MLP。NCF 在接近第 10 次迭代时达到最大值, 随着迭代次数增加, HR@10 和 NDCG@10 具有略微的下降趋势, 后期伴随较大的抖动性, 模型性能不稳定; 其原因是 NCF 子模型 MLP 带来较大的抖动性。
- DMF 性能优于 NCF。模型收敛速度比 NCF 快, 比 HMF 差; 随着迭代次数增加, HR@10 和 NDCG@10 比 NCF 高, 与 HMF 变化趋势相当, 都具有小幅波动性。
- HMF 性能优于 DMF。在第 10 次迭代之前, HMF 快速收敛, 随着迭代次数增加, HR@10 和 NDCG@10 在 [0.8, 0.9] 内微小波动。HMF 通过 GMF、LSTM 和 MLP 获取了用户高低阶特征和长短期偏好, 使得模型性能更优。鉴于 MLP 在多特征融合时, 抖动现象较严重, 实验时, 尝试在 MLP 基础上增加批标准化 (batch normalization, BN) 层和丢弃 (dropout) 层, 实验效果较差, 抖动现象更严重。

从以上实验结果可知, 多特征融合时, 低阶网络无法捕获更多高阶特征交互信息, MF、GMF 性能均低于 NCF、DMF 和 HMF。

(2) 多特征融合模型 HMF、DMF 与单特征模型综合性能对比

从图 3 可知, 在用户多特征融合时, HMF、DMF 模型表现较好; 为比较多特征融合模型与单

特征模型的推荐性能,实验只选取了多特征融合模型 HMF、DMF 与单特征模型进行比较。为区别单特征模型 HMF、DMF,多特征融合模型命名为 mHMF、mDMF,由图 4 可知:

- mHMF 相对于其他所有模型,其总体性能最优;
- 单特征模型中,MF 收敛性最差;从图 4(b)放大处可知,GMF 在第 10 次迭代之前 HR@10 和 NDCG@10 都呈上升趋势,接近第 30 次迭代时达到稳定,与 NCF、MLP 和 HMF 相当,其原因是 GMF 点乘可保留原始数据特征,与神经网络学习的特征相当;DMF 收敛速度最快,第 10 次迭代之后,性能有所下降,其原因是预测评分结果经多个 MLP 层,会产生过拟合现象,影响实验结果。

从以上实验结果可知,HMF 在多特征和单特征情况下,总体性能较好,说明模型泛化性强。

实验二 多特征融合模型 HMF、DMF 与单特征模型在不同情况下的性能对比

(1) 不同潜在特征向量维度下的模型性能分析

为分析不同潜在特征向量维度下模型的推荐性能,实验在潜在特征向量维度为 10、20、30、40、50、60、70 和 80 的情况下进行模型训练,不同潜在特征向量维度下模型的 HR@10 和 NDCG@10 如图 5 所示。

多特征模型迭代训练 20 次,单特征模型迭代训练 10 次。由图 5 可以得出如下结论。

- 单特征模型性能指标随着潜在特征向量维度的增加而提升,达到最佳潜在特征向量维度后,由于维度过大模型过拟合,模型推荐性能降低。这说明更大的潜在向量特征维度可提取更完整的用户和项目的特征信息,特征表示更具体,模型预测精度得到提高。
- mHMF 性能随着潜在特征向量维度的增加

而提升,潜在特征向量维度增加到 40 后,性能提升缓慢,具有微小波动性;当潜在特征向量维度增加到 70 时,其性能最佳。mDMF 随潜在特征向量维度增加时,性能表现具有很大的波动性,性能不稳定。





图 5 不同潜在特征向量维度下模型的 HR@10 和 NDCG@10

从以上实验结果可知,HMF 在多特征和单特征情况下,随着潜在特征向量的增加,推荐性能先提高然后在一定范围内小幅波动,说明模型稳定性强。



(2) 不同负样本采样数下的模型性能分析

为分析不同负采样数对模型推荐性能的影响,实验在整数范围 1~10 的负采样数下进行模型训练,不同负样本采样数下模型的 HR@10 和 NDCG@10 如图 6 所示。




图 6 不同负样本采样数下模型的 HR@10 和 NDCG@10

- 除 mDMF 外,所有模型性能随负采样数增加而逐步提高,达到最佳负采样数后继续增加负采样数,由于负采样数过多,样本分布不均衡,正采样损失被淹没,模型推荐性能缓慢降低。

- mDMF 随负采样数增加时,性能波动下降,性能不稳定。

从以上实验结果可知,在真实推荐场景中,需适当增加采样数缓解数据稀疏性,从提高模型推荐预测精度。mHMF 的推荐性能在负采样数为 3 时达到最佳。

(3) 不同推荐列表参数 k 下的模型性能分析

为分析不同推荐列表参数 k 下模型的推荐性能,实验在推荐列表参数 k 为 1~10 的情况下进行模型训练,不同推荐列表参数 k 下模型的 HR@10 和 NDCG@10 如图 7 所示。




图 7 不同推荐列表参数 k 下模型的 HR@10 和 NDCG@10

潜在特征向量维度取 10，多特征模型迭代训练 20 次；单特征模型迭代训练 10 次。由图 7 可以得出如下结论：所有模型推荐性能都随 k 增大逐步提高。mmHMF 表现最优，mDMF 表现最差。由图 4 (a) 和图 4 (b) 可知，mDMF 在 $k=10$ 时命中率和增益在 0.8 上下波动，从初始 k 值较小时开始训练，随着 k 值增大，其性能模型达不到预期效果，原因是其模型性能不稳定。

从以上实验结果可知，mHMF 在不同 k 值下均能获取较全面的高低阶交互特征和用户长短期偏好信息，预测更精准，说明模型具有较好的普适性和鲁棒性。

实验三 mHMF 模型中 MLP 层数对模型性能的影响

为研究 MLP 层数对模型推荐性能的影响，实验设计 MLP 层数为 0~8、潜在特征向量维度为 10~80，不同 MLP 层数下的 HR@10、NDCG@10 分别见表 4、表 5。每种情况都迭代训练 20 次，

加粗部分数据可显示其变化情况。

- 随 MLP 层数的增加，模型的 HR@10 和 NDCG@10 指标波动提升，模型推荐效果逐步改善。
- 当潜在特征向量维度为 10 时，模型性能波动性较大，HR@10、NDCG@10 随 MLP 层数变化呈锯齿状波动上升；当特征向量维度为 20、40、60、70 和 80，MLP 层数为 1 时，HR@10、NDCG@10 最小；当特征向量维度为 30、MLP 层数为 2 时，HR@10 最小，当特征向量维度为 30、MLP 层数为 0 时，NDCG@10 最小。
- 当潜在特征向量维度为 50 时，层数为 7 之前，模型性能随层数增加而逐步提高，在层数为 7 时，性能最好，7 层后，性能下降。

从以上实验结果可知，MLP 达到一定层数后，模型的性能指标提升幅度降低甚至下降。MLP 层数过多，导致模型训练过拟合，束缚了模型性能。

表 4 不同 MLP 层数下的 HR@10

潜在特征向量维度/维	MLP0	MLP1	MLP2	MLP3	MLP4	MLP5	MLP6	MLP7	MLP8
10	0.708 4	0.578 9	0.785 4	0.569 6	0.804 3	0.742 0	0.857 9	0.949 8	0.871 2
20	0.734 4	0.685 1	0.828 3	0.844 7	0.892 4	0.948 0	0.956 1	0.975 8	0.979 1
30	0.691 0	0.769 0	0.678 9	0.921 8	0.927 3	0.953 8	0.968 7	0.980 4	0.977 6
40	0.710 2	0.594 3	0.800 0	0.886 6	0.943 4	0.971 5	0.964 4	0.980 3	0.975 8
50	0.688 8	0.776 0	0.889 9	0.922 4	0.974 8	0.977 6	0.980 5	0.983 1	0.980 0
60	0.706 0	0.596 2	0.879 0	0.974 2	0.970 2	0.976 1	0.980 2	0.978 9	0.980 6
70	0.735 6	0.659 6	0.958 9	0.973 6	0.972 4	0.981 4	0.982 1	0.978 9	0.980 3
80	0.726 7	0.615 4	0.890 9	0.952 8	0.974 5	0.979 9	0.978 4	0.981 1	0.983 4

表 5 不同 MLP 层数下的 NDCG@10

潜在特征向量维度/维	MLP0	MLP1	MLP2	MLP3	MLP4	MLP5	MLP6	MLP7	MLP8
10	0.605 7	0.450 5	0.727 5	0.470 0	0.757 0	0.717 0	0.843 0	0.940 9	0.860 2
20	0.651 6	0.595 7	0.785 1	0.841 9	0.881 5	0.939 9	0.948 8	0.968 8	0.972 5
30	0.596 5	0.709 0	0.625 0	0.912 0	0.919 0	0.945 3	0.960 6	0.972 5	0.969 0
40	0.627 0	0.499 3	0.774 2	0.871 0	0.933 7	0.962 7	0.956 0	0.972 7	0.969 1
50	0.612 8	0.741 6	0.874 8	0.913 3	0.967 33	0.969 9	0.973 1	0.974 9	0.973 5
60	0.640 7	0.508 1	0.864 4	0.966 7	0.962 5	0.968 2	0.973 8	0.972 2	0.974 3
70	0.673 6	0.599 8	0.948 9	0.968 3	0.965 0	0.973 1	0.975 1	0.971 5	0.973 5
80	0.672 7	0.542 1	0.872 4	0.944 3	0.967 8	0.973 6	0.971 4	0.974 3	0.975 5



同时,过多的MLP层数使得模型的参数数量和复杂度呈指数式增长,从而导致训练时间过长,模型难以收敛。

4 结束语

针对推荐系统在实际推荐场景中未融合用户多个特征挖掘更深层次交互关系的问题,提出一种基于用户多特征融合的混合推荐模型HMF。该模型将用户ID、用户年龄、用户职业和项目ID原始数据,经嵌入层映射成相同潜在特征向量维度的特征数据;利用LSTM从多维度(ID、年龄、职业)获取用户与项目间的时序特征,经融合层融合所有时序特征,通过多层MLP挖掘用户年龄、职业与项目间的交互关系;最后将GMF获得的简单非线性低阶交互关系与时序非线性高阶交互关系融合,经神经元为1的一个全连接层得出最终预测评分。在HMF中,因为训练集和验证集的用户是相同的,无用户冷启动问题;主要针对不同的项目,对未评分的项目进行评分预测,有效解决了项目冷启动问题。相比NCF模型,HMF主要通过增强用户特征缓解项目的冷启动问题,实验表明,HMF的推荐准确度明显提高,效果突出。在多特征融合时,本文考虑年龄和职业的潜在特征向量维度与用户总体的潜在特征向量维度是相等的,还可从不同向量维度的角度分析年龄和职业对项目评分的具体影响。

参考文献:

- [1] LIN Y. A neural network-based approach to personalized recommendation of digital resources[J]. Computer Informatization and Mechanical System, 2022, 5(4).
- [2] NAN X, KANATO K, WANG X L. Design and implementation of a personalized tourism recommendation system based on the data mining and collaborative filtering algorithm[J]. Computational Intelligence and Neuroscience, 2022: 1424097.
- [3] ZHAN Z, XU B G. Analyzing review sentiments and product images by parallel deep nets for personalized recommendation[J]. Information Processing & Management, 2023, 60(1): 103166.
- [4] HUANG Y, GADDE R S K, LOPES S, et al. Improving occupant thermal comfort through personalized space recommendation[J]. Journal of Computing in Civil Engineering, 2023, 37(1): 04022053.
- [5] PANG N. A personalized recommendation algorithm for semantic classification of new book recommendation services for university libraries[J]. Mathematical Problems in Engineering, 2022: 1-8.
- [6] AFOUDI Y, LAZAAR M, ACHHAB M A. Hybrid recommendation system combined content-based filtering and collaborative prediction using artificial neural network[J]. Simulation Modelling Practice and Theory, 2021(113): 102375.
- [7] HE X N, LIAO L Z, ZHANG H W, et al. Neural collaborative filtering[C]//Proceedings of the 26th International Conference on World Wide Web. New York: ACM Press, 2017: 173-182.
- [8] DO P M T, NGUYEN T T S. Semantic-enhanced neural collaborative filtering models in recommender systems[J]. Knowledge-Based Systems, 2022(257): 109934.
- [9] RENDLE S. Factorization machines with libFM[J]. ACM Transactions on Intelligent Systems and Technology, 2012, 3(3): 1-22.
- [10] SINGH R K, SINGH P K, SINGH J P, et al. Utilizing alike neighbor influenced similarity metric for efficient prediction in collaborative filter-approach-based recommendation system[J]. Applied Sciences, 2022, 12(22): 11686.
- [11] WANG Y, ZHAO X H, ZHANG Z Q, et al. A collaborative filtering algorithm based on item labels and Hellinger distance for sparse data[J]. Journal of Information Science, 2022, 48(6): 749-766.
- [12] DUAN R, JIANG C Q, JAIN H K. Combining review-based collaborative filtering and matrix factorization: a solution to rating's sparsity problem[J]. Decision Support Systems, 2022(156): 113748.
- [13] SEJWAL V K, ABULAIISH M, JAHIRUDDIN. CRecSys: a context-based recommender system using collaborative filtering and LOD[J]. IEEE Access, 2020(8): 158432-158448.
- [14] NGUYEN S T, KWAK H Y, LEE S Y, et al. Featured hybrid recommendation system using stochastic gradient descent[J]. International Journal of Networked and Distributed Computing, 2021, 9(1): 25.
- [15] KIM D, PARK C, OH J, et al. Convolutional matrix factorization for document context-aware recommendation[C]//Proceedings of the 10th ACM Conference on Recommender Systems. New York: ACM Press, 2016: 233-240.
- [16] 田震, 潘腊梅, 尹朴, 等. 深度矩阵分解推荐算法[J]. 软件学报, 2021, 32(12): 3917-3928.
TIAN Z, PAN L M, YIN P, et al. Deep matrix factorization recommendation algorithm[J]. Journal of Software, 2021, 32(12): 3917-3928.
- [17] 王骏, 虞歌. 基于改进神经协同过滤模型的电影推荐系统[J]. 计算机工程与设计, 2020, 41(7): 2069-2075.
WANG J, YU G. Movie recommendation system based on improved neural collaborative filtering model[J]. Computer Engineering and Design, 2020, 41(7): 2069-2075.


- [18] 李浩, 张亚钊, 康雁, 等. 融合循环知识图谱和协同过滤电影推荐算法[J]. 计算机工程与应用, 2020, 56(2):106-114.
LI H, ZHANG Y C, KANG Y, et al. Fusion recurrent knowledge graph and collaborative filtering movie recommendation algorithm[J]. Computer Engineering and Applications, 2020, 56(2): 106-114.
- [19] 高茂庭, 徐彬源. 基于循环神经网络的推荐算法[J]. 计算机工程, 2019, 45(8): 198-202, 209.
GAO M T, XU B Y. Recommendation algorithm based on recurrent neural network[J]. Computer Engineering, 2019, 45(8): 198-202, 209.
- [20] 李利杰, 张君华. 基于循环神经网络和全局化领域的推荐算法[J]. 计算机与数字工程, 2022, 50(8): 1676-1679, 1701.
LI L J, ZHANG J H. Recommendation algorithm based on recurrent neural network and global domain[J]. Computer and Digital Engineering, 2022, 50(8): 1676-1679, 1701.
- [21] 田晓婧, 谢颖华. 融合长短期记忆网络与广义矩阵分解的神经协同过滤模型[J]. 计算机系统应用, 2022, 31(1): 190-194.
TIAN X J, XIE Y H. Neural collaborative filtering model integrating LSTM and generalized matrix factorization[J]. Computer Systems & Applications, 2022, 31(1): 190-194.
- [22] KIRAN R, KUMAR P, BHASKER B. DNNRec: a novel deep learning based hybrid recommender system[J]. Expert Systems With Applications, 2020(144): 113054.
- [23] TANG X L, WANG T Y, YANG H Z, et al. AKUPM: attention-enhanced knowledge-aware user preference model for recommendation[C]//Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: ACM Press, 2019: 1891-1899.
- [24] 秦川, 祝恒书, 庄福振, 等. 基于知识图谱的推荐系统研究综述[J]. 中国科学: 信息科学, 2020, 50(7): 937-956.
QIN C, ZHU H S, ZHUANG F Z, et al. A survey on knowledge graph-based recommender systems[J]. SCIENTIA SINICA Informationis, 2020, 50(7): 937-956.
- [25] WANG H W, ZHANG F Z, WANG J L, et al. RippleNet: propagating user preferences on the knowledge graph for recommender systems[C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2018: 417-426.
- [26] MA M, CAO Q, LIU X Y. A graph convolution collaborative filtering integrating social relations recommendation method[J]. Applied Sciences, 2022, 12(22): 11653.
- [27] BAYER I, HE X N, KANAGAL B, et al. A generic coordinate descent framework for learning from implicit feedback[C]//Proceedings of the 26th International Conference on World Wide Web. New York: ACM Press, 2017: 1341-1350.
- [28] WAKITA Y, OKU K, KAWAGOE K. Toward fashion-brand recommendation systems using deep-learning: preliminary analysis[J]. International Journal of Knowledge Engineering, 2016, 2(3): 128-131.

- [29] HE X N, CHEN T, KAN M Y, et al. TriRank: review-aware explainable recommendation by modeling aspects[C]//Proceedings of the 24th ACM International on Conference on Information and Knowledge Management. New York: ACM Press, 2015: 1661-1670.

[作者简介]



卢敏(1964—), 男, 江西理工大学教授, 主要研究方向为深度学习和智能通信、电子材料和设备。



胡娟(1997—), 女, 江西理工大学硕士生, 主要研究方向为深度学习和智能通信。



张先超(1984—), 男, 博士, 浙江省医学电子与数字健康重点实验室研究员, 主要研究方向为无线网络资源管理、人工智能等。



丁伟健(1993—), 男, 江西理工大学硕士生, 主要研究方向为深度学习和智能通信。



乐光学(1963—), 男, 博士, 嘉兴学院信息科学与工程学院、浙江省医学电子与数字健康重点实验室教授, 主要研究方向为多云融合与协同服务、边缘计算、深度学习、智能通信等。