

doi:10.3969/j.issn.2095-0411.2021.01.010

基于深度学习特征表示协同过滤算法

宋志理¹, 胡胜利¹, 王 峰²

(1.安徽理工大学 计算机科学与工程学院, 安徽 淮南 232001; 2.阜阳师范学院 计算机与信息工程学院, 安徽 阜阳 236037)

摘要:在推荐系统中,单一的学习矩阵分解的内积交互或者利用深度神经网络来捕获用户与项目交互,不足以有效地学习用户与项目的潜在特征。针对这一问题,提出一种在显式反馈与隐式反馈基础上,称为基于深度学习特征表示的协同过滤算法(DLFeaCF)。该模型首先学习用户与项目的内积与外积交互;然后在内积的基础上,从隐式映射与特征映射两个方面再利用多层感知机(MLP)的非线性交互学习能力去获取用户与项目的全局特征;同时在外积的基础上,利用 CNN 学习捕获用户与项目的局部特征;最后在融合层组合特征并获得预测分数。在真实的 MovieLens 数据集上进行实验,表明 DLFeaCF 模型能获得更好的推荐性能。

关键词:协同过滤;多层感知机;卷积神经网络;深度学习

中图分类号:TP 393

文献标志码:A

文章编号:2095-0411(2021)01-0062-08

Research on Cooperative Filtering Algorithm Based on Deep Learning Feature Representation

SONG Zhili¹, HU Shengli¹, WANG Feng²

(1. School of Computer Science and Engineering, Anhui University of Science and Technology, Huainan 232001, China; 2. School of Computer and Information Engineering, Fuyang Normal University, Fuyang 236037, China)

Abstract:In the recommendation system, the inner product interaction of a single learning matrix decomposition or the use of deep neural networks to capture user interaction with the project is not sufficient to effectively learn the potential characteristics of users and projects. In view of this problem, this paper proposes a collaborative filtering algorithm based on deep learning feature representation (DLFeaCF) based on display feedback and implicit feedback. The model first learns the inner product and outer product interaction between the user and the project. Then, based on the inner product, it uses the nonlinear interactive learning ability of the multi-layer perceptron (MLP) to obtain the two

收稿日期:2020-08-16。

基金项目:阜阳市政府横向合作科研资助项目(XDHX2016018)。

作者简介:宋志理(1993—),女,安徽宣城人,硕士生。通信联系人:胡胜利(1978—),E-mail:slhu@aust.edu.cn

引用本文:宋志理,胡胜利,王峰. 基于深度学习特征表示协同过滤算法[J]. 常州大学学报(自然科学版), 2021, 33(1): 62-69.

aspects from implicit mapping and feature mapping; on the basis of the outer product, CNN learning is used to capture the local features of the user and the project; finally, combine the features in the fusion layer and obtain the prediction score. The experiments on the real MovieLens dataset show that the DLFeaCF model can achieve better recommendation performance.

Key words: collaborative filtering; multi-layer perceptron; convolutional neural network; deep learning

在信息爆炸的时代,数据过载是面临的问题之一。因此出现了个性化的推荐系统,推荐系统有助于减轻数据超载问题,已经被许多在线的服务商所采用。最近,研究工作者提出了各种方法来开发基于协同过滤的推荐算法。协同过滤(CF)^[1-3]是个性化推荐系统中使用的关键技术之一。一些研究工作者通过设计基于神经网络的协同过滤来研究深度神经网络(DNN)在推荐系统中的应用。例如,GUO等^[4-5]基于Wide&Deep提出了一种模型(DeepFM),采用因子机与深度神经网络建模低层次与高层次的交互特征学习。由于未结合矩阵分解,XUE等^[6]提出一种深度矩阵分解模型(DMF),该模型首先构造一个具有显式反馈与隐式反馈的矩阵,用这个矩阵作为输入,再设计一个深度结构学习框架来学习用户与项目的共同低维空间表示。考虑到学习用户与项目的非线性建模,HE等^[7]提出了一种神经协同过滤(NCF)框架,用于隐式反馈建模,主要是在建模用户与项目的交互上组合了矩阵因子分解的线性特征和MLP的非线性特征。因未有模型利用外积来学习用户与项目的交互,HE等^[8]在NCF模型的基础上又提出了用不同的外积来模拟嵌入空间维度之间的成对相关性,最后在外积运算后获得的交互图(interaction map)的上方再采用卷积神经网络来学习嵌入维度之间的高阶相关性。上述研究方法主要是单一的考虑神经结构或者是内积、外积运算,并没有在显式与隐式反馈的基础上利用MLP和CNN来共同学习用户与项目潜在特征表示。

提出一种新颖的基于深度学习特征表示的协同过滤算法(DLFeaCF)。该模型共同学习用户与项目的显式反馈与隐式反馈。在学习用户与项目内积交互时,使用多层感知机(MLP)来获取用户与项目的非线性关系,再获取用户与项目交互的全局特征;在嵌入层上方使用外积操作,可以明确捕获嵌入维度之间的成对相关性,然后再利用卷积神经网络提取局部特征;最后融合局部特征和全局特征并产生推荐。

1 相关工作

1.1 特征提取

传统的协同过滤算法根据用户对项目的评级进行预测,然后根据预测的评分给项目进行排序,再产生项目列表推荐给用户^[9]。课题组考虑从基于显式反馈与隐式反馈中提取用户与项目的潜在特征表示,更好地为用户进行推荐。

显式反馈一般可以用三元组(用户、项目、评分)的形式来表示,显式反馈可以直接用评分来显示用户的兴趣爱好。对于隐式反馈数据,如用户点击、浏览、收藏、分享等操作,这些反馈在一定程度上表现用户的偏好^[10]。假设有 M 个用户 $U=\{u_1, u_2, \dots, u_M\}$, N 个项目 $V=\{v_1, v_2, \dots, v_N\}$ 。设 Z_{ij} 表示用户 i 对项目 j 的评分。用户-项目交互矩阵 $Z \in \mathbf{R}^{M \times N}$ 。

$$Z_{ij} = \begin{cases} 1, & \text{交互存在} \\ 0, & \text{无交互} \end{cases} \quad (1)$$

式中 $Z_{ij}=1$,代表用户 i 与项目 j 存在交互,否则表示用户 i 对项目 j 无兴趣或未知项目 j ,称为非偏好

隐式反馈。推荐系统的隐式反馈表示的是估计 Z 中未被观察项目的评分问题,这些评分用于对项目进行排序。基于模型的方法,假设数据可以由基础模型生成(或者描述),定义为

$$\hat{Z}_{ij} = f(u, i | \Theta) \quad (2)$$

式中: \hat{Z}_{ij} 为用户与项目之间的交互 Z_{ij} 的预测分数; Θ 为模型的参数; f 为将模型参数映射到预测分数的函数。

1.2 神经网络学习

神经网络主要是有很多个简单的神经元互相连接而形成的一个复杂的网络架构。

多层感知机 (Multilayer Perceptron, MLP) 是一种前馈人工神经网络,包含输入层、输出层,它中间可以有多个隐层,最简单的 MLP 结构中,隐藏层只有 1 个,如图 1 所示。

在文中,使用标准的 MLP 来学习用户与项目潜在特征之间的交互。在基于用户与项目的显式反馈与隐式反馈数据,将 MF 得到的线性交互与 MLP 获取的非线性交互共同为用户与项目建模获取用户与项目的全局特征表示。

对于局部特征表示的学习,由卷积神经网络来获取。卷积神经网络 (Convolutional Neural Network, CNN) 是一种多层神经网络,擅长处理图像数据^[4]。与传统的神经网络相比,在 CNN 的卷积层中,一个神经元与部分周边相邻的神经元相连。在 CNN 的一个卷积层中,含有很多个特征平面,同一个特征平面的神经元共享权值,这权值共享网络结构就是卷积核,它能极大的减少参数数量,减少整体模型结构的复杂度,泛化能力也大大提高。CNN 还利用池化层操作降低了模型中数据的维度,增加鲁棒性。通常而言, CNN 利用卷积来模拟特征分区,再利用卷积的权值共享以及池化,来降低参数数量,再利用传统神经网络来完成分类等任务。卷积神经网络主要由输入层、卷积层、下采样层(池化层)、全连接层和输出层组成,如图 2 所示。




图 1 MLP 模型图

Fig.1 MLP model diagram

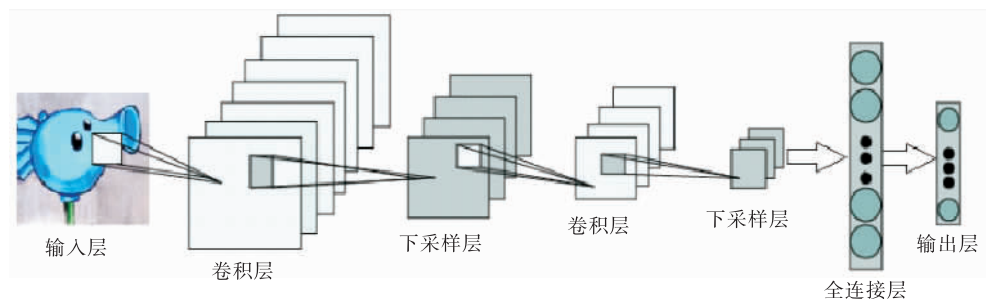


图 2 卷积神经网络示意图

Fig.2 Schematic diagram of convolutional neural network

在文中,主要是在显式反馈与隐式反馈的基础上,在学习用户与项目的外积运算,之后再利用卷积神经网络获取用户与项目的局部特征。

2 DLFeaCF 算法模型

2.1 模型结构

基于深度学习特征表示的协同过滤算法模型 (DLFeaCF) 框架如图 3 所示。DLFeaCF 模型的工作原理:在基于用户与项目的反馈上学习用户与项目的内积交互 (Implicit interaction),然后将获得的内积交互与 MLP 获取的非线性交互共同学习用户与项目的全局特征;在基于用户与项目的显式反馈与隐式反馈上学习用户与项目的外积交互 (User-Item interaction),再利用 CNN 捕获用户与项目的特征后进行池化 (Poolings) 操作获取用户与项目的局部特征;从辅助信息特征上获得用户与项目的特征映射 (Feature map),然后同 1) 一样学习用户与项目的全局特征;最后在融合层 (Fusion layer) 进行组合局部特征和全局特征并产生预测评分。

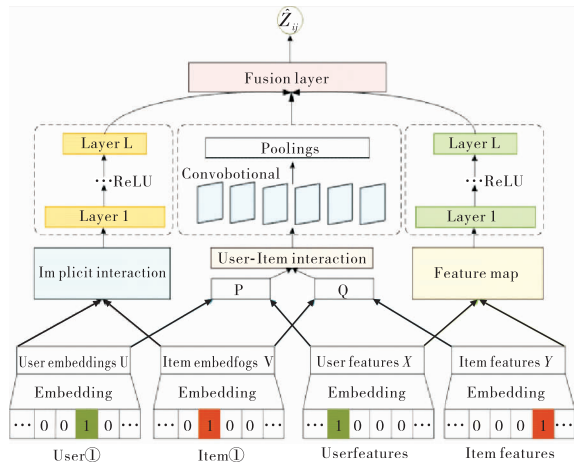


图 3 DLFeaCF 框架图

Fig.3 DLFeaCF frame diagram

2.2 特征学习

2.2.1 全局特征学习

该模型的全局特征是从用户-项目和从用户-项目辅助信息特征两个方面进行学习。因此可以直观地将两条路径结合起来共同学习用户-项目的全局特征。

由于输入的是用户-项目 ID 的 one-hot 编码,所获得的嵌入向量被看作是用户-项目的潜在矢量。让 p_i 和 q_j 分别为用户 i 和项目 j 的潜在向量, MF 获取 p_i 和 q_j 的内积交互为

$$\hat{Z}_{ij} = f(i, j | p_i, q_j) = p_i^T q_j = \sum_{k=1}^k p_{ik} q_{jk} \quad (3)$$

式中 k 表示潜在空间的维度,假设每个潜在空间的维度是相互独立的,而将它们与相同的权重线性组合。矩阵分解也代表是用户-项目潜在因素的线性模型。为了再学习非线性交互,使用标准的 MLP 来学习用户与项目潜在特征之间的非线性交互。因此,DLFeaCF 框架下的 MLP 被定义为

$$\begin{cases} z_1 = \varphi_1(p_i, q_j) = \begin{bmatrix} p_i \\ q_j \end{bmatrix} \\ \varphi_2(z_1) = \alpha_2(W_2^T z_1 + b_2) \\ \vdots \\ \varphi_L(z_{L-1}) = \alpha_L(W_L^T z_{L-1} + b_L) \\ \hat{Z}_{ij} = \sigma(h^T \varphi_L(z_{L-1})), \end{cases} \quad (4)$$

式中 W_x , b_x , σ 分别表示第 x 层感知机的权重矩阵、偏置向量和激活函数。对于激活函数,本文选择的是 RELU,它更适合稀疏数据,并且使得模型不太可能产生过度拟合。

2.2.2 局部特征学习

DLFeaCF 模型的局部特征学习从卷积神经网络方面学习获得。

假设给定用户 i 和项目 j 以及它们的特征(例如:用户的 ID、性别、项目目次等),首先对它们的特征

进行 one-hot 编码。设 \mathbf{X} 和 \mathbf{Y} 分别为用户 i 和项目 j 的特征向量。可以获得它们的嵌入向量 \mathbf{p}_i 和 \mathbf{q}_j , 为

$$\begin{cases} \mathbf{p}_i = \mathbf{P}^T \mathbf{X} \\ \mathbf{q}_j = \mathbf{Q}^T \mathbf{Y} \end{cases} \quad (5)$$

式中: $\mathbf{Z} \in \mathbf{R}^{M \times N}$ 以及 $\mathbf{Q} \in \mathbf{R}^{N \times K}$ 分别为用户特征和项目特征的嵌入矩阵, K, M, N 分别是嵌入大小, 用户特征数和项目特征数。在嵌入层之上, 本文提出在 \mathbf{p}_i 和 \mathbf{q}_j 上使用外积来得到交互图。

$$\mathbf{E} = \mathbf{p}_i \otimes \mathbf{q}_j = \mathbf{p}_i \mathbf{q}_j^T \quad (6)$$

式中 \mathbf{E} 是 $K \times K$ 的矩阵, 每个元素被计算为 $e_{k_1, k_2} = p_{i, k_1} q_{j, k_2}$ 。

交互图上方有一堆卷积层, 目的是为了提取有用的信息。本文在交互图上使用 CNN 来学习用户与项目的局部特征主要由两部分组成: 卷积层与池化层。

卷积层的公式为

$$a_c = \varphi(\mathbf{W} * \mathbf{E} + b) \quad (7)$$

式中: $*$ 为卷积算子; \mathbf{W} 为权重矩阵; b 为 \mathbf{W} 的偏置项; φ 为一个非线性激活函数。在卷积层之上, 池化层减小了卷积输出的表示大小, 从而从卷积中细化了特征以获得更好的鲁棒性。池化的学习方式表示为

$$a_p = P(a_c) \quad (8)$$

式中 a_p 为池化函数, 例如最大池化(Max-pooling)或平均池化(Average-pooling)。

2.2.3 融合组合特征以及预测

对于 DLFeaCF 模型融合层的组合特征表示为

$$h_f = \delta_f(\mathbf{W}_f \mathbf{z}_f + \mathbf{b}_f) \quad (9)$$

式中: \mathbf{W}_f 为权重矩阵; \mathbf{b}_f 为偏差向量; δ_f 为激活函数; \mathbf{z}_f 为潜在交互表示的串联。设 \hat{Z}_{ij} 表示预测评分, 为

$$\hat{Z}_{ij} = \sigma(\mathbf{W}_0^T \mathbf{a}_L + \mathbf{b}_0) \quad (10)$$

式中: σ 为激活函数; \mathbf{W}_0 为偏重矩阵; \mathbf{a}_L 为 L 层激活函数的输出; \mathbf{b}_0 为偏置向量。由于模型没有涉及负样本, 采取负抽样策略对一负样本进行采样。实验采取从矩阵 \mathbf{R} 中未观察到的相互作用抽取负样本, 采取一致的负抽样策略, 方法同文献[1]。

2.3 损失函数

损失函数一般由特征提取的重构误差和预测误差组成。推荐系统有两类损失函数: 点向函数和成对损失函数。考虑本文模型中含有深度学习模型框架, 这里使用的损失函数是同文献[7], 损失函数为

$$L = - \sum_{\langle i, j \rangle \in r \cup r^-} Z_{ij} \log \hat{Z}_{ij} + (1 - Z_{ij}) \log(1 - \hat{Z}_{ij}) \quad (11)$$

式中: Z_{ij} 为用户 i 对项目 j 的评分; \hat{Z}_{ij} 为预测评分。这是 DLFeaCF 模型最小化的目标函数。实际上, 它是二元交叉熵损失, 将隐式反馈的 RS 问题作为二元分类问题求解。

3 实 验

3.1 数据集

根据推荐系统中广泛使用的 MovieLens 1M (ML1M) 来评估本文的模型^[6]。MovieLens 数据集, 见表 1。

表 1 数据集统计

Table 1 Dataset statistics

数据集	交互	用户	项目	稀疏度
MovieLens 1M	1 000 209	6 040	3 706	95.53%

本文使用的数据集至少包含 100 万个评分,每个用户至少有 20 个评分。

参数设置:为确定该模型的超参数,实验中为每个用户随机的抽取一个交互作为验证数据并且调整超参数。使用上述提及的损失函数进行数据学习,利用高斯分布随机初始化模型参数(平均值为 0,标准偏差为 0.01)。测试中的 batch_size 为[128,256,512,1 024],学习率为[0.000 1,0.000 5,0.001,0.005]。文中的 MLP 框架是 32 → 16 → 8,嵌入大小是 16。

3.2 评估方案

为了评估推荐的效果,采用了广泛使用的留一法评估方法^[11]。将用户最新评论的记录作为测试集,其余记录用于训练集。这里引用作者在文献中使用的实验策略[1],将随机选择 100 个未被用户评分的项目,然后对候选项目进行排序以获得前 N 项。在文中,将使用命中率(Hit Ratio,HR)和标准化折现累积增益(Normalized Discounted Cumulative Gain,NDCG)来表示项目排序的性能^[12]。 λ_{HR} 是测量测试项是否在前 N 项列表中, η_{DCG} 主要考虑该项目的位置。如果 η_{DCG} 值越大,则表明项目的位置越靠前。计算公式定义为:

$$\lambda_{HR} = \frac{h(N)}{|G_T|} \quad (12)$$

$$\eta_{DCG} = Z_N \sum_{i=1}^N \frac{2^{r_i} - 1}{\log_2(i+1)} \quad (13)$$

式中: G_T 为测试列表集; r_i 为项目在第 i 位置的分数关联值; Z_N 为正规化。在实验中,令 $r_i \in \{0,1\}$, r_i 值取决于 i 是否在测试集中。

3.3 方法比较

将文中提出的模型与以下方法进行比较:

ItemPop:项目的排名主要取决于项目的受欢迎程度与交互的数量^[13]。这是从非个性化的方法来衡量推荐的性能。

ItemKNN:亚马逊公司的基于标准项目的协同过滤方法^[14]。本文遵循参考文献^[15]的设置,使用其隐式数据来应用这种方法。

BPR:贝叶斯个性化排名(BPR)。本文对该模型进行了优化,使其具有成对排名损失,并从隐式反馈中学习^[13]。

NeuMF:神经矩阵分解模型。该模型利用 GMF 的线性核与 MLP 的非线性核来共同建模用户与项目的交互^[7]。

3.4 结果与分析

3.4.1 性能比较

如表 2,图(4)和图(5)所示,本文提出的 DLFeaCF 模型的 $\lambda_{HR,10}$ 与 $\eta_{DCG,10}$ 的值均高于 ItemPop, ItemKNN,BPR,NeuMF 模型的值,推荐的准确性整体上优于其他 4 种模型。

ItemPop 推荐算法,主要是取决于项目的受欢迎程度与交互的数量来获得项目排名,最后根据项目排名向用户进行推荐。由于项目的受欢迎程度与其他

表 2 $\lambda_{HR,10}$ 和 $\eta_{DCG,10}$ 的前 10 项推荐



Table 2 Top 10 recommendations for $\lambda_{HR,10}$ and $\eta_{DCG,10}$

模型	MovieLens 1M	
	$\lambda_{HR,10}$	$\eta_{DCG,10}$
ItemPop	0.472	0.263
ItemKNN	0.637	0.372
BPR	0.667 4	0.390 7
NeuMF	0.688	0.410
DLFeaCF	0.711 9	0.429 2

说明:ItemPop,ItemKNN 见文献[4],BPR 见文献[2],NeuMF 见文献[1]。

用户兴趣的联系度不高,ItemPop 的 $\lambda_{HR,10}$ 与 $\eta_{DCG,10}$ 的值很低,所以推荐的性能不佳。进一步说明,不能简单的向所有用户推荐流行的商品,要考虑用户的偏好问题。ItemKNN 基于项目的协同过滤算法,主要是基于项目之间的相似度进行推荐,该算法加入了相似度分析,若项目 A 与项目 B 具有很高的相似度,用户喜欢项目 A,则用户喜欢项目 B 的可能性就高于其他项目,如实验结果中图(4),图(5)所示, $\lambda_{HR,10}$ 与 $\eta_{DCG,10}$ 的值高于 ItemPop 算法的值,推荐性能整体上优于 ItemPop 算法。

BPR 算法主要将任意用户对应的物品进行标记,考虑了用户之间的偏好行为各自独立和同一用户对不同项目的偏好行为各自独立,如图(4)与图(5)所示,BPR 算法的 $\lambda_{HR,10}$ 与 $\eta_{DCG,10}$ 的实验结果整体上优于 ItemPop,ItemKNN 算法。可以得出在算法中加入用户偏好,可以进一步的提升推荐算法的性能。NeuMF 模型利用神经网络深度学习用户与项目的潜在特征,主要学习线性核与非线性核来共同建模用户与项目之间的交互,降低了数据模型的稀疏度,有效的学习了用户与项目之间的交互,从而提升了推荐的性能。结合深度学习的 NeuMF 模型的 $\lambda_{HR,10}$ 与 $\eta_{DCG,10}$ 的结果值都高于其他 3 种算法。由于 DLFeaCF 模型在 NeuMF 模型的基础上进一步有效地学习了用户与项目的交互,DLFeaCF 模型的 $\lambda_{HR,10}$ 与 $\eta_{DCG,10}$ 的值高于其他 4 种算法,则推荐效果优于其他算法。

图 4 电影数据集 $\lambda_{HR,10}$ Fig.4 MovieLens dataset $\lambda_{HR,10}$ 图 5 电影数据集 $\eta_{DCG,10}$ Fig.5 MovieLens dataset $\eta_{DCG,10}$

3.4.2 MLP 对实验的影响

由 NeuMF 模型可知,将用户与项目的潜在向量添加隐藏层,使用标准的 MLP 来学习用户与项目的潜在特征向量,提高了协同过滤推荐的准确性。NeuMF 的整体性能优于 ItemPop,ItemKNN,BPR。结合 NeuMF 的经验,DLFeaCF 模型利用深度神经网络学习用户与项目的局部与全局特征之后,再利用 MLP 学习非线性特征并融合组合特征。使得 DLFeaCF 模型的推荐效果在性能上优于 NeuMF。

4 结 论

针对现有模型学习用户与项目特征能力不佳的问题,提出了一种新的神经网络体系结构用于协同过滤。在考虑用户显示反馈与隐式反馈的基础上,可以通过矩阵分解和多层感知机分别学习用户与项目的线性交互与非线性交互。该模型基于深度学习特征表示的协同过滤算法模型(DLFeaCF)主要是结合了深度神经网络与卷积神经网络,分别获取用户与项目的全局特征和局部特征。在实验分析中,课题组的方法明显优于其他方法。

在未来的工作中,考虑使用自动编码器先获取用户与项目的特征再结合神经网络共同学习特征,进一步解决数据的稀疏性与冷启动问题。

参考文献:

- [1]LIU Y, WANG S, KHAN M S, et al. A novel deep hybrid recommender system based on auto-encoder with neural collaborative filtering[J]. Big Data Mining and Analytics, 2018, 1(3): 211-221.
- [2]STRUB F, GAUDEL R, MARY J. Hybrid recommender system based on autoencoders[C]// Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. Boston:ACM, 2016: 11-16.
- [3]LIANG D, KRISHNAN R G, HOFFMAN M D, et al. Variational autoencoders for collaborative filtering[C]. Geneva: [s.n.], 2018.
- [4]黄立威, 江碧涛, 吕守业, 等. 基于深度学习的推荐系统研究综述[J]. 计算机学报, 2018, 41(7):1-30.
- [5]GUO H F, TANG R M, YE Y M, et al. Deepfm: a factorization-machine based neural network for ctr prediction[C]. [S.l.:s.n.], 2017.
- [6]XUE H J, DAI X, ZHANG J, et al. Deep matrix factorization models for recommender systems[C]. [S.l.]: IJCAI, 2017: 3203-3209.
- [7]HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering[C]//Proceedings of the 26th International Conference on World Wide Web. Perth:International World Wide Web Conferences Steering Committee, 2017: 173-182.
- [8]HE X, DU X, WANG X, et al. Outer product-based neural collaborative filtering[C]//Twenty-Seventh International Joint Conference on Artificial Intelligence{IJCAI-18}. [S.l.:s.n.], 2018.
- [9]CHEN Y, DE RIJKE M. A collective variational autoencoder for top-n recommendation with side information[C]//. Proceedings of the 3rd Workshop on Deep Learning for Recommender Systems. [S.l.]: ACM, 2018: 3-9.
- [10]ZHANG Q, CAO L, ZHU C, et al. CoupledCF: learning explicit and implicit user-item couplings in recommendation for deep collaborative filtering[C]. [S.l.]: IJCAI, 2018: 3662-3668.
- [11]CHENG W, SHEN Y, ZHU Y, et al. DELF: A dual-embedding based deep latent factor model for recommendation [C]. [S.l.]: IJCAI, 2018: 3329-3335.
- [12]XIAO T, LIANG S, SHEN H, et al. Neural variational hybrid collaborative filtering[M]. [S.l.:s.n.], 2018.
- [13]RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: bayesian personalized ranking from implicit feedback[C]// Proceedings of the twenty-fifth conference on uncertainty in artificial intelligence. [S.l.]: AUAI Press, 2009: 452-461.
- [14]SARWAR B, KARYPIS G, KONSTAN J, et al. Item-based collaborative filtering recommendation algorithms[C]// Proceedings of the 10th international conference on World Wide Web. [S.l.]: ACM, 2001: 285-295.
- [15]HU Y, KOREN Y, VOLINSKY C. Collaborative filtering for implicit feedback datasets[C]// Data Mining, 2008. ICDM'08. Eighth IEEE International Conference on. [S.l.]:IEEE, 2008: 263-272.

(责任编辑:李艳)