

## 基于物品的统一推荐模型

邓 凯<sup>1</sup>, 黄佳进<sup>2\*</sup>, 秦 进<sup>1</sup>

(1. 贵州大学 计算机科学与技术学院, 贵阳 550025; 2. 北京工业大学 国际 WIC 研究院, 北京 100000)

(\* 通信作者电子邮箱 jhuang@bjut.edu.cn)

**摘 要:** 用户-物品交互模式建模是个性化推荐的一项重要任务, 许多推荐系统都基于用户与商品之间存在线性关系的假设, 忽略了现实物品与历史物品之间交互的复杂性和非线性, 导致这些系统不足以捕捉到用户的复杂决策过程。为此, 将一个更有表现力的 Top-N 推荐系统的物品相似性因子模型解决方法与多层感知机方法相结合, 以有效地建模物品之间的高阶关系, 捕获更复杂的用户决策。分别在三个数据集 MovieLens、Foursquare 和 ratings\_Digital\_Music 上验证了结合后的效果, 并与基准方法 MLP、分解物品相似度模型 (FISM)、DeepICF 和 ItemKNN 进行对比, 结果表明, 所提出的方法在推荐性能上有明显的提高。

**关键词:** 深度神经网络; 个性化推荐; 高阶关系; 非线性; 用户决策

**中图分类号:** TP18 **文献标志码:** A

### Item-based unified recommendation model

DENG Kai<sup>1</sup>, HUNAG Jiajin<sup>2\*</sup>, QIN Jin<sup>1</sup>

(1. School of Computer Science and Technology, Guizhou University, Guiyang Guizhou 550025, China;

2. International WIC Institute, Beijing University of Technology, Beijing 100000, China)

**Abstract:** The modeling of user-item interaction patterns is an important task for personalized recommendation. Many recommendation systems are based on the assumption that there is a linear relationship between users and items, and ignore the complexity and non-linearity of interaction between real and historical items, as a result, these systems cannot capture the complex decision-making process of users. Therefore, a more expressive top-N recommendation system's item similarity factor model solution was combined with the multi-layer perceptron approach, to effectively model the higher-order relationships between items and capture more complex user decisions. The combination effect was verified on the three datasets of MovieLens, Foursquare and ratings\_Digital\_Music; and compared with the benchmark methods such as MLP (Multi-Layer Perception), Factored Item Similarity Model (FISM), DeepICF (Deep Item-based Collaborative Filtering) and ItemKNN (Item-based K-Nearest Neighbors), the results demonstrate that the proposed method has significant improvement in recommendation performance.

**Key words:** deep neural network; personalized recommendation; higher-order relationship; non-linearity; user decision making

## 0 引言

推荐系统旨在为用户提供需要的物品, 让用户能更快速更高效地找到自己所需物品。在信息过载的时代, 推荐系统在电子商务、音乐/电影/书籍网址、社交平台等许多网络服务上扮演着重要的角色。现如今推荐系统已经成为了人们研究的热点话题, 并且在信息检索、人工智能以及数据挖掘方面的关注度在逐渐增加。

在各种推荐方法中, 协同过滤 (Collaborative Filtering, CF)<sup>[1]</sup> 已被人们广泛采用, 它通过用户与物品之间交互的数据来预测用户与物品间的相关性。在一种假设下: CF 通过给相似用户推荐其他用户喜欢的内容; 另一种假设是: 基于用户对物品的偏好找到相似的物品, 然后根据用户的历史偏好, 推荐相似的物品给他。根据不同的假设, CF 被分为两种类型: 一

种是基于用户的协同过滤方法 (User-based Collaborative Filtering, UCF); 一种是基于物品的协同过滤方法 (Item-based Collaborative Filtering, ICF)<sup>[2]</sup>。矩阵分解 (Matrix Factorization, MF) 模型<sup>[3-4]</sup> 在 UCF 中是一个典型的例子, 通过计算该用户的潜在因子 (Latent Factor, LF) 和对应物品的 LF 的内积, 最后将内积的结果作为预测的评分矩阵。基于物品的协同过滤表示一个用户已经购买过的物品记录, 并且通过使用该用户要购买的目标物品和该用户购买过的物品的相似性来评估用户-物品的相关性。为了更好地表示出一个用户和他购买过的物品记录, 每一个用户都有一个固定的 ID, 这样在输入阶段 ICF 过滤方法与 UCF 相比更具有标志性。此外, 当一个用户有新的物品购买记录或者一个新用户开始购买物品, 不需要重新训练模型参数来更新推荐列表。ICF 能通过简单的检索新购

收稿日期: 2019-08-20; 修回日期: 2019-10-23; 录用日期: 2019-10-24。 基金项目: 贵州省科学技术厅科技计划项目 (2502)。

作者简介: 邓凯 (1994—), 男, 贵州毕节人, 硕士研究生, 主要研究方向: 推荐系统; 黄佳进 (1977—), 男, 贵州遵义人, 助理研究员, 博士, 主要研究方向: 推荐系统; 秦进 (1978—), 男, 贵州毕节人, 副教授, 博士, 主要研究方向: 计算智能。

买的物品和之前购买过的物品的相似性来更新物品清单。然而UCF方法像矩阵分解一样将模型参数与用户ID关联,强制它们为了一个用户更新参数来更新推荐列表(MF是在线更新策略)。

在最近几年,用户购买的物品被应用在两种常见的代表方法中:一种是直接采用用户已经购买过的物品作为输入向量,并且采用神经网络把输入的向量转化为能更好表示用户低秩表示的学习(Latent Low-Rank Representation, LatLLR),这充分利用了神经网络的非线性和高容量特征;另一种表示将每一个被用户购买过的物品作为一个潜在向量,并且把这些潜在向量两两内积计算其两个物品的相似性。前一种方法仅仅是把历史物品转化为一个用户向量而没有考虑物品之间的相似性;后一种方法考虑了物品之间的相似性,但每一个被购买过的物品都有很多参数以及一个额外的潜在向量。因此这两种方法各有优势,如果能把这些不同性能的方法整合起来将得到更好的推荐效果。

## 1 相关工作

虽然MF在推荐研究中很受欢迎,但ICF在推荐系统中效果要好于UCF。ICF通过表示用户所购买的物品,在物品中编码更多的信号输入,并不是简单地使用ID表示用户的UCF。这为ICF提供了更大的潜力,且提高了用户偏好建模的准确性和可解释性。对于top- $N$ 推荐,ICF方法的准确性优于UCF方法<sup>[5]</sup>。ICF可以将推荐的物品解释为与用户之前购买过的某些物品高度相似,这比基于“相似用户”的解释方案<sup>[6]</sup>更容易被用户接受。其次,ICF在用户偏好建模中的可组合性使得在线个性化<sup>[7]</sup>的实现更加容易。例如,当用户有新的购买时,ICF不需要重新训练模型参数来刷新推荐列表,而只需检索与新购买的物品相似的物品,就可以近似地得到已刷新的列表。这种策略基于用户最近的观看成功地在YouTube上提供了即时个性化。相比之下,像MF这样的UCF方法将模型参数与用户ID关联起来,使得它们必须更新模型参数来刷新用户的推荐列表。

ICF通常是采用Pearson相关性和余弦相似度来计算两个物品之间的相似性<sup>[8-9]</sup>。近年来,为了从数据中学习物品相似度,人们研究了获取数据特征的方法,其中比较有代表性的两种方法是稀疏线性方法(Sparse Linear Method, SLIM)<sup>[10]</sup>和分解物品相似度模型(Factored Item Similarity Model, FISM)<sup>[11]</sup>。在FISM中,两个物品之间的相似性是通过它们的潜在向量乘积后得到的,可以将其视为物品-物品相似矩阵。ICF的一些最新发现通过神经注意相似度(Neural Attentive Item Similarity, NAIS)模型扩展了FISM模型。利用注意网络区分物品间的相似性对预测更为重要,即协同去噪自动编码器(Collaborative Denoising Auto-Encoder, CDAE)<sup>[12]</sup>采用非线性自编码结构<sup>[13]</sup>学习物品相似性全局和本地SLIM,它为不同的用户子集使用不同的SLIM模型。

MLP(Multi-Layer Perception)<sup>[14]</sup>是一个多层神经网络模型,它一般由三部分组成:一部分是输出层且含有多个感知单元;一部分是由多个感知单元构成的一层或者多层隐藏层;还

有一部分是含有多个感知单元的的输出层。MLP被广泛地应用于自然语言处理、图像处理等多个领域。在本文工作中,将MLP应用于个性化推荐领域,用于建模用户和物品或者是物品与物品之间的交互关系。

基于前人的研究,本文将FISM模型和MLP模型结合成UICF模型,这对于物品的推荐更具有表征力。

## 2 模型设计和描述

### 2.1 MLP

设用户集 $U$ 包含 $M$ 个用户,物品集 $I$ 包含 $N$ 个物品, $r_{uj}$ 表示用户 $u$ 对物品 $j$ 是否有过交互。对于隐式反馈(如购买), $r_{uj}$ 用二进制数1或0表示用户 $u$ 是否和物品 $j$ 有过交互,1表示有过交互,0表示没有。这种思想是基于物品的协同过滤,它通过一个用户和该用户在过去所有交互过的物品与现有物品 $i$ 的相似性来预测该用户对现有物品 $i$ 的偏好。

对于用户 $u$ 有: $\mathbf{r}_u = (r_{u1}, r_{u2}, \dots, r_{uN})$ 。本文把一个 $N$ 行 $N$ 列的物品-物品表示为相似矩阵 $\mathbf{S}$ 。在相似矩阵 $\mathbf{S}$ 中第 $i$ 行和第 $j$ 列表示的是第 $i$ 个物品和第 $j$ 个物品的相似性。 $\mathbf{S}_i$ 表示的是物品 $i$ 和其他所有物品之间的相似性。 $\mathbf{r}'_{ui} = \mathbf{r}_u \times \mathbf{S}_i$ ,  $\mathbf{r}'_{ui}$ 的值表示的是用户打算购买的目标物品与该用户之前交互过物品的相似性。预测模型被表示为:

$$f_{ui}^{\text{MLP}} = \alpha(\mathbf{W}_L^T(\mathbf{W}_{L-1}^T(\dots\alpha(\mathbf{W}_1^T\mathbf{r}'_{ui} + \mathbf{b}_1)) + \mathbf{b}_{L-1}) + \mathbf{b}_L) \quad (1)$$

其中: $\mathbf{W}_*$ 和 $\mathbf{b}_*$ 表示每一层的权重和偏置, $\alpha$ 是Sigmoid激活函数。

### 2.2 FISM

$R_u$ 表示用户 $u$ 购买过的物品集,并且每一个物品被两个嵌入向量 $\mathbf{p}$ 和 $\mathbf{q}$ 划分为两部分:一部分是预测的目标物品,另一部分是之前与用户交互过的物品。预测模型表示为:

$$f_{ui}^{\text{FISM}} = \sum_{j \in I - \{i\}} r_{uj} (\mathbf{p}_i \odot \mathbf{q}_j) \quad (2)$$

式(1)采用0-1向量直接表示一个用户的输入,并且把这个向量转化成一个LatLLR方法。两个向量的内积被直接用来表示物品 $i$ 与购买物品 $i$ 的这个用户之前所交互过的所有物品之间的相似性。在式(2)中,被购买过的物品嵌入到 $\mathbf{q} \in \mathbf{R}^{N \times d}$ 中,其中 $d$ 是物品嵌入的维度。式(2)能被考虑作为计算物品 $i$ 与购买物品 $i$ 的用户所有交互过的物品之间相似性的一种直接方法。不同的0-1表示,不仅从整个物品集中获取物品的嵌入,并且这样还包含了全局语义信息。对于每一个被购买的物品,这样的分布式表示自然可以作为用户对物品的喜好程度。

### 2.3 MLP和FISM结合

为了结合FISM和MLP这两种模型,本文需要设计一种策略融合它们,以便结合后它们的性能都得到增强。其中一种最常见的融合策略是通过连接学习表示法来获得联合表示,并且把这种表示输入到一个全连接层。在本文的方法中,预测函数是由两步得到的:第一步,该模型利用FISM模型和MLP模型中用户偏好潜在因子和物品潜在因子的元素乘积 $\odot$ 分别计算出两个预测向量;第二步,将用户进行Multi-Hot编码,目标物品进行One-Hot编码,再用不同权重将两个预测

向量串联起来。CF 两种类型方法有不同的优势,并且从不同的环境中学习预测向量,将这两个预测向量连接起来,将得到一个更健壮、更鲁棒的联合表示用户-物品对。由此产生的全连接层使模型能够对联合表示中包含的特征分配不同的权重。图 1 说明了上述提出的融合策略,给出的形式如下:

$$\hat{r}_{ui} = \sigma \left( \mathbf{h}^T \left[ \begin{matrix} \mathbf{f}_{ui}^{\text{FISM}} \\ \mathbf{f}_{ui}^{\text{MLP}} \end{matrix} \right] + \mathbf{b} \right) \quad (3)$$

其中:  $\mathbf{h}^T$ 、 $\mathbf{b}$  分别是权重和偏置,  $\sigma$  是 Sigmoid 激活函数。UICF 的模型图如图 1 所示。




图 1 UICF 模型

Fig. 1 Model graph of UICF

## 2.4 损失函数

令  $\langle u, i, j \rangle$  表示一个有效的训练实例对,表示用户  $u$  相对物品  $j$  更偏向喜欢物品  $i$ ,其中  $(u, i) \in R_u, (u, j) \notin R_u$ 。由 BPR 派生形成的一对 L2 正则化损失  $L_{\text{reg}}$ 。

$$L_2(\langle u, i, j \rangle) = \ln((\hat{r}_{ui} - r_{uj}) - \lambda L_{\text{reg}}) \quad (4)$$

其中  $\sigma$  是 Sigmoid 函数。Sigmoid 函数是一个单调增函数,在式(4)中将使得  $\hat{f}(u, i)((u, i) \in R_u)$  大于  $\hat{f}(u, j)((u, j) \notin R_u)$ 。

文献[14]提出,模型参数的初始化对基于深度学习(Deep Learning, DL)的模型收敛和最终表现起到相当重要的作用。为了能够得到更好的预测评分的效果,先初始化 FISM 模型的参数,使其服从均值为 0、标准差为 0.01 的 Gaussian 分布,然后再训练 FISM 模型直到收敛。同样地,也初始化 MLP 模型,使其服从均值为 0、标准差为 0.01 的 Gaussian 分布。对于最终模型的融合是分别将单独训练好的 FISM 模型和 MLP 模型对应参数初始化融合模型中的 FISM 和 MLP,其中包含了 FISM 中的用户偏置项、物品偏置项以及 MLP 部分隐藏层权重系数和偏置项的初始化。

## 3 实验结果与分析

### 3.1 实验设置

#### 3.1.1 实验数据集

本文使用了 3 个公开的数据来验证本文方法的有效性:

1) MovieLens 是一个被广泛使用于验证 CF 算法有效性的电影评分数据集。MovieLens 有多个版本,在本文的实验中选择含有约 100 万条交互记录的版本 ML-1M。因为在这个版本的 MovieLens 数据集中,每个用户都至少含有 20 条交互记录。

2) Foursquare 数据集。该数据集相当稀疏,为了能更好地评估本文的模型,先对 Foursquare 进行过滤,使得这个数据集中每个用户至少含有 30 条交互记录。

3) ratings\_Digital\_Music 数据集(下面简称 Music 数据集)。

该数据集同样极其稀疏,因此对该数据集也进行了同样的过滤,确保每个用户至少含有 30 条交互记录。

3 个数据的具体数值指标如表 1 所示。

表 1 实验数据集的统计信息

Tab. 1 Statistics of experimental datasets

| 数据集名称      | 交互次数      | 用户数   | 物品数   | 密度/% |
|------------|-----------|-------|-------|------|
| MovieLens  | 1 000 209 | 3 706 | 6 040 | 4.47 |
| Foursquare | 39 287    | 2 321 | 5 596 | 0.30 |
| Music      | 53 494    | 1 729 | 7 871 | 0.39 |

#### 3.1.2 评估指标与对比算法

为了验证本文将两个模型结合后的评分预测效果的有效性,选择了 4 个基准方法进行对比实验,分别为 ItemKNN(Item-based K-Nearest Neighbors)<sup>[16]</sup>、DeepICF(Deep Item-based Collaborative Filtering)<sup>[17]</sup>、MLP 和 FISM。其中,ItemKNN 是传统的基于物品的协同过滤方法,DeepICF 是解决物品间高阶连接(Higher-Order)关系问题的一种基于物品的协同过滤方法。

在实验中,首先根据数据中的时间戳信息来对每个用户以及物品进行由远及近进行编号和排序。对于 3 个数据集,本文都用同样的方法,对每个用户选择最后一次交互的数据作为测试集,其他部分作为训练集。关于评价指标,采用了两种不同的评估方法:  $NDCG$  (Normalized DCG) 和  $HR$  (Hit Ratio),对于两个评级指标的计算参考文献[15-16]。  $NDCG$  和  $HR$  的值越大,表示模型预测分值越精确。

#### 3.1.3 参数设置

为了避免模型过拟合,对于每一个方法本文都会在  $[10^{-7}, 10^{-6}, \dots, 10^{-1}, 10^0]$  范围内来调整正则化项系数的值。对于用户(物品)潜在因子向量的维度  $embedding\_size$ ,本文在进行不同方法对比中选取 32 进行测试,即  $embedding\_size = 32$ ;另外也对不同向量维度进行对比,即  $embedding\_size = 8, 16, 32, 64$ 。对于学习率,在实验中对不同大小的学习率选择  $[10^{-5}, 10^{-4}, \dots, 10^{-2}]$  进行实验,选出最佳学习率;本文选择的优化器为标准梯度下降法(Gradient Descent, GD)。

### 3.2 实验结果与分析

1) UICF 模型与 3 个基准模型在 2 个评估指标上的效果的展示。

UICF 与基准方法的对比结果如表 2 所示,加粗的数值表示最好结果。为了公平地进行比较,表中每个方法的  $embedding\_size$  均设为 32(本文将在下个实验中比较不同  $embedding\_size$  对 UICF 的影响)。从表 2 中可以看出,融合后的模型 UICF 在 3 个数据集上的  $HR$  和  $NDCG$  上基本上都取得了最大值( $HR$  和  $NDCG$  的值越大代表训练出来的模型在测试集上的测试分值越接近实际分值),特别是在 Foursquare 和 Music 两个数据集上,效果更加明显。

融合后的模型 UICF 的  $HR$  和  $NDCG$  的值在 top-5 和 top-10 上效果很明显,远大于其他三个对比方法的  $HR$  和  $NDCG$  的值;而在 MovieLens 数据集上,这两个值有了提高但并不是很明显。

2) 预训练与非预训练对实验效果的影响。

表 3 展示了在 3 个数据集上分别使用预训练和未使用预训练对实验效果的影响。从表 3 可以明显观察出,使用预训练后效果都明显好于没有预训练的,这也进一步说明了,预训练对基于 DL 模型的收敛和最终表现效果起到了极其重要的作用。

表 2 UICF 和基准方法的对比结果

Tab. 2 Comparison between UICF and benchmark methods

| 数据集        | 评估方法    | MLP     | DeepICF | FISM           | ItemKNN        | UICF           |
|------------|---------|---------|---------|----------------|----------------|----------------|
| MovieLens  | HR@5    | 0.517 5 | 0.520 6 | 0.551 8        | 0.375 5        | <b>0.555 6</b> |
|            | HR@10   | 0.698 5 | 0.698 1 | <b>0.720 1</b> | 0.535 3        | 0.717 5        |
|            | NDCG@5  | 0.347 1 | 0.349 3 | 0.371 9        | 0.255 1        | <b>0.376 6</b> |
|            | NDCG@10 | 0.404 1 | 0.405 3 | 0.425 9        | 0.305 2        | <b>0.427 8</b> |
| Foursquare | HR@5    | 0.168 4 | 0.161 5 | 0.156 8        | 0.197 8        | <b>0.230 0</b> |
|            | HR@10   | 0.243 8 | 0.253 3 | 0.233 0        | 0.252 9        | <b>0.294 7</b> |
|            | NDCG@5  | 0.111 5 | 0.105 6 | 0.101 0        | 0.140 0        | <b>0.183 5</b> |
|            | NDCG@10 | 0.134 4 | 0.134 8 | 0.125 0        | 0.157 7        | <b>0.204 7</b> |
| Music      | HR@5    | 0.260 8 | 0.243 4 | 0.246 3        | 0.264 9        | <b>0.278 7</b> |
|            | HR@10   | 0.362 0 | 0.345 8 | 0.349 3        | 0.357 4        | <b>0.389 8</b> |
|            | NDCG@5  | 0.182 1 | 0.168 7 | 0.168 8        | <b>0.188 0</b> | 0.184 3        |
|            | NDCG@10 | 0.215 4 | 0.201 6 | 0.203 7        | 0.217 9        | <b>0.219 9</b> |

表 3 预训练和非预训练方法的对比结果

Tab. 3 Comparison between method with pre-training and method without pre-training

| 数据集        | 非预训练    |         | 预训练     |         |
|------------|---------|---------|---------|---------|
|            | HR@10   | NDCG@10 | HR@10   | NDCG@10 |
| MovieLens  | 0.714 9 | 0.420 9 | 0.717 5 | 0.427 8 |
| Foursquare | 0.274 0 | 0.149 0 | 0.294 7 | 0.204 7 |
| Music      | 0.355 1 | 0.206 3 | 0.389 8 | 0.219 9 |

3) 维度  $d$  对实验效果的影响。




图 2 UICF 和基准方法在 3 个数据集上的  $HR@5$  走势图

Fig. 2  $HR@5$  of UICF and benchmark methods on three datasets

4 结语

本文提出了 FISM 模型和 MLP 模型结合后的 UICF 模型,并通过实验验证了 UICF 模型的有效性。本文主要利用了基于物品的推荐方法假设用户倾向于选择与他们之前喜欢的物品相似的物品,因此利用物品的相似作为推荐的依据,在解决数据稀疏性上具有优势。

参考文献 (References)

[1] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering [C]// Proceedings of the 26th International Conference on World Wide Web. Republic and Canton of Geneva, Switzerland: International World Wide Web Conferences Steering Committee, 2017:

对于物品维度  $d$  的大小考虑与其他基准方法在 3 个数据集上对比  $NDCG$  和  $HR$  值的变化,在实验中不同维度  $d$  对预测评分的影响。表 4 为维度  $d$  取值 8、16、32、64 时 UICF 的不同表现效果。从表 4 中可以看出,当维度  $d$  的值分别为 8、16、32、64 时  $HR$  和  $NDCG$  的值基本没什么波动,这也说明了维度  $d$  的大小对 UICF 的表现效果影响不大。

4) UICF 与基准方法在数据集上的  $HR@5$  走势图。

将各方法分别在 3 个数据集上运行 90 个 epoch 后,  $top@5$  时  $HR$  上的结果如图 2 所示。可以看出,本文方法把 MLP 方法和 FISM 方法结合后性能得到了提高,经过 90 个 epoch 的训练,本文的融合方法 UICF 在 3 个数据集上的结果好于对比方法;而且 UICF 模型从开始训练到训练结束时  $HR$  值的变化不大,这是因为 FISM 和 MLP 这两个模型在结合前都经过预训练,收敛较快。在 MovieLens 和 Foursquare 数据集上, UICF 模型的  $HR$  从开始上涨到一定值后就保持不变了, UICF 模型的效果高于其他几种对比方法;在 Music 数据集上,  $HR$  的值在 0.23 与 0.28 之间波动相对很大,这是由于学习率设置较大造成的,但这并不影响它的效果优于其他对比方法。

表 4 维度大小的影响

Tab. 4 The impact of dimension size

| 数据集        | 评估方法    | 预测向量的维数 |         |         |         |
|------------|---------|---------|---------|---------|---------|
|            |         | 8       | 16      | 32      | 64      |
| MovieLens  | HR@10   | 0.718 0 | 0.718 3 | 0.717 5 | 0.718 3 |
|            | NDCG@10 | 0.428 3 | 0.428 4 | 0.427 8 | 0.428 5 |
| Foursquare | HR@10   | 0.294 7 | 0.293 8 | 0.294 7 | 0.293 4 |
|            | NDCG@10 | 0.203 8 | 0.204 7 | 0.204 7 | 0.204 4 |
| Music      | HR@10   | 0.379 4 | 0.385 1 | 0.389 8 | 0.388 0 |
|            | NDCG@10 | 0.223 2 | 0.227 3 | 0.219 9 | 0.225 9 |

173-182.  
[2] 汪从梅,王成良,徐玲. 自适应用户的 Item-based 协同过滤推荐算法[J]. 计算机应用研究, 2013, 30(12): 3606-3609. (WANG C M, WANG C L, XU L. User-adaptive item-based collaborative filtering recommendation algorithm [J]. Application Research of Computers, 2013, 30(12): 3606-3609.)  
[3] HE X, ZHANG H, KAN M Y, et al. Fast matrix factorization for online recommendation with implicit feedback [C]// Proceedings of the 39th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2016: 549-558.  
[4] KOREN Y. Factorization meets the neighborhood: a multifaceted

- collaborative filtering mode [C]// Proceedings of the 14th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2008: 426-434.
- [5] SEDHAIN S, MENON A K, SANNER S, et al. AutoRec: autoencoders meet collaborative filtering [C]// Proceedings of the 24th International Conference on World Wide Web. New York: ACM, 2015: 111-112.
- [6] ZHANG Y, CHEN X. Explainable recommendation: a survey and new perspectives [EB/OL]. [2019-04-06]. <https://arxiv.org/pdf/1804.11192.pdf>.
- [7] HE X, HE Z, SONG J, et al. NAIS: neural attentive item similarity model for recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2018, 30(12): 2354-2366.
- [8] 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. New York: ACM, 2001: 285 - 295.
- [9] LINDEN G, SMITH B, YORK J. Amazon. com recommendations: item-to-item collaborative filtering [J]. IEEE Internet Computing, 2003, 7(1): 76-80.
- [10] NING X, KARYPIS J. SLIM: sparse linear methods for top-*N* recommender systems [C]// Proceedings of the 11th IEEE International Conference on Data Mining. Piscataway: IEEE, 497-506.
- [11] KABBUR S, NING X, KARYPIS G. FISM: factored item similarity models for top-*N* recommender systems [C]// Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2013: 659-667.
- [12] WU Y, DUBOIS C, ZHENG A X, et al. Collaborative denoising auto-encoders for top-*N* recommender systems [C]// Proceedings of the 9th ACM International Conference on Web Search and Data Mining. New York: ACM, 2016: 153-162.
- [13] ZHANG S, YAO L, SUN A, et al. NeuRec: on nonlinear transformation for personalized ranking [C]// Proceeding of the 27th International Joint Conference on Artificial Intelligence. Palo Alto, CA: AAAI Press, 2018: 3669-3675.
- [14] ERHAN D, BENGIO Y, COURVILLE A, et al. Why does unsupervised pre-training help deep learning? [J]. The Journal of Machine Learning Research, 2010, 11: 625-660.
- [15] HE X, CHEN T, KAN M Y, et al. TriRank: review-aware explainable recommendation by modeling aspects [C]// Proceeding of the 24th ACM International Conference on Information and Knowledge Management. New York: ACM, 2015: 1661-1670.
- [16] DESHPANDE M, KARYPIS G. Item-based top-*N* recommendation algorithms [J]. ACM Transactions on Information Systems, 2004, 22(1): 143-177.
- [17] XUE F, HE X N, WANG X, et al. Deep item-based collaborative filtering for top-*n* recommendation [J]. ACM Transactions on Information Systems, 2019, 37: 247-254.

This work is partially supported by the Science and Technology Program of Guizhou Province Science and Technology Department (Qiankehe Zhicheng[2019]2502).

**DENG Kai**, born in 1994, M. S. candidate. His research interests include recommendation system.

**HUANG Jiajin**, born in 1977, Ph. D., assistant research fellow. His research interests include recommendation system.

**QIN Jin**, born in 1978, Ph. D., associate professor. His research interests include computational intelligence.