

# 融合时间特性和用户偏好的卷积序列化推荐



陈晋鹏 胡哈蕾 张帆 曹源 孙鹏飞

北京邮电大学计算机学院(国家示范性软件学院) 北京 100876

**摘要** 推荐系统如今已被广泛应用于生活中,大大便利了人们的生活。传统的推荐方法主要是针对用户与物品的交互情况进行分析,分析用户与物品的历史记录,得到的只是用户过去对于物品的喜好程度。序列化推荐系统通过分析用户近一段时间与物品交互的序列,来考虑用户前后行为的关联性,能够获得用户短期内对物品的喜好程度。然而,序列化方法强调的是用户与物品在短期的联系,忽视了物品属性之间存在的关系。针对以上问题,文中提出了融合时间特性和用户偏好的卷积序列化推荐(Convolutional Embedding Recommendation with Time and User Preference, CERTU)模型。该模型能够分析物品之间存在的多样性关系,从而捕获用户对物品随时间变化的动态喜好程度这一特性。除此之外,该模型进一步考虑了物品序列中存在的单个物品和多个物品对下一物品推荐的影响。实验结果表明, CERTU 模型的性能优于当前的基线方法。

**关键词:** 推荐系统;卷积神经网络;序列化推荐;用户兴趣;时间特性

**中图法分类号** TP311

## Convolutional Sequential Recommendation with Temporal Feature and User Preference

CHEN Jin-peng, HU Ha-lei, ZHANG Fan, CAO Yuan and SUN Peng-fei

School of Computer Science(National Pilot Software Engineering School), Beijing University of Posts and Telecommunications, Beijing 100876, China

**Abstract** At present, recommendation system has been widely used in our life, which greatly facilitates people's life. The traditional recommendation method mainly analyzes the interaction between users and items and considers the history of users and items, and only obtains the user's preference for items in the past. The sequential recommendation system, by analyzing the interaction sequence of items in the recent period of time and considering the relevance between the user's previous and subsequent behaviors, can obtain user's preference for items in short term. It emphasizes the short-term connection between user and item, while ignoring the relationship between the attributes of the item. Aiming at the above problems, this paper presents a convolutional embedding recommendation with time and user preference (CERTU) model. This model can analyze the relations between items. It can obtain dynamic changes in user preferences. The model also considers the influence of individual item and multiple items to the next item. Experiments show that the performance of CERTU model is better than that of the current baseline method.

**Keywords** Recommendation system, Convolutional neural network, Sequential recommendation, User preferences, Temporal feature

### 1 引言

随着时代的发展,信息技术使人们的生活变得越来越便捷。人类社会已经进入了大数据时代,与此同时,人类也陷入了数据的困境。人们从数据中发现有价值的信息代价太大,很难从海量的数据中获取自己需要的信息。推荐系统正是为解决这样的问题而诞生的并得到了快速发展。传统的推荐系统往往从用户的偏好或者物品的特点进行分析。例如,基于内容的推荐系统对用户历史交互过的物品记录进行分析,将物品分为多种属性。

然而,用户的兴趣偏好并不是固定不变的,而是会随着时间的推移而发生变化。对于某一类物品,用户在拥有前可能对其有非常大的兴趣,而在拥有并使用一段时间后兴趣可能会消减,此时推荐系统不应向用户推荐同种物品。Top-N 序列化推荐主要处理用户过去一段时间内交互的物品序列,目的是预测用户在不久的将来可能喜欢的排名前 N 的项目,但很多 Top-N 推荐算法只考虑了用户的一般偏好,而忽视了物品在时间上的关系。例如,在电商领域,用户上一次或前几次的购买行为会大大影响后续的购买行为。用户购买了智能手机后可能很想购买耳机,此时推荐系统可以向该用户推荐耳

收稿日期:2020-12-22 返修日期:2021-04-19 本文已加入开放科学计划(OSID),请扫描上方二维码获取补充信息。

基金项目:国家自然科学基金(61702043)

This work was supported by the National Natural Science Foundation of China(61702043).

通信作者:陈晋鹏(jpchen@bupt.edu.cn)

机的相关物品;用户购买了耳机后,对于同类型耳机的需求不高,此时推荐系统不应向该用户推荐耳机的相关物品。这是考虑用户兴趣爱好受时间变化影响的典型场景。

与此同时,用户自身的偏好也是影响推荐系统的重要因素。例如,有的用户特别喜欢裙子,喜欢收藏各种类型的裙子,这是一种长期且固定的行为,推荐系统应考虑这些因素。单单考虑用户自身的兴趣爱好往往不够充分,物品之间也具有较为丰富的属性。对于物品来说,物品之间可以大致归纳为两种关系:互补与替代<sup>[1]</sup>。对于互补关系:两种物品之间的作用可以得到相互补充、相互支持,例如手机与耳机。对于替代关系:一种物品可以替代另一种物品发挥作用,用户若缺少某一种物品则可以选择另一种物品来替代,这种关系往往是同种类型不同品牌或不同样式的物品,例如不同品牌的耳机。物品除了属性之间有关联,在物品的序列中也能找到物品之间的影响关系。对于物品序列来说,不同物品可能独立对某一预测目标物品产生作用,也可能与不同物品联合起来对某一预测目标物品产生作用。例如,购买牛奶后可以推荐面粉,购买黄油后可以推荐面粉,联合考虑这两个购买行为推荐面粉的概率更高。直觉上,单个行为与联合行为也是影响推荐系统性能的重要因素。

综合以上分析,本文提出了融合时间特性和用户偏好的卷积序列化推荐(CERTU)模型。CERTU主要从用户和物品两个维度进行建模。在用户方面,不仅考虑用户的长期偏好,同时考虑用户对同一物品随时间变化的偏好。在物品方面,对单个物品预测与多个物品联合预测进行分析,同时对物品之间的关系进行分析。

本文的主要贡献如下:

(1)本文综合考虑用户和物品这两个方面进行建模。本文提出的模型不仅分析了时间对用户的影响,同时对物品进行了更为细粒度的划分,将物品之间的关系、单个物品预测以及多个物品联合预测进行融合。

(2)本文提出的模型不仅考虑了用户的短期偏好,同时对用户的长期偏好进行了分析,对用户的行为特点进行了更为细粒度的处理。

(3)本文将提出的 CERTU 模型在亚马逊数据集上进行实验。实验结果表明,CERTU 模型优于当前流行的方法。

本文第 2 节主要描述了相关工作;第 3 节主要介绍了本文提出的 CERTU 模型;第 4 节主要介绍实验部分,并分析了实验结果;最后总结全文。

## 2 相关工作

### 2.1 协同过滤算法

基于用户的协同过滤算法(UserCF)通常是给用户推荐与其兴趣相似的其他用户喜欢的物品。基于物品的协同过滤算法(ItemCF)向用户推荐与其之前喜欢的物品相似的物品。协同过滤算法虽然能够让机器更容易分析难以理解的信息(如音乐等),但难以捕捉用户对物品的兴趣随时间变化的特点,缺少对用户兴趣变化的分析。本文将物品之间的关系分为互补与替代,并在这两种关系的条件下分析用户对物品的兴趣随时间变化的特点。

### 2.2 序列化推荐

在现实生活中,人们的当前行为总是会受到历史行为因素的影响。序列化推荐考虑了用户的历史行为,通过分析用户过去的行为向用户推荐相应的物品。FPMC 模型将矩阵分解与马尔可夫链相结合,为每个用户学习了各自的转换矩阵,使用一个两两交互模型对换立方体来观察矩阵的转换,将相邻行为之间的转换信息嵌入物品潜在因素中进行推荐<sup>[2]</sup>。HRM 模型考虑了用户序列化行为对下一行为的影响,同时分析了用户的一般偏好,利用表征学习将用户序列化信息作为潜在因素<sup>[3]</sup>。上述模型虽然考虑了用户序列化行为,但考虑的主要相邻的两个行为,并且都应用于稠密数据上,在处理更为复杂的多步行为或稀疏数据时具有一定的局限性。Fossil 模型主要利用改进的马尔可夫链解决序列化推荐中数据稀疏的问题,在稀疏数据中捕获用户的动态兴趣<sup>[4]</sup>。

### 2.3 神经网络方法

RBM 模型第一次成功地将两层神经网络应用到推荐问题中<sup>[5]</sup>。LeCun 提出了世界上第一个卷积神经网络(Convolutional Neural Networks,CNN),主要是用于解决机器识别手字体的问题<sup>[6]</sup>。卷积神经网络一般用于图像处理,Zheng 等提出了深度合作神经网络(Deep Cooperative Neural Networks,DeepCoNN),创新性地将卷积神经网络用于处理用户的评论信息,从而提取出用户的特征<sup>[7]</sup>。上述模型虽然在推荐系统中获得了不错的效果,但都没有考虑序列化信息。卷积序列嵌入推荐模型(Convolutional Sequence Embedding Recommendation Model,Caser)借鉴了卷积神经网络处理图像的方式,将一个序列中的物品看作一张“图像”,通过卷积滤波器学习该“图像”的序列化模式<sup>[8]</sup>。Caser 模型对数据集有要求,在序列化密度较大的数据集(如 MovieLens)中有着良好的表现,但在一些序列化密度较低的商品数据集(如 Tmall)中进行训练得到的效果一般。LSTPM 模型在 RNN 的基础上考虑了用户短期与长期兴趣,同时分析用户最近浏览过的地点的地理相关性<sup>[9]</sup>。ARNN 模型对相似位置的序列规律性和转移规律性进行联合建模,捕捉控制用户移动性的上下文信息,从而获得更为有效的序列规则<sup>[10]</sup>。KRED 模型聚合新闻实体信息,利用知识图谱与多任务学习的方法来获得较好的推荐效果<sup>[11]</sup>。ACPR 算法采用消费者、物品和生产者三元组交互的方式提高了推荐准确度<sup>[12]</sup>。UIKG 算法利用基于图卷积神经网络的方法从用户知识图谱中学习用户表示向量,再将用户表示向量引入项目知识图谱中,有效地挖掘了用户的个性化偏好<sup>[13]</sup>。Chorus 模型主要分析用户对商品的偏好随时间变化的关系,同时考虑了商品之间的关系。本文综合考虑了上述两种模型 Caser 与 Chorus,在 Caser 中考虑了商品之间的关系与用户对商品偏好随时间变化的特点。

## 3 CERTU 模型

本文提出的考虑时间特性和用户偏好的卷积嵌入推荐模型(Convolutional Embedding Recommendation with Time and User Preference,CERTU)利用知识图谱的方式获取商品之间的关系,再通过分析用户购买记录规定时间核函数,得到物

品的表示向量。物品表示向量将通过卷积神经网络来学习序列化特征,捕捉其连续变化的特点。CERTU 考虑用户的一般兴趣爱好,将用户信息转化为用户表示向量,与最后卷积得到的物品向量进行连接。CERTU 模型主要分为 3 层:数据处理输入层、卷积层和全连接层。如图 1 所示,将物品关系构建知识图谱<sup>[14]</sup>,知识图谱中黄色线条表示两个物品具有先后购买的关系,说明二者的物品功能相互补充,而蓝色线条表示购买一个物品后用户只是查看了另一个物品并未购买,说明二者的物品功能相似。对于功能相互补充的这一类物品,用户对这一类物品的兴趣随时间变化的曲线往往呈现正态分布趋势<sup>[1]</sup>。对于功能类似的这一类物品,用户对这一类物品的兴趣随时间变化的曲线往往呈现两个正态分布趋势。用户的兴趣爱好不仅有短期特征,同时也存在长期偏好。数据输入处理层得到的物品向量将分别进入水平卷积层和垂直卷积层进行卷积计算。得到的结果将进入全连接层与用户长期偏好向量进行连接计算,最终得到预测结果。

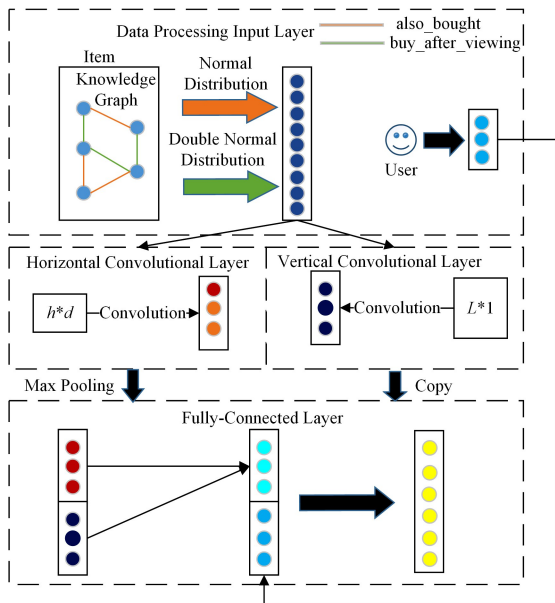


图 1 CERTU 模型图(电子版为彩色)

Fig.1 CERTU model

### 3.1 数据输入处理层

数据输入处理层主要分为两部分,分别为物品和用户。物品之间存在着上文所说的互补与替代关系,为了对物品以及物品之间的关系信息进行融合,可以将这些信息引入知识图谱中。物品之间的关系可以采用三元组形式进行构建<sup>[1]</sup>,例如(耳机、互补、手机),这样的三元组可以作为知识图谱中的元素,进而构建整个物品关系的知识图谱。对于物品,本文将功能互相补充的物品作为一类,用户购买某种物品后将会对该物品有互补关系的物品产生兴趣,例如用户在购买手机后会对耳机产生非常大的兴趣。在短时间内,用户可能会对某物品非常感兴趣,而随着时间的推移,用户会购买其他功能互补的物品,因此用户对该物品的兴趣爱好会随着时间的推移慢慢减小。用户的兴趣爱好随时间变化的曲线呈现出正态分布的趋势。兴趣随时间变化的时间函数表示为:

$$T(\Delta t) = N(\Delta t | 0, \sigma^2) \quad (1)$$

其中,  $N(\Delta t | 0, \sigma^2)$  表示平均值为 0 的正态分布,  $\sigma$  表示正态分

布的方差,  $c$  与物品的类别有关。

本文将功能相似的物品作为另一类,用户购买物品后,在短期内对功能相似的物品往往不再感兴趣或者不需要,这时用户的兴趣往往是负向消极的。而随着时间的迁移,用户购买的物品会出现损耗等问题,用户可能需要功能相似的物品作为替代,这时用户对功能相似的物品的需求增加或者兴趣热情上升,推荐系统此时应该向用户推荐功能相似的物品。而当用户购买了该物品后,又出现了上文中提到的不再感兴趣的情况,即用户对功能相似物品的兴趣爱好往往呈现上升到顶峰再下降的过程。由于用户对功能相似物品的兴趣爱好在刚开始时往往是负向的,因此曲线的纵坐标应由负值开始,由此时间变化曲线为两个正态分布,其中一个为负向正态分布。分布函数的计算式如下:

$$T(\Delta t) = -N(\Delta t | 0, \sigma^2) + N(\Delta t | \mu^c, \sigma^2) \quad (2)$$

其中,  $N(\Delta t | \mu^c, \sigma^2)$  中的  $\mu^c$  表示这类物品到达用户兴趣顶峰时与物品类别  $c$  有关。

图 1 中的用户图标代表用户长期以来的兴趣爱好,而 Chorus 模型中考虑得更多的是用户兴趣爱好随时间变化的特点,也可能是用户对物品需求程度的变化特点。而对于一些用户来说,他们可能会一直喜欢某类物品。对于这种情况,单独考虑用户对物品的需要程度往往比较片面,因此本文考虑用户的属性作为其长期偏好。

### 3.2 卷积计算层

卷积计算在图像处理中已经获得了巨大的成功。卷积计算在两个矩阵中进行,在两个矩阵中存在一个卷积核,卷积核以一定的步长在输入矩阵中进行移动,并进行点积计算,从而得到输出矩阵。Caser 模型将 CNN 应用于电影推荐中,对于电影观影记录,分析了多部电影分别推荐、多部电影合并推荐的情况,提出了水平卷积核与垂直卷积核<sup>[8]</sup>。对于物品,多个物品的购买记录推荐结果和单个物品的购买记录推荐结果在某些情况下可能不同,因此,对于物品来说,水平卷积核与垂直卷积核均适用。

本文将卷积层分为两种。一种是水平卷积层,它主要通过水平滤波器来实现,水平滤波器的大小为  $h \times d$ ,其中  $d$  表示水平滤波器的列数,  $h \in \{1, \dots, L\}$  表示水平滤波器的高度。本文用  $M^k$  表示水平滤波器,其中  $k$  表示水平滤波器的序号。本文定义上一层数据输入处理层得到的物品嵌入向量为  $I$ ,因此第  $i$  个物品水平卷积的计算式为:

$$item_h = f_a(I \odot M^k) \quad (3)$$

其中,  $f_a(\cdot)$  表示卷积层的激活函数,  $\odot$  表示内积运算符。

第二种是垂直卷积层,它主要通过垂直滤波器来实现,垂直滤波器的大小为  $L \times 1$ ,其中  $L$  表示垂直滤波器的高度,垂直滤波器的宽度默认为 1。垂直滤波器将从左往右与物品向量矩阵进行相乘,计算式如下:

$$item_v^k = I \cdot F^k \quad (4)$$

其中,  $F^k$  表示第  $k$  个垂直滤波器,  $item_v^k$  表示第  $k$  个计算得到的物品向量。最终将计算得到的物品向量组合起来,得到垂直卷积的物品表示:

$$item_v = [item_v^1, item_v^2, item_v^3, \dots, item_v^k] \quad (5)$$

### 3.3 全连接层

本文将水平卷积层与垂直卷积层的输出进行连接,全连接层对提取的特征进行组合后输出。两种卷积层的连接公式为:

$$\mathbf{g} = f_b \left( \mathbf{W} \left( \begin{bmatrix} e_1 \\ e_2 \end{bmatrix} + b \right) \right) \quad (6)$$

其中,  $f_b(\cdot)$  表示全连接层的激活函数,  $\mathbf{W}$  表示权重矩阵,  $b$  表示偏置项,  $\mathbf{g}$  表示物品卷积连接后得到的向量表示。

## 4 实验分析

本文将 CERTU 模型与当前最先进的方法进行比较。

### 4.1 实验设置

#### 4.1.1 数据集

实验所使用的数据为公开的亚马逊数据集<sup>[1]</sup>。亚马逊数据集中包括用户评论 ID、物品的基本信息、buy\_after\_viewing 和 also\_buy。本文将亚马逊数据集中的 buy\_after\_viewing 作为物品替代关系,将 also\_buy 作为物品互补关系。本文主要采用亚马逊数据集中的手机及配件数据集,如表 1 所列。

表 1 数据集统计信息

Table 1 Statistics of dataset

Dataset	Amazon Cellphones
Users	27 900
Items	10 300
Entry	193 200

#### 4.1.2 评价指标

本文采用留一法来计算实验结果,每次只留下一个样本作为测试集,其他样本作为训练集,将所有结果的平均值用以衡量模型的性能。本文采用 HR (Hit Ratio) 和 NDCG (Normalized Discounted Cumulative Gain) 作为评价指标。HR@K 计算正确预测的结果是否出现在 Top-K 列表中,如果出现,则记为一次命中,最后计算命中率。NDCG@K 则更加关注预测结果在排名中的位置。

#### 4.1.3 对比模型

(1)BPR<sup>[15]</sup>。该方法提出了一种双排序损失优化矩阵分解模型的方法,是目前优秀的基于隐式反馈数据非序列化物品推荐方法。

(2)Tensor<sup>[16]</sup>。该方法考虑了历史上下文信息,通过张量因子分解,用  $n$  维张量代替传统的二维用户-物品矩阵。

(3)GRU4Rec<sup>[17]</sup>。该方法使用 GRU 来获取推荐物品的排序分数。

(4)NARM<sup>[18]</sup>。该方法通过 GRU 与注意力机制提升了基于会话的序列化推荐的性能。

(5)CFKG<sup>[19]</sup>。该方法利用 TransE 模型来获取用户与物品、物品与物品之间的关系。

(6)SLRC<sup>[20]</sup>。该方法考虑了用户重复消费的习惯,对用户长期行为和短期行为进行分析。

(7)Caser<sup>[8]</sup>。该方法采用水平过滤器和垂直过滤器提取不同的物品序列模式信息,强调短期信息的影响。

### 4.2 实验结果

CERTU 和 7 种基线方法的实验结果比较如表 2 所列,

横轴表示各种方法的名称,纵轴表示性能指标。相比其他方法,CERTU 在 HR 和 NDCG 这两个指标上都能取得较好的性能。BPR 算法为传统的协同过滤算法,使用的是表示用户与物品交互关系的三元组信息。Tensor 通过将数据建模为一个用户、项目和上下文的张量来代替传统的用户项目矩阵,考虑了上下文的信息 Tensor 比传统的协同过滤算法更好。GRU4Rec 属于序列化推荐,应用 GRU 模型来推导排名分数进而进行推荐,它的性能比协同过滤算法更好。这也说明了序列化的特点对提升推荐效果起到了积极的作用。NARM 在 GRU 的基础上引入了注意力机制并将其应用于序列化推荐,同样比协同过滤算法的表现更好。CFKG 考虑了用户与物品的关系,将其转换成知识图谱,并使用 TransE 模型来学习图嵌入,性能比大部分的基线方法更好,说明将用户与物品的关系引入推荐系统中能够获得更好的效果。SLRC 考虑了短期效应和长期效应的影响,将 Hawkes 过程引入协同过滤中,性能效果在所有基线方法中表现最好,说明用户对物品的长期和短期的兴趣爱好对提升推荐系统的性能具有重要意义。Caser 利用卷积神经网络(CNN)对短期序列的信息进行提取,同时将序列模式分为点级和并级,它的性能比协同过滤算法更好,说明将卷积神经网络引入推荐系统中能够获得更好的效果。

表 2 不同方法的性能比较

Table 2 Performance comparison of different methods

Model	HR@5	HR@10	NDCG@5	NDCG@10
BPR	0.3357	0.4430	0.2309	0.2658
Tensor	0.3469	0.4315	0.2739	0.3012
Caser	0.3626	0.4723	0.2884	0.2524
NARM	0.4028	0.5014	0.2985	0.3303
CFKG	0.4023	0.5350	0.2833	0.3263
SLRC	0.4133	0.5140	0.3040	0.3368
GRU4Rec	0.4019	0.4997	0.3009	0.3325
CERTU	0.4359	0.5497	0.3153	0.3524

本文提出的 CERTU 模型比所有的基线方法的效果都更好,这表明考虑用户兴趣随时间变化的特性以及物品之间的关系有利于推荐。CERTU 模型同时以卷积神经网络为基础,将长期物品信息与短期物品信息的序列模式分为点级和并级,通过这样的方式能够让推荐系统获得更为丰富的信息来源。相比 CFKG 模型,CERTU 不仅考虑了物品之间的关系,还融合了物品之间的关系随时间变化的规律。相比 Caser,CERTU 不仅考虑了短期物品的序列,而且考虑了长期物品信息,同时还引入了物品之间的关系与用户兴趣随时间变化的特性,能够让推荐系统更为灵活,获得的效果更佳。

### 4.3 用户兴趣与物品关系建模的有效性

为了进一步证明用户兴趣随时间变化的特性与物品之间的关系对推荐效果有正向作用,本文在 CERTU 模型的基础上提出了该模型的变种 CERTU-I 与 CERTU-T。CERTU-I 模型不考虑物品之间的关系,忽略了物品之间存在的互补与替代关系。CERTU-T 模型未分析用户兴趣随时间变化的特性,用户兴趣将保持不变的状态。通过对比这 3 个模型,可以验证用户兴趣与物品关系建模对推荐的有效性。图 2 给出了 CERTU,CERTU-I 与 CERTU-T 这 3 个模型的实验结果,通

过对比可以看出, CERTU 的实验结果优于 CERTU-I 与 CERTU-T, 这表明用户兴趣随时间的特性与物品之间的关系能够提升推荐系统的推荐效果。




图2 用户兴趣与物品关系的有效性

Fig. 2 Effectiveness of user preference and the relationship of items

#### 4.4 参数分析

图3给出了学习率(Learning\_rate)对 HR@10 的影响效果,其中横坐标为  $10^{-x}$  中的  $x$  指数,学习率每次以 10 倍递减。可以看出,学习率从 0.1 开始,随着学习率越来越小, HR@10 的值越来越大,直到学习率为 0.001, HR@10 达到最大,其值为 0.5497。而当学习率大于 0.001 时, HR@10 逐渐减小。从以上分析可知,学习率为 0.001 时, HR@10 能获得最优的结果。




图3 学习率对 HR@10 的影响

Fig. 3 Influence of learning rate on HR@10

图4给出了批尺寸(Batch\_size)对 NDCG@10 的影响效果。图4中,横坐标批尺寸以 64 为初始值,每次变化以 2 倍增长进行模型训练。从图中可以看出,批尺寸从 64 变为 128 时 NDCG@10 有所下降,原因是批尺寸的值过小,网络收敛不稳定,在振荡中出现了 NDCG@10 值较大的情况。批尺寸从 128 开始, NDCG@10 开始逐渐增大。当批尺寸为 512 时, NDCG@10 达到最大值,为 0.3524。当批尺寸大于 512 时, NDCG@10 开始下降。在一定范围内,批尺寸增大能够一定程度地提升模型的性能,但随着批尺寸持续增大,模型泛化能力下降,最终导致 NDCG@10 值变小。




图4 Batch\_size 对 NDCG@10 的影响

Fig. 4 Influence of batch\_size on NDCG@10

的影响效果。图5中横坐标嵌入向量维度表示用户与物品向量的维度。从图中可以看出,嵌入向量维度等于 16 时为最低,原因是嵌入向量维度的值过小会导致模型获得的用户和物品特征信息较少,得到的性能指标较低。随着嵌入向量维度的增大, HR@5 也在不断增大。而在嵌入向量维度由 32 增大到 48 时,虽然 HR@5 出现了短暂的下降,但总体显示为性能上升的趋势。当嵌入向量维度达到 64 时, HR@5 达到最大值,为 0.4359。随着嵌入向量维度的值继续增大, HR@5 开始降低,原因是用户和物品的特征维度过多,出现了过拟合的情况。




图5 Embedding\_size 对 HR@5 的影响

Fig. 5 Influence of embedding\_size on HR@5

**结束语** 本文综合考虑物品之间存在的互补与替代关系,同时分析这两种关系下用户对该物品的好好程度,将其构建为相应的知识图谱,以此作为物品的表示向量。本文也考虑了物品序列中出现的单个物品与多个物品分别影响用户对下一物品的好好程度,采用水平滤波器与垂直滤波器分别对物品表示向量进行卷积计算处理。通过对以上因素的分析处理,本文提出了 CERTU 模型,经过实验对比,其结果比其他基线方法更好,体现了该模型的有效性。

未来,我们将从以下 3 方面进行 CERTU 模型的改进: 1) 物品中可能存在着流行度的属性,一些物品由于品牌方的宣传或者自身口碑较好,在一段时间内人们的关注度较高,模型应考虑物品流行度的属性特点; 2) 用户对物品的兴趣爱好随时间变化的曲线可能不只具有正态分布的特点,模型将利用更多类型的函数曲线进行分析; 3) 物品之间的关系可能具有更为丰富的表示,今后将对物品关系的挖掘进行更为深入的研究,以提升模型的预测能力。

#### 参考文献

- [1] WANG C Y, ZHANG M, MA W Z, et al. Make It a Chorus: Knowledge- and Time-aware Item Modeling for Sequential Recommendation[C]// Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval. 2020: 109-118.
- [2] STEFFEN R, CHRISTOPH F, LARS S. Factorizing personalized markov chains for next-basket recommendation[C]// Proceedings of the 19th International Conference on World Wide Web. 2010: 811-820.
- [3] WANG P F, GUO J F, LAN Y Y, et al. Learning hierarchical representation model for next basket recommendation[C]// Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. 2015: 403-412.

图5给出了嵌入向量维度(Embedding\_size)对 HR@5

- [4] RUINING H, JULIAN M. Fusing Similarity Models with Markov Chains for Sparse Sequential Recommendation[C] // 2016 IEEE 16th International Conference on Data Mining (ICDM). 2016; 191-200.
- [5] RUSLAN S, ANDRIY M, GEOFFREY H. Restricted Boltzmann machines for collaborative filtering[C] // Proceedings of the 24th International Conference and Machine Learning, 2007: 791-798.
- [6] LECUN Y, BOTTOU L, BENGIO Y. Gradient-based learning applied to document recognition[J]. Proceedings of the IEEE, 1998, 86(11): 2278-2324.
- [7] ZHENGL, NOROOZIV, YUPS. JointDeepModelingofUsersandItems Using Reviews for Recommendation[C] // Proceedings of the Tenth ACM International Conference on Web Search and Data Mining, 2017; 425-434.
- [8] TANG J X, WANG K. Personalized Top-N Sequential Recommendation via Convolutional Sequence Embedding[C] // Proceedings of the Eleventh ACM International Conference on Web Search and Data Mining, 2018; 565-573.
- [9] SUN K, QIAN T, CHEN T, et al. Where to Go Next; Modeling Long-and Short-Term User Preferences for Point-of-Interest Recommendation[C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2020; 214-221.
- [10] GUO Q, SUN Z, ZHANG J, et al. An Attentional Recurrent Neural Network for Personalized Next Location Recommendation[C] // Proceedings of the AAAI Conference on Artificial Intelligence, 2020; 83-90.
- [11] LIU D, LIAN J, WANG S, et al. KRED; Knowledge-Aware Document Representation for News Recommendations[C] // Fourteenth ACM Conference on Recommender Systems, 2020; 200-209.
- [12] ZHAN W J, HONG Z L, FANG L P, et al. Collaborative Filtering Recommendation Algorithm Based on Adversarial Learning [J]. Computer Science, 2021, 48(7): 172-177.
- [13] LIANG H H, GU T L, BIN C Z, et al. Combining User-end and Item-end Knowledge Graph Learning for Personalized Recommendation[J]. Computer Science, 2021, 48(5): 109-116.
- [14] BORDES A, USUNIER N, GARCIA-DURAN A, et al. Translating embeddings for modeling multi-relational data[J]. Advances in Neural Information Processing Systems, 2013, 26: 2787-2795.
- [15] STEFFEN R, CHRISTOPH F, ZENO G. BPR; Bayesian personalized ranking from implicit feedback[C] // Proceedings of the 25th Conference on Uncertainty in Artificial Intelligence, 2009: 452-461.
- [16] ALEXANDROS K, XAVIER A, LINAS B. Multiverse recommendation; n-dimensional tensor factorization for context-aware collaborative filtering[C] // Proceedings of the 4th ACM Conference on Recommender Systems, 2010: 79-86.
- [17] BALÁZS H, ALEXANDROS K, LINAS B. Session-based recommendations with recurrent neural networks[C] // International Conference on Learning Representations, 2016; 1-10.
- [18] PABLO L, CHEN L, YU H. Modeling user session and intent with an attention-based encoder-decoder architecture[C] // Proceedings of the 11th ACM Conference on Recommender Systems, 2017; 147-151.
- [19] ZHANG Y F, AI Q Y, CHEN X, et al. Learning over knowledge-base embeddings for recommendation[C] // Special Interest Group on Information Retrieval, 2018; 8-12.
- [20] WANG C Y, ZHANG M, MA W Z, et al. Modeling Item-Specific Temporal Dynamics of Repeat Consumption for Recommender Systems[C] // The World Wide Web Conference, 2019; 1977-1987.



**CHEN Jin-peng**, born in 1985, Ph.D, associate professor, Ph.D supervisor, is a member of China Computer Federation. His main research interests include social network analysis, recommendation system, data mining, and machine learning.

(责任编辑:李亚辉)