

基于LSTM与深度矩阵分解的推荐融合模型

丁伟健^{1,3}, 卢敏¹, 杨忠明^{1,3}, 陈丽萍²

(1. 江西理工大学理学院, 江西赣州 341000; 2. 嘉兴南湖学院图书馆, 浙江嘉兴 314001;
3. 浙江省医学电子与数字健康重点实验室, 浙江嘉兴 314000)

摘要: 针对现实推荐场景中多数推荐算法忽略用户偏好动态变化的时效因素, 导致模型性能受限的问题, 提出一种基于LSTM和深度矩阵分解的推荐融合模型LDFMF。该模型通过广义矩阵分解学习用户和项目间非线性低阶特征, 运用多层感知机学习用户和项目间非线性高阶特征, 获取用户长期动态偏好, 利用LSTM对时间序列的强拟合能力, 获取用户短期动态偏好。为验证LDFMF模型的有效性和可行性, 在公开数据集MovieLens-1M和Pinterest上进行对比实验。仿真实验表明, LDFMF模型的HR@10和NDCG@10指标相比传统MF算法分别提升了0.103 4和0.132 2、0.118 1和0.101 8; 相比DMF模型分别提升了0.022 8和0.032 3、0.016 9和0.013 5, 推荐性能显著提升。

关键词: 推荐融合; 广义矩阵分解; 多层感知机; 跳跃连接; 长短期记忆网络

DOI: 10.11907/tjdk.231826

开放科学(资源服务)标识码(OSID):



中图分类号: TP391.3

文献标识码: A

文章编号: 1672-7800(2024)009-0041-07

Recommendation Fusion Model Based on LSTM and Deep Matrix Factorization

DING Weijian^{1,3}, LU Min¹, YANG Zhongming^{1,3}, CHEN Liping²

(1. College of Science, Jiangxi University of Science and Technology, Ganzhou 341000, China; 2. Library, Jiaxing Nanhu University, Jiaxing 314001, China; 3. Key Laboratory of Medical Electronics and Digital Health of Zhejiang Province, Jiaxing 314000, China)

Abstract: Aiming at the problem that most recommendation algorithms in real recommendation scenarios ignore the timeliness factors of dynamic changes in user preferences, resulting in limited model performance, a recommendation fusion model based on LSTM and deep matrix factorization (Long Short-Term Memory Fusion Deep Matrix Factorization, LDFMF) is proposed. The model uses generalized matrix factorization to learn nonlinear low-order features between users and items, uses multi-layer perceptron to learn nonlinear high-order features between users and items, and obtains users' long-term dynamic preferences. LSTM's strong fitting ability to time series is used to obtain users' short-term dynamic preferences. In order to verify the effectiveness and feasibility of the LDFMF model, comparative experiments are carried out on the public datasets MovieLens-1M and Pinterest. The simulation results show that the HR@10 and NDCG@10 indexes of the LDFMF model are improved by 0.103 4 and 0.132 2, 0.118 1 and 0.101 8, respectively, compared with the traditional MF algorithm. Compared with the DMF model, it is improved by 0.022 8 and 0.032 3, 0.016 9 and 0.013 5, respectively, the recommendation performance is significantly improved.

Key Words: recommendation fusion; generalized matrix factorization; multilayer perceptron; skip connections; long short-term memory

0 引言

随着互联网、人工智能等技术的飞速发展, 个性化推

荐系统备受重视。个性化推荐根据用户和项目间历史交互信息挖掘用户对项目的偏好, 向用户推荐项目^[1]。推荐系统一般分为基于项目内容和协同过滤两种算法模型^[2]。这类算法通过内容属性或历史行为数据计算用户喜好, 原

收稿日期: 2023-09-19

扫描二维码阅读全文:



基金项目: 国家自然科学基金项目(U19B2015)

作者简介: 丁伟健(1993-), 男, CCF会员, 江西理工大学理学院硕士研究生, 研究方向为深度推荐系统与智能通信; 卢敏(1964-), 男, 硕士, 江西理工大学理学院教授, 研究方向为智能通信及电子材料器件; 杨忠明(1998-), 男, 江西理工大学理学院硕士研究生, 研究方向为移动云计算; 陈丽萍(1970-), 女, 嘉兴南湖学院图书馆馆员, 研究方向为文献智能检索分析与个性化推荐。本文通讯作者: 陈丽萍。

理简单,复杂度低,却忽略了非线性高阶交互特征。深度学习技术是非线性高阶交互特征获取的有效方法之一,在推荐领域获得成功^[3-6]。但以上研究不能同时获取用户和项目间非线性高低阶交互特征和用户长短期偏好。鉴于此,本文提出一种基于长短期记忆网络(Long Short-Term Memory, LSTM)和深度矩阵分解的推荐融合模型(Long Short-Term Memory Fusion Deep Matrix Factorization, LFD MF),通过广义矩阵分解(Generalized Matrix Factorization, GMF)、多层感知机(Multilayer Perceptron, MLP)、LSTM同时捕获用户和项目间非线性高低阶特征和长短期动态偏好,在全连接层拼接特征预测评分,实现精准动态推荐。

1 相关工作

矩阵分解(Matrix Factorization, MF)通过隐向量拆分用户评分矩阵,用内积拟合用户与项目间的交互关系^[7-8]。为了提升性能,研究人员对MF进行了改进,高玉凯等^[9]通过多层概率矩阵获取多维度隐特征,利用迭代决策树计算用户偏好,优化精度。AtifSM等^[10]提出低秩校正的非负奇异值分解(SVD)方法,低秩结构显著减少初始误差以提升准确度。但是,以上算法只能建模线性交互关系,无法学习非线性交互关系。

深度神经网络因其突出的非线性特征学习、提取能力,使更多的研究在推荐领域结合深度学习技术。Zhang等^[11]改进传统矩阵因式分解获取潜在特征,作为深度神经网络(Deep Neural Network, DNN)的输入优化预测评分。He等^[12]提出神经协同过滤模型NeuMF,通过GMF、MLP获取非线性高低阶特征,泛化能力和准确度更优。Ma等^[13]利用偏置奇异值分解融合偏差和深度矩阵分解,对偏置进行特征表示,优化特征向量。田震等^[14]提出一种融合GMF和MLP的深度矩阵分解模型(Deep Matrix Factorization, DMF),在GMF上添加多层神经网络学习用户和项目隐向量特征间的交互关系,提升模型非线性高阶建模能力和鲁棒性。纪强等^[15]提出一种基于循环神经网络(Recurrent Neural Network, RNN)的模型,通过RNN捕获历史交互中短期动态偏好,效果更优。

基于深度学习的推荐算法利用深度学习学习非线性交互关系、处理时序数据和深层次特征提取等方面的能力,极大提升推荐性能。而如何同时获取用户和项目间高低阶特征和长短期动态偏好是值得思考的问题。本文构建LFD MF模型获取非线性高低阶交互特征和用户长短期动态偏好,提高预测精度。

2 基于LSTM与深度矩阵分解的推荐融合模型

假设有用户集 U 和项目集 I ,现给定用户 $u \in U$ 、项目

$i \in I$,其中,用户 u 未与项目 i 产生交互。推荐融合模型通过LSTM对时序评分数据的依赖关系和强拟合能力获取用户短期动态偏好,GMF和MLP获取用户和项目间非线性高低阶交互关系和用户长期动态偏好,进而预测用户 u 对项目 i 的评分。

2.1 广义矩阵分解

GMF将用户和项目原始数据进行One-Hot编码,与潜在特征矩阵相乘得到用户特征向量 p_u 和项目特征向量 q_i ,通过一层神经网络映射到输出层,映射关系定义为^[11]:

$$\Phi_1(p_u, q_i) = p_u \odot q_i \quad (1)$$

$$\hat{y}_{ui} = a_{out}(h^T(p_u \odot q_i)) \quad (2)$$

其中, Φ_1 表示映射函数, \odot 表示点积, \hat{y}_{ui} 表示预测评分, a_{out} 表示激活函数, h^T 表示权重。

2.2 多层感知机

MLP引入多层隐藏层学习用户和项目间非线性高阶交互关系,获取深层交互特征,定义为^[14]:

$$\begin{cases} Z_1 = \Phi_1(p_u, q_i) \\ Z_2 = \Phi_2(Z_1) = a_2(Z_1 W_2^T + b_2) \\ \dots \\ Z_L = \Phi_L(Z_{L-1}) = a_L(Z_{L-1} W_L^T + b_L) \\ \hat{y}_{ui} = \delta(h^T Z_L) \end{cases} \quad (3)$$

其中, Φ_i 表示第 i 层映射函数, a_i, W_i^T, b_i 表示第 i 层激活函数、权重和偏置, Z_i 表示第 i 层输出; δ, h^T 表示输出层激活函数和权重。

2.3 长短期记忆网络

LSTM可以有效建模时序数据的长短期依赖关系,挖掘上下文关系,创建用户、项目状态进行自回归运算,分析历史交互数据。LSTM结构如图1所示^[16]。




Fig. 1 LSTM structure

图1 LSTM结构

LSTM状态更新满足以下公式^[16]:

$$f_t = \sigma(W_f[h_{t-1}, x_t] + b_f) \quad (5)$$

$$i_t = \sigma(W_i[h_{t-1}, x_t] + b_i) \quad (6)$$

$$c_t = f_t \cdot c_{t-1} + i_t \cdot \tanh(W_c[h_{t-1}, x_t] + b_c) \quad (7)$$

$$o_t = \sigma(W_o[h_{t-1}, x_t] + b_o) \quad (8)$$

$$h_t = o_t \cdot \tanh(c_t) \quad (9)$$

其中, f_t, i_t 和 o_t 表示遗忘门、输入门和输出门, c_t 表示 t

时刻隐藏层神经元状态, 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 时刻输入的拼接向量, W 表示权重, b 表示偏置。

2.4 LFDMMF 设计

为了同时学习用户和项目间非线性高低阶交互特征和长短期动态偏好, 本文提出 LFDMMF 模型, 该框架如图 2 所示。

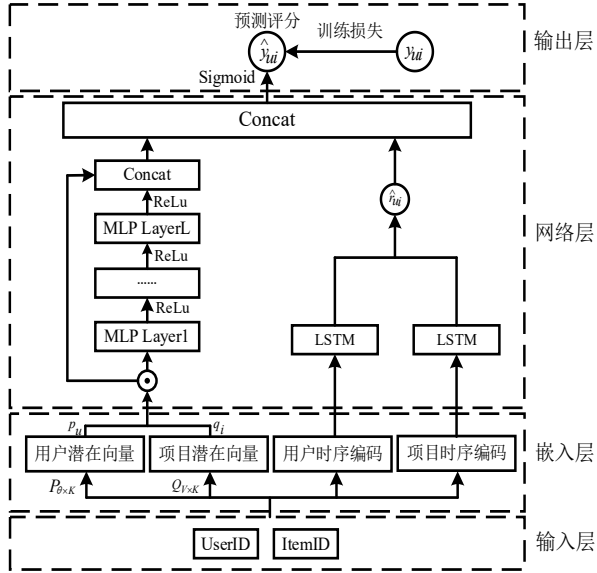


Fig. 2 LFDMMF model

图2 LFDMMF 模型

(1) 输入层。通过 One-Hot 编码为用户、项目 ID 创建二值表示, 获取高维稀疏编码数据, 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 M 和项目数目 N 。

(2) 嵌入层。嵌入层将独热编码与潜在特征矩阵相乘映射到低维紧密向量空间, 得到用户潜在特征向量 p_u 和项目潜在特征向量 q_i 。

(3) 网络层。通过 GMF 和 MLP 学习用户和项目间非线性高低阶交互特征和用户长短期动态偏好, 定义为^[11]:

$$\varphi_{GMF} = p_u^c \odot q_i^c \quad (10)$$

$$\varphi_{MLP} = a_L (W_L^T (a_{L-1} (\dots (W_2^T (p_u^c \odot q_i^c) + b_2) \dots) + b_{L-1}) + b_L) \quad (11)$$

根据上一时刻状态通过 LSTM 预测 t 时刻状态, 然后预测 $t+1$ 时刻用户和项目交互概率^[17]有:

$$U_{u,t+1} = g(U_{u,t}, \{r_{uilt}\}) \quad (12)$$

$$I_{i,t+1} = h(I_{i,t}, \{r_{uilt}\}) \quad (13)$$

t 时刻的预测分数表示为:

$$\hat{r}_{uilt} = f(U_{u,t}, I_{i,t}) \quad (14)$$

其中, p_u^c 和 q_i^c 表示 GMF 的嵌入矩阵, r_{uilt} 和 \hat{r}_{uilt} 表示用户 u 在时刻 t 对项目 i 的实际评分和预测评分。

(4) 输出层。拼接 GMF、MLP 和 LSTM 输出的特征向量, 经全连接层进行评分预测。

$$\hat{y}_{ui} = a_{FC} (W_{FC}^T [\varphi_{GMF}, \varphi_{MLP}, \varphi_{LSTM}] + b_{FC}) \quad (15)$$

其中, φ_{LSTM} 表示 LSTM 网络输出, W_{FC}^T 和 b_{FC} 为全连接层的权重和偏置, a_{FC} 为全连接层激活函数。

3 实验与性能分析

3.1 实验设置

(1) 数据集。实验在 MovieLens-1M (<https://grouplens.org/datasets/movielens/1m/>) 和 Pinterest (<https://sites.google.com/site/xueatalephabeta/academic-projects>) 公开数据集上验证 LFDMMF 模型的可靠性和有效性。其中, MovieLens-1M 数据集, 用户数 6 040, 项目数 3 706, 交互次数 1 000 209, 稀疏度 95.53; Pinterest 数据集用户数 55 187, 项目数 9 916, 交互次数 1 500 809, 稀疏度 99.73%。

(2) 训练集和测试集。实验采用留一法^[18]将评分矩阵 $Y_{\theta \times v}$ 中的评分交互项记为 1, 未交互项记为 0; 采用一般策略^[19]选取每个用户最近一次的评分交互记录为测试正样本, 从所有项目样本中随机抽取 99 个未交互的负样本为测试集, 其余交互信息为训练集。

(3) 实验配置。模型均基于 Tensorflow 2.0 实现, 损失函数为 Binary Cross-Entropy, 优化器为 Adam, 批处理大小为 2^{13} , 初始学习率为 0.001。

3.2 评价指标

推荐性能由 NDCG (normalized discounted cumulative gain) 和 HR (hit ratio) 加以衡量^[20], 在实验中将排名列表 K 截断为 10。

HR 强调预测准确性, 表明预测项目是否包含在推荐列表中, 描述为用户偏好的命中概率^[20], 其计算公式如式 (16) 所示。

$$HR@K = \frac{1}{N} \sum_{i=1}^N hits(i) \quad (16)$$

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

NDCG 强调预测顺序性, 值越大, 表示预测项目在列表中的位置越靠前。其值由式 (17) 计算得到^[20]。

$$NDCG = \frac{1}{N} \sum_{i=1}^N \frac{1}{\log_2(p_i + 1)} \quad (17)$$

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

3.3 对比模型分析

实验将本文模型与以下 5 种基准模型进行比较, 以 Training loss、HR@10 和 NDCG@10 为评价指标。

MF 引入潜在特征因子, 通过内积拟合用户和项目间的交互关系^[7]。

GMF 通过神经网络改进矩阵分解, 获取用户和项目间二阶非线性交互关系^[11]。

MLP 通过深层网络结构建模用户和项目间非线性高阶特征交互^[11]。

NeuMF 利用 GMF 和 MLP 学习非线性高低阶交互, 隐藏层拼接特征, 推荐项目^[11]。

DMF 通过 GMF 建模低阶交互关系, 经过 MLP 学习高阶交互特征, 隐藏层预测评分^[15]。

3.4 实验结果与分析

为全面评估模型性能, 实验主要从模型推荐性能、

LFDMF 消融实验、负采样数、潜在向量维度、MLP 层数方面对模型进行分析。

3.4.1 实验一: 模型性能分析

实验对比分析 MF、GMF、MLP、NeuMF、DMF 和 LFDMF 模型 Training loss、HR@10 和 NDCG@10 的性能表现, 实验结果如图 3 和图 4 所示。




Fig. 3 Performance of each model on the MovieLens-1M dataset

图3 MovieLens-1M数据集下各模型性能




Fig. 4 Performance of each model on the Pinterest dataset

图4 Pinterest数据集下各模型性能

从图 3、图 4 可以看出, 各模型性能比较结果为 LFDMF > DMF > NeuMF > MLP > GMF > MF。

(1) NeuMF 和 DMF 的性能优于 MLP, MF 性能表现最差。GMF 通过神经网络学习非线性关系, 性能优于 MF, 但低阶网络无法捕获高阶特征, 因而性能低于 MLP、NeuMF、DMF 和 LFDMF; NeuMF、DMF 基于 GMF、MLP 获取非线性高低阶特征, 性能更优。

(2) LFDMF 性能优于 NeuMF 和 DMF。LFDMF 通过融合 LSTM、MLP、GMF 同时获取用户长短期偏好和非线性高低阶特征, 特征更全面, 性能表现最优, 验证了模型有效性。

3.4.2 实验二: LFDMF 消融实验

为分析各模块对模型的影响, 实验对 MF、LSTM、DMF 和 LFDMF 模型进行 30 轮训练, 取不同模型结果的平均值如表 1、表 2 所示。

可以看出, LFDMF 性能均优于 DMF、LSTM、MF。①对于 MF 模型, LFDMF、DMF、LSTM 在 MovieLens-1M 数据集

Table 1 HR@10 and NDCG@10 for each module on the MovieLens-1M dataset

表 1 MovieLens-1M 数据集下各模块 HR@10 和 NDCG@10

模型	HR@10	NDCG@10
MF	0.587 9	0.282 7
LSTM	0.641 6	0.365 8
DMF	0.668 5	0.382 6
LFDMF	0.691 3	0.414 9

Table 2 HR@10 and NDCG@10 for each module on the Pinterest dataset

表 2 Pinterest 数据集下各模块 HR@10 和 NDCG@10


模型	HR@10	NDCG@10
MF	0.742 1	0.416 5
LSTM	0.826 1	0.493 4
DMF	0.843 3	0.504 8
LFDMF	0.860 2	0.518 3

上的 HR@10 和 NDCG@10 分别提升了 0.103 4、0.080 6、0.053 7 和 0.132 2、0.099、0.083 1; 而在 Pinterest 数据集上

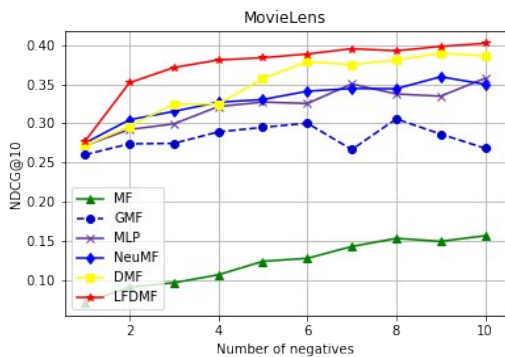
HR@10 和 NDCG@10 分别提升了 0.118 1、0.101 2、0.084 和 0.101 8、0.088 3、0.076 9; ②对于单一模型 LSTM、DMF, LFD MF 在 MovieLens-1M 数据集上 HR@10 和 NDCG@10 分别提升了 0.045 3、0.022 8 和 0.049 1、0.032 3; 而在 Pinterest 数据集上 HR@10 和 NDCG@10 分别提升了 0.034 1、0.016 9 和 0.024 9、0.013 5。

3.4.3 实验三: 不同负样本采样数下的性能分析

为评价负采样数对模型的影响, 实验范围设置 1~10 的 10 种负采样数进行训练, 实验结果如图 5 和图 6 所示。



(a) HR@10
(a) 命中率@10



(b) NDCG@10
(b) 归一化折损累计增益@10

Fig. 5 HR@10 and NDCG@10 of models with different negative sampling numbers on the MovieLens-1M dataset


图 5 MovieLens-1M 数据集下不同负采样数模型的 HR@10 和 NDCG@10

从图 5、图 6 可以看出: ①训练稀疏数据集时增加训练负采样数, 评价指标逐步增长; ②加入负样本, 只需更新部分权重, 减少计算量, 模型收敛快; 当负采样数增加到一定值后, 过多负采样数导致样本不均衡, 正样本损失被淹没, 模型过拟合, 性能有所下降。

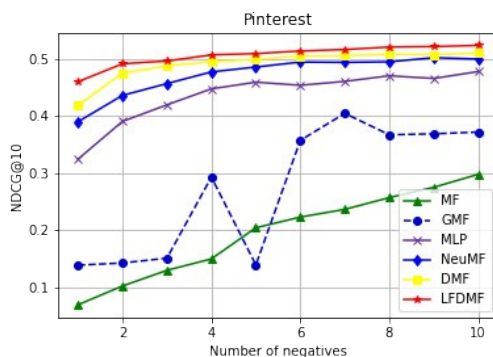
LFD MF 在 MovieLens-1M 和 Pinterest 数据集上最优负采样数分别为 7、9。

3.4.4 实验四: 不同潜在向量维度下模型的性能分析

为分析潜在向量对模型性能的影响, 实验在潜在向量维度为 10、20、30、40、50、60、70 和 80 的情况下进行训练,



(a) HR@10
(a) 命中率@10



(b) NDCG@10
(b) 归一化折损累计增益@10

Fig. 6 HR@10 and NDCG@10 of models with different negative sampling numbers on the Pinterest dataset

图 6 Pinterest 数据集下不同负采样数模型的 HR@10 和 NDCG@10

实验结果如图 7 和图 8 所示。


从图 7、图 8 可以看出: ①模型性能指标随着潜在向量维度的增加而提升。更大的潜在向量维度能够提取更多用户项目特征, 建模用户和项目隐向量更加精确, 预测精度不断提高; ②模型性能在达到最佳潜在向量维度之后, 维度过大导致模型过拟合, 性能降低;

LFD MF 在 MovieLens-1M 和 Pinterest 数据集上最佳潜在向量维度分别为 40、60。


3.4.5 实验五: 不同 MLP 层数下 LFD MF 的性能分析

为分析 MLP 层数对 LFD MF 的影响, 实验在向量维度为 10~70 的情况下设置 MLP 层数为 0~5 和 0~7 的对比模型, 实验结果如表 3—表 6 所示。

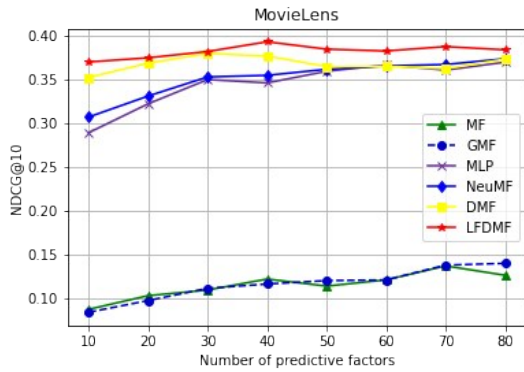
可以看出: ①随着 MLP 层数增加, HR@10 和 NDCG@10 不断提高。单层 MLP 利用神经网络学习非线性低阶关系, 深层 MLP 学习用户和项目间的非线性高阶关系, 有效提升模型性能; ②在 MovieLens-1M 和 Pinterest 数据集上, MLP 层数为 4 和 6 之后, 性能提升幅度降低甚至下降; MLP 层数过多, 训练过拟合, 约束了模型性能; 过多的 MLP 层数使模型参数和复杂度呈指数式增长, 训练时间过长, 难以收敛。



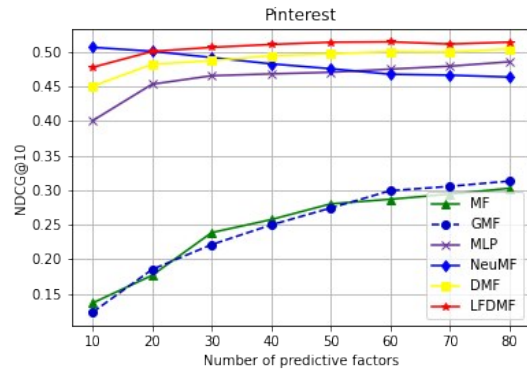
(a) HR@10
(a) 命中率@10



(a) HR@10
(a) 命中率@10



(b) NDCG@10
(b) 归一化折损累计增益@10



(b) NDCG@10
(b) 归一化折损累计增益@10

Fig. 7 HR@10 and NDCG@10 of models with different latent vector dimension on the MovieLens-1M dataset

图7 MovieLens-1M数据集下不同潜在向量维度模型的HR@10和NDCG@10

LFD MF 在 MovieLens-1M 数据集上最佳层数为 4, 表 3、表 4 进一步验证了 LFD MF 最优潜在向量维度为 40, 在 Pinterest 数据集上最佳层数为 6, 表 5、表 6 进一步验证了 LFD MF 最优潜在向量维度为 60。

4 结语

本文针对推荐系统在实际场景中忽略数据时效性, 无法同时学习用户和项目间非线性高低阶关系和用户长短期偏好的不足, 设计一种基于 GMF、MLP 和 LSTM 的深度推荐融合模型。该模型通过 GMF、MLP 引入用户和项目间非线性高低阶关系和用户长期偏好, 运用 LSTM 获取用户短期偏好, 学习更抽象、全面的特征, 将项目预测在 MovieLens-1M 和 Pinterest 数据集上训练。实验结果表明, 本文模型推荐效果突出。

但同时, 本文只考虑了项目 and 用户之间的 ID 交互, 年龄、性别、项目类别等辅助信息的特征建模, 可作为未来研究方向。

Fig. 8 HR@10 and NDCG@10 of models with different latent vector dimensions on the Pinterest dataset

图8 Pinterest数据集下不同潜在向量维度模型的HR@10和NDCG@10

Table 3 HR@10 of models with different MLP layers on the MovieLens-1M Dataset

表3 MovieLens-1M数据集下不同MLP层数模型的HR@10

潜在向量维度	MLP0	MLP1	MLP2	MLP3	MLP4	MLP5
10	0.451 3	0.467 3	0.484 6	0.531 1	0.569 8	0.619 0
20	0.450 9	0.449 5	0.507 4	0.578 4	0.622 3	0.631 7
30	0.451 9	0.470 7	0.532 6	0.609 6	0.629 1	0.648 1
40	0.451 0	0.473 8	0.576 2	0.641 9	0.653 5	0.643 9
50	0.448 2	0.471 6	0.566 4	0.631 1	0.645 5	0.645 2
60	0.451 1	0.487 3	0.597 7	0.640 4	0.651 1	0.649 7
70	0.448 8	0.490 2	0.613 4	0.635 9	0.641 2	0.644 7

Table 4 NDCG@10 of models with different MLP layers on the MovieLens-1M dataset

表4 MovieLens-1M数据集下不同MLP层数模型的NDCG@10

潜在向量维度	MLP0	MLP1	MLP2	MLP3	MLP4	MLP5
10	0.251 1	0.258 1	0.268 5	0.298 0	0.319 6	0.349 1
20	0.251 6	0.252 2	0.281 7	0.323 9	0.354 5	0.362 9
30	0.251 8	0.261 1	0.298 6	0.347 7	0.361 2	0.379 1
40	0.250 5	0.265 1	0.323 2	0.350 9	0.380 7	0.371 4
50	0.250 7	0.262 4	0.320 6	0.360 5	0.369 7	0.377 1
60	0.251 1	0.279 1	0.347 7	0.368 0	0.376 6	0.379 3
70	0.249 8	0.271 0	0.345 8	0.367 7	0.373 9	0.378 3

Table 5 HR@10 of models with different MLP layers on the Pinterest dataset

表5 Pinterest数据集下不同MLP层数模型的HR@10

潜在向量维度	MLP0	MLP1	MLP2	MLP3	MLP4	MLP5	MLP6	MLP7
10	0.274 4	0.365 7	0.746 9	0.762 6	0.807 7	0.831 6	0.841 5	0.842 7
20	0.274 3	0.403 9	0.773 7	0.805 1	0.827 5	0.835 3	0.841 8	0.845 4
30	0.273 5	0.728 7	0.795 4	0.819 2	0.831 0	0.836 2	0.845 4	0.843 9
40	0.272 3	0.730 8	0.803 3	0.826 5	0.837 7	0.844 4	0.844 6	0.846 1
50	0.269 8	0.764 4	0.813 3	0.827 7	0.836 9	0.845 5	0.846 5	0.846 2
60	0.272 0	0.767 6	0.810 7	0.831 8	0.843 2	0.841 3	0.848 2	0.847 5
70	0.273 6	0.764 0	0.817 2	0.832 8	0.838 4	0.845 0	0.846 3	0.847 5

Table 6 NDCG@10 of models with different MLP layers on the Pinterest dataset

表6 Pinterest数据集下不同MLP层数模型的NDCG@10

潜在向量维度	MLP0	MLP1	MLP2	MLP3	MLP4	MLP5	MLP6	MLP7
10	0.140 4	0.190 4	0.418 5	0.427 9	0.475 1	0.497 3	0.505 1	0.508 1
20	0.140 2	0.208 7	0.436 7	0.471 7	0.494 2	0.501 0	0.506 3	0.510 9
30	0.140 1	0.401 1	0.463 1	0.487 6	0.498 0	0.503 4	0.510 8	0.509 8
40	0.139 1	0.405 2	0.472 3	0.496 0	0.503 1	0.508 4	0.510 4	0.512 4
50	0.138 8	0.431 4	0.484 3	0.496 8	0.502 7	0.508 7	0.511 5	0.510 1
60	0.138 9	0.431 1	0.478 8	0.497 7	0.509 1	0.505 2	0.513 3	0.512 2
70	0.139 3	0.434 0	0.487 5	0.500 7	0.504 4	0.510 0	0.512 3	0.512 7

参考文献:

- [1] LI X. Overview and prospect of personalized recommendation algorithm [J]. *Hans Journal of Data Mining*, 2019, 9(3): 81-87.
- [2] CHEN J, ZHAO C, CHEN L. Collaborative filtering recommendation algorithm based on user correlation and evolutionary clustering [J]. *Complex & Intelligent Systems*, 2020, 6(1): 147-156.
- [3] ZI Y F, LI Y L, SUN H Y. Research of personalized recommendation system based on deep neural network [J]. *Application of Electronic Technique*, 2019, 45(1): 14-18, 22.
字云飞, 李业丽, 孙华艳. 基于深度神经网络的个性化推荐系统研究 [J]. *电子技术应用*, 2019, 45(1): 14-18, 22.
- [4] WANG H, LIANG G, ZHANG X. Feature regularization and deep learning for human resource recommendation [J]. *IEEE Access*, 2018, 6: 39415-39421.
- [5] NI J, HUANG Z, CHENG J, et al. An effective recommendation model based on deep representation learning [J]. *Information Sciences*, 2021, 542: 324-342.
- [6] MA Y, GENG X, WANG J. A deep neural network with multiplex interactions for cold-start service recommendation [J]. *IEEE Transactions on Engineering Management*, 2020, 68(1): 105-119.
- [7] KOREN Y, BELL R, VOLINSKY C. Matrix factorization techniques for recommender systems [J]. *Computer*, 2009, 42(8): 30-37.
- [8] SONG R X, LI G Y. Application of improved matrix factorization model in recommendation system [J]. *Computer Applications*, 2019, 39(S1): 93-95.
宋瑞雪, 李国勇. 基于改进的矩阵分解模型在推荐系统中的应用 [J]. *计算机应用*, 2019, 39(S1): 93-95.
- [9] GAO Y K, WANG X H, GUO L, et al. A user cold start recommendation algorithm based on collaborative matrix decomposition [J]. *Journal of Computer Research and Development*, 2017, 54(8): 1813-1823.
高玉凯, 王新华, 郭磊, 等. 一种基于协同矩阵分解的用户冷启动推荐算法 [J]. *计算机研究与发展*, 2017, 54(8): 1813-1823.
- [10] ATIF S M, QAZI S, GILLIS N. Improved SVD-based initialization for nonnegative matrix factorization using low-rank correction [J]. *Pattern Recognition Letters*, 2019(5): 53-59.
- [11] ZHANG L, LUO T, FEI Z, et al. A recommendation model based on deep neural network [J]. *IEEE Access*, 2018, 6: 9454-9463.
- [12] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering [C]//*Proceedings of the 26th International Conference on World Wide Web*, 2017: 173-182.
- [13] MA C S, LI J J, PAN P, et al. BDMF: a biased deep matrix factorization model for recommendation [C]//*Leicester: 2019 IEEE Smart World, Ubiquitous Intelligence & Computing, Advanced & Trusted Computing, Scalable Computing & Communications, Cloud & Big Data Computing, Internet of People and Smart City Innovation*, 2019.
- [14] TIAN Z, PAN L M, YIN P, et al. Deep matrix factorization recommendation algorithm [J]. *Journal of Software*, 2021, 32(12): 3917-3928.
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.
- [15] JI Q. Research on deep recommendation model based on recurrent neural network [D]. Hefei: Anhui University, 2020.
纪强. 基于循环神经网络的深度推荐模型研究 [D]. 合肥: 安徽大学, 2020.
- [16] TIAN X J, XIE Y H. Neural collaborative filtering model based on long short-term memory network and generalized matrix factorization [J]. *Journal of Computer Systems and Applications*, 2021, 31(1): 190-194.
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.
- [17] WU C Y, AHMED A, BEUTEL A, et al. Recurrent recommender networks [C]//*Cambridge: Proceedings of the 10th ACM International Conference on Web Search and Data Mining*, 2017: 495-503.
- [18] BAYER I, HE X, 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*, 2017: 1341-1350.
- [19] 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.
- [20] HE X, CHEN T, KAN M Y, et al. Trirank: review-aware explainable recommendation by modeling aspects [C]//*Proceedings of the 24th ACM International Conference on Information and Knowledge Management*, 2015: 1661-1670.