

# 控制与决策

Control and Decision

## 基于时间动态性的场感知分解机模型

燕彩蓉, 黄颜, 徐光伟, 黄永锋

引用本文:

燕彩蓉, 黄颜, 徐光伟, 等. 基于时间动态性的场感知分解机模型[J]. 控制与决策, 2020, 35(1): 169–173.

在线阅读 View online: <https://doi.org/10.13195/j.kzyjc.2018.0685>

---

## 您可能感兴趣的其他文章

Articles you may be interested in

### 基于多输出极限学习机的快速一致性分类器

A fast conformal classifier based on multi-output extreme learning machine

控制与决策. 2019, 34(3): 555–560 <https://doi.org/10.13195/j.kzyjc.2017.1172>

### 基于主成分分析的模糊时间序列模型的平稳化算法

Stabilization algorithm of fuzzy time series based on principal component analysis

控制与决策. 2018, 33(9): 1643–1648 <https://doi.org/10.13195/j.kzyjc.2017.0603>

### 带权重变化和决策融合的ELM在线故障检测

A new online extreme learning machine with varying weights and decision level fusion for fault detection

控制与决策. 2018, 33(6): 1033–1040 <https://doi.org/10.13195/j.kzyjc.2017.0274>

### 考虑维修优先权的多状态温贮备系统可靠性模型

Reliability analysis for multi-state warm standby system with repair priority

控制与决策. 2018, 33(11): 2029–2036 <https://doi.org/10.13195/j.kzyjc.2017.0718>

### 模糊聚类光滑支持向量机

Fuzzy clustering smooth support vector machine

控制与决策. 2017, 32(3): 547–551 <https://doi.org/10.13195/j.kzyjc.2015.1526>

### 含有时间幂次项的灰色预测模型病态特性

Morbid property of grey prediction model with time-power

控制与决策. 2016, 31(5): 953–956 <https://doi.org/10.13195/j.kzyjc.2015.0384>

### 三参数区间灰数信息下的动态多属性决策方法

Dynamic multi-attribute decision-making methods with three-parameter interval grey number

控制与决策. 2015(9): 1623–1629 <https://doi.org/10.13195/j.kzyjc.2014.0768>

### 基于具有自适应分段损失函数支持向量机的产品销售预测模型

Product sale forecasting method based on support vector machine with adaptive segmented loss function

控制与决策. 2015(10): 1803–1809 <https://doi.org/10.13195/j.kzyjc.2013.1541>

## 基于时间动态性的场感知分解机模型

燕彩蓉<sup>†</sup>, 黄 颜, 徐光伟, 黄永锋

(东华大学 计算机科学与技术学院, 上海 201620)

**摘 要:** 场感知分解机模型 FFM 能够有效解决高维数据特征组合的稀疏问题且具有较高的预测准确度和计算效率, 广泛应用于推荐系统领域. FFM 在建模时没有考虑时间动态性因素, 而真实场景中部分特征值会随着时间发生变化, 并在不同时间段对预测影响程度不同. 鉴于此, 提出一种基于时间动态性的场感知分解机模型 tFFM. 该模型考虑两类时间动态性: 偏置动态性和特征动态性. 前者从用户行为和物品流行趋势变化角度分别进行动态建模, 并基于时间窗口技术设置不同粒度的时间因子; 后者将特征细分为随时间变化的动态特征和保持稳定的静态特征, 采用 ReLU 激活函数建立时间函数. 采用统一特征编码方式, 并设计一种样本数据生成和存取策略, 能够大幅降低模型的训练和预测时间复杂度. 利用随机优化方法 Adam 对目标进行优化, 实验结果表明, tFFM 比目前广泛应用的 FM 和 FFM 相关方法具有更高的预测准确度.

**关键词:** 场感知分解机; 因子分解机; 推荐系统; 特征工程

中图分类号: TP273

文献标志码: A

## Field-aware factorization machine model based on time dynamics

YAN Cai-rong<sup>†</sup>, HUANG Yan, XU Guang-wei, HUANG Yong-feng

(School of Computer Science and Technology, Donghua University, Shanghai 201620, China)

**Abstract:** The field-aware factorization machine model (FFM) is widely used in the field of recommender systems since it can effectively solve the sparse problem of high dimensional feature combination with high prediction accuracy and computation efficiency. However, the FFM does not consider time dynamics in the modeling phase. In real scene, some feature values change with time and they will have different effects on prediction at different time. A field-aware factorization machine model based on the time dynamics FFM (tFFM) is proposed. The model takes into account two kinds of time dynamics, bias dynamics and feature dynamics. The former is modelled dynamically from user behavior changes and popularity of items respectively, and different time granularities based on time-window technique are used. The latter subdivides features into static features that maintain stability and dynamic features that change with time, and the time function is established by using the ReLU activation function. The unified feature encoding method is used and a sample data representation and access strategy is designed to greatly reduce the time complexity of model training and prediction. The stochastic optimization method Adam is used to optimize the target. The experimental results show that the tFFM can obtain higher prediction accuracy compared with the state-of-the-art methods related to factorization machines such as the FM and the FFM.

**Keywords:** field-aware factorization machine; factorization machine; recommender systems; feature engineering

## 0 引 言

云计算、移动互联网和社会媒体等技术的迅猛发展, 使得网络空间中所蕴含的信息量呈指数级增长. 推荐系统(recommender systems, RSs)是指通过分析 and 挖掘用户与物品之间的二元关系, 帮助用户从海量数据中发现其感兴趣的有形或无形的物品(如信息、服务、商品等), 生成个性化推荐列表<sup>[1]</sup>. 相关研究成果已融入日常生活的各项个性化服务中, 如在线电商<sup>[2]</sup>、信息检索<sup>[3]</sup> 和移动应用<sup>[4]</sup>. Top-k 推荐和评分

预测都可归结为预测问题.

场感知分解机(field-aware factorization machine, FFM)模型是因子分解机(factorization machine, FM)模型的改进版<sup>[5-6]</sup>. FFM 自提出以来, 在推荐/预测领域表现突出, 分别在 Criteo 和 Avazu 举办的广告点击率(click-through rate, CTR)预测竞赛中夺得冠军. 与 FM 一样, FFM 对所有文本特征变量进行交互建模, 通过共享特定特征隐向量来计算因式分解参数<sup>[6]</sup>. 不过在真实环境中, 文本特征变量通常很多, 而且并非

收稿日期: 2018-05-21; 修回日期: 2018-07-31.

基金项目: 国家自然科学基金项目(61402100).

<sup>†</sup>通讯作者. E-mail: cryan@dhu.edu.cn.

所有的特征交互都有效. 为了减少不必要的交互, 提高计算效率, 本课题组之前基于FFM提出了一种智能化场感知分解机模型iFFM. 该模型对关键属性进行提升, 运用特征工程技术将因子选择智能地嵌入到算法求解过程中<sup>[7]</sup>.

动态建模是推荐系统面临的挑战之一<sup>[1]</sup>. FM、FFM以及iFFM模型都没有考虑时间因素, 不能有效模拟用户行为偏好以及物品流行趋势的动态变化, 而时间动态性(time dynamics)在某些领域对于推荐和预测的准确度具有很大的影响<sup>[8-9]</sup>. 文献[10]将时间动态性应用到矩阵奇异值分解(singular value decomposition, SVD)模型中, 通过提取非视觉特征的时间动态因子, 分别对用户偏置和物品偏置进行动态建模, 取得了较好的推荐效果. 文献[8]同时对非视觉特征和视觉特征进行轻量级的时间建模, 虽然没有对变化趋势进行细分, 但也极大地改善了推荐结果. 用户行为和物品变化趋势有较大差异, 通常短期内物品的流行趋势变化不明显, 研究不同特征的不同变化趋势对于构建推荐模型具有重要意义.

本文基于FFM, 提出基于时间动态性的模型tFFM(time dynamics based FFM). 该模型考虑两类时间动态性, 对于偏置动态性, 采用不同的时间粒度从用户和物品角度进行建模; 对于特征动态性, 在模型中添加相应的时间函数. 本文创新点如下:

1) 数据预处理时, 采用统一特征编码方式, 设计一种样本数据生成和分块存取策略, 能够大幅降低模型训练和预测的时间复杂度.

2) 模型构建时, 提出一种基于时间动态性的场感知分解机模型tFFM, 从用户行为变化和物品流行趋势角度添加偏置动态性.

3) 模型训练时, 采用Adam方法优化损失函数. 真实数据集测试结果表明, tFFM模型具有更高的准确度.

## 1 相关定义

**定义1 (FM)** FM于2010年提出, 旨在解决稀疏数据情况下特征组合的参数学习不充分的问题, 度为2的FM模型<sup>[5]</sup>为

$$\hat{y}(x) := w_0 + \sum_{i=1}^n w_i x_i + \sum_{i=1}^n \sum_{j=i+1}^n \langle v_i, v_j \rangle x_i x_j. \quad (1)$$

其中:  $n$ 为样本特征数量,  $x_i$ 为第 $i$ 个特征值,  $w_0 \in R$ ,  $W \in R^n$ ,  $V \in R^{m \times n}$ ,  $\langle v_i, v_j \rangle$ 表示大小为 $k$ 的两个向量的点积.

每维特征 $x_i$ 通过训练, 学习出唯一对应的隐向量 $v_i$ ,  $\langle v_i, v_j \rangle$ 即为特征交叉项 $x_i x_j$ 的权重参数. 由式

(1)可见, FM模型的复杂度为 $O(kn^2)$ , 但通过二次项化简, 其复杂度可优化到 $O(kn)$ . 通过随机梯度下降(stochastic gradient descent, SGD)方法对FM进行训练, 模型各个参数的梯度可为线性.

**定义2 (FFM)** FFM在FM的基础上, 将相同性质的特征归于同一个场(field), 所有特征被分入 $f$ 个场, 特征 $x_i$ 有自身唯一对应的场 $f_i$ . 在FFM中, 每一维特征 $x_i$ 针对其他特征的每一个场 $f_j$ 都会学习产生一个隐向量 $v_{i, f_j}$ , 从而特征 $x_i$ 会学到 $f$ 个与之对应的隐向量(相比FM, 特征通过训练学习出唯一对应的隐向量 $x_i$ ). 因此, 隐向量不仅与特征相关, 也与场相关. 假设样本的 $n$ 个特征属于 $f$ 个场, 那么FFM的二次项则有 $nf$ 个隐向量. 根据FFM的场敏感特性, 可以导出其模型方程<sup>[6]</sup>为

$$\hat{y}(x) := w_0 + \sum_{i=1}^n w_i x_i + \sum_{i=1}^n \sum_{j=i+1}^n \langle v_{i, f_j}, v_{j, f_i} \rangle x_i x_j, \quad (2)$$

其中 $f_j$ 为第 $j$ 个特征所属的场. 如果隐向量的长度为 $k$ , 那么FFM的二次参数有 $nfk$ 个, 远多于FM模型的 $nk$ 个. 此外, 由于隐向量与场相关, FFM的交叉项并不能够像FM那样作化简, 模型预测复杂度为 $O(kn^2)$ .

**定义3 (基准预测(baseline predictor))** 由于不同用户在评分时具有不同倾向, 不同物品在用户群中也有不同反响, 为了更准确地构建预测模型, 引入更细粒度的偏置<sup>[10]</sup>, 表示如下:

$$b_{ui} := \mu + b_u + b_i. \quad (3)$$

其中:  $b_u$ 和 $b_i$ 分别为用户 $u$ 和物品 $i$ 的观察偏置,  $b_{ui}$ 可用于代替式(2)中的 $w_0$ . 随着时间变化 $b_u$ 和 $b_i$ 会受到影响, 可以将这两个静态参数调整为时间动态函数<sup>[10]</sup>, 模型如下:

$$b_{ui}(t) := \mu + b_u(t) + b_i(t). \quad (4)$$

其中:  $b_{ui}(t)$ 为用户 $u$ 对物品 $i$ 在 $t$ 时间的基准预测,  $b_u(t)$ 和 $b_i(t)$ 分别为用户 $u$ 和物品 $i$ 随时间变化的偏置函数.

本文在建模时参考定义1~定义3, 并将其有效地结合到新的模型中.

## 2 tFFM模型

### 2.1 特征预处理

特征预处理为模型构建提供数据基础, 本文采用统一特征编码方式, 即统计所有特征值的个数. 假设共有 $n$ 个特征值, 就从1到 $n$ 对特征值进行编码, 每个特征值获取唯一对应的特征编号(feature index). 推荐模型所面对的数据特征可以分为3类: 无序特征

(categorical feature)、有序特征 (ordinal feature) 和数值型特征, 对这些特征进行如下预处理: 首先, 将无序特征转化为数值型特征, 假设某电子商务网站中耳机的品牌包括 Panasonic, Sennheiser, Sony, Sound Intone, Bose, Beats, Audio-Technica 和 Ausdom 八种, 那么这 8 种品牌分别对应 8 个特征值. 其次, 将有序特征转化为数值型特征, 有序特征与无序特征在处理上没有区别, 例如一个人的教育背景 (education) 有 3 种取值: bachelor, master 和 phd, 分别对应 3 个特征值. 对于数值型特征, 事先对其进行离散化处理, 如年龄可以划分为 [0, 18], [19, 25], [26, 35], [36, 50], [51, 60] [61, 75], 这 6 个年龄段将对应 6 个特征值. 同理, 电影的发行时间等特征也需要进行离散化处理.

### 2.2 时间动态性

实际应用场景中, 用户的决策行为通常会随着时间发生变化, 其他有关因素如促销或新产品的出现也会对用户的决策产生重要影响. 因此, 考虑时间因素不仅可以提高模型预测准确度, 而且可以更好地对预测结果进行解释. 本文考虑两类时间动态性: 偏置动态性和特征动态性, 前者从用户行为变化和物品流行趋势角度分别进行考虑.

1) 偏置动态性. 分为用户的偏置动态性和物品的偏置动态性. 设置用户偏置动态性的原因在于: 用户对物品的评分会随时间发生变化, 如用户 Aphro 过去倾向于给电影《秒速五厘米》评 9 分, 现在她对于动画片的狂热减退, 只会评 8 分.

对于用户和物品的偏置动态性表示, 可以在其用户偏置  $b_u$  和物品偏置  $b_i$  中添加如下时间函数:

$$b_u(t) = b_u + \tau_u(t), \quad b_i(t) = b_i(t) + \tau_i(t). \quad (5)$$

其中:  $\tau_u(t)$  为关于用户评分行为的时间函数,  $\tau_i(t)$  为关于物品评分时间的函数. 静态与动态偏置合成之后构成总体偏置.

本文设计时间窗口 (time-window) 对  $\tau_u(t)$  和  $\tau_i(t)$  进行建模. 将数据的时间线 (time line) 分割成离散的时间段 (epoch), 在不同的时间段, 不同的属性因素占据主导地位, 从而影响用户的决策. 模型中可设置含有  $N$  个时间段 (如  $N$  取值 4 代表季度, 取值 12 则代表月份, 根据数据集的具体情况确定), 最终的模型偏置可以表示为

$$w_{ui}(t) = w_0 + b_u(t) + b_i(t). \quad (6)$$

2) 特征动态性. 对于属性  $x_i$ , 细分成随时间变化的动态属性和保持稳定的静态属性, 静态属性无需处理, 动态属性则添加时间变化函数, 调整为

$$x_i(t) = x_i f(t), \quad (7)$$

其中  $f(\cdot)$  为非线性激活函数, 本文采用 ReLU 函数. 相对于 sigmoid 函数, ReLU 具备引导适度稀疏的能力, 且速度快, 精确度高. 这些偏置函数和属性函数将会加入到 tFFM 模型中.

### 2.3 模型表示

设数据集样本  $x$  由 4 个部分组成: 用户的属性特征向量、物品的属性特征向量、用户与物品之间的交叉积特征和会话中的特征. 模型可表示为

$$\hat{y}(ui) := w_{ui}(t) + \sum_{j=1}^n w_j x_j + \sum_{p=1}^n \sum_{q=p+1}^n \langle v_{p,f_q}, v_{q,f_p} \rangle x_p x_q. \quad (8)$$

其中:  $w_{ui}(t)$  为评分偏置:  $w_0 = \sum_{(u,i) \in T} r_{ui} / |T|$  是全局评分偏置;  $b_u$  和  $b_i$  分别为用户  $u$  对不同物品的评分偏置和不同用户对物品  $i$  的评分偏置,  $b_u = \sum_{i \in R(u)} r_{ui} / |R(u)|$ ,  $b_i = \sum_{u \in R(i)} r_{ui} / |R(i)|$ ;  $r_{ui}$  为用户  $u$  对物品  $i$  的评分, 若是广告点击率等二分类问题, 则  $r_{ui}$  取值为 0 或者 1, 表示用户是否对广告进行点击;  $|T|$  为数据集中实例的个数, 由于本文采用 tensorflow 平台,  $|T|$  表示每次批处理所选择的样本个数 (batch size);  $R(u)$  为批处理中用户  $u$  评分过的物品集合,  $R(i)$  为批处理中对物品  $i$  进行过评分的用户集,  $|R(u)|$  和  $|R(i)|$  分别为相应集合中的元素个数.

将编码后的数据存储到 label 文件、bias 文件、feature 文件和 value 文件中, 按行合并即可得到实验所需的完整数据. 此时式 (8) 中二阶交互可调为

$$\sum_{p=1}^f \sum_{q=p+1}^f \langle v_{n_p, f_q}, v_{n_q, f_p} \rangle x_{n_p} x_{n_q}.$$

其中:  $f$  为 field\_idx 的个数;  $n_j$  为值  $x_{n_j}$  在第  $j$  个域中对应的 feature\_idx, 个数为  $n$ ;  $f_p$  和  $f_q$  为值  $x_{n_p}$  和  $x_{n_q}$  对应的 field\_idx. 假设隐向量的长度为  $k$ , 则 tFFM 的二次项参数有  $nfk$  个, 其空间复杂度与 FFM 相同, 时

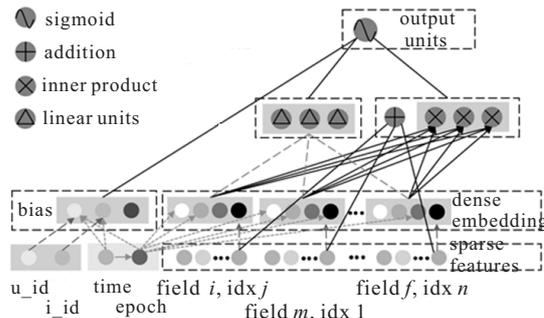


图 1 tFFM 模型的结构

间复杂度为 $O(kf^2)$ . 由于实际应用中 $f \ll n$ , 因此相比FFM的预测时间复杂度 $O(kn^2)$ , tFFM能够极大地节省计算时间. 模型结构如图1所示, 实线为normal connection, 虚线为weight\_1 connection, 实线箭头为weight\_2 connection, 虚线箭头为embedding, 点线箭头为temporal.

### 3 模型训练

对于tFFM模型, 建立目标优化函数

$$J(\theta) = \arg \min \left( \sum_{(c,x,y,t) \in S} cl(\hat{y}(x,t|\theta), y) + \frac{\lambda}{2} \|\theta\|^2 \right). \quad (9)$$

其中:  $c$ 为样本个数的倒数,  $l(*)$ 为损失函数,  $\theta \in \{b_u, b_i, w_j, w_{p,f_q}, w_{q,f_p}\}$ ,  $\lambda$ 为正则化参数. 本文主要关注电影等多评分预测, 损失函数选取平方损失函数, 即 $l(\hat{y}(x,t|\theta)) = (\hat{y}(x,t|\theta) - y)^2$ .

采用Adam优化目标函数 $J(\theta)$ . 对非零样本数据和特征进行归一化处理, 对于零值样本数据和特征, 其归一化系数为零. 对于样本特征, 采用单个样本的损失函数计算模型的梯度 $\nabla_{\theta} J(\theta)$ . tFFM的训练算法如下, 其中 $|u|$ 为用户个数,  $|i|$ 为物品的个数.

**算法1** training tFFM using Adam.

```

input:  $N$  instances with feature vectors  $r$ ;
output average error  $J(\theta)$ .
initialize parameters and normalize  $x$ 
calculate rating time set for all users
     $dic_u = \{u : [t_1, t_2, \dots]\}$ 
calculate rating time set for all items
     $dic_i = \{i : [t_1, t_2, \dots]\}$ 
segment time epoch
for  $r \in \{1, 2, \dots, N\}$  do
    sample a quaternion  $(y, u, i, t)$ 
    calculate  $b_u(t)$  and  $b_i(t)$  by 式(5)
    for  $j \in \{1, 2, \dots, f\}$  do
        calculate sub gradient for  $w_j$ 
        for  $d \in \{1, 2, \dots, k\}$  do
            update gradient for  $w_j$ 
        end
    end
end
for  $p \in \{1, \dots, f\}$  do
    for  $q \in \{p+1, p+2, \dots, f\}$  do
        calculate sub gradient
        for  $q \in \{1, 2, \dots, k\}$  do
            update gradient
        end
    end
end
end
end

```

calculate  $J(\theta)$  by 式(9)

update  $w_0, b_i, b_u, w_f, w_{p,f_q}$

end

tFFM的偏置项参数个数为 $(|u| + |i| + 1)$ , 一次项参数个数为 $nk$ , 二次项参数个数为 $nfk$ , 空间复杂度为 $O(nk(f+1))$ , tFFM的一次项计算时间为 $kf$ , 二次项计算时间为 $nf^2$ , 时间复杂度为 $O(kf(f+1))$ . 比较而言, FFM和iFFM的时间复杂度都是 $O(kn^2)$ , 而 $f \ll n$  (一般情况下 $f$ 小于20, 而 $n$ 大于1000), 所以tFFM的算法相对更高效.

### 4 实验和结果

实验采用的数据集包括: R4-Yahoo! Movies User Ratings and Descriptive Content Information, v.1.0(简称为yahoo)数据集, MovieLens 1M(简称为ml-1m)数据集和MovieLens 10M(简称为ml-10m)数据集. yahoo数据集是7642名用户对11915部电影的评分记录; ml-1m数据集是6040名用户对3900部电影大约100万次评分, 评分密度为4.2%; ml-10m数据集是71567名用户对65133部电影的大约1000万次评分, 评分密度为2.1%. 采用随机采样方式, 按照8:1:1的比例将数据集划分为训练集、验证集和测试集. 实验使用的主要评价标准是推荐系统中常用的均方根误差(root mean square error, RMSE). 设计两组实验, 分别对SVD、libFM、libFFM(将二分类问题修改为回归问题, 采用平方损失函数)、iFFM和tFFM模型进行准确率对比. tFFM可看作是添加了偏置和时间因素的FFM模型, 不考虑时间因素、只考虑偏置的模型简称为tFFM-1, 都考虑的模型简称为tFFM-2.

首先考虑模型参数初始学习率 $\eta$ (此时 $\lambda = 0.05$ )和正则化参数 $\lambda$ (此时 $\eta = 0.001$ )对tFFM-2的影响. 以ml-1m数据集为例(时间段数 $|ep| = 4$ , 模型参数 $\beta = 4$ , 隐向量长度 $k = 20$ ), 实验结果见图2和图3.

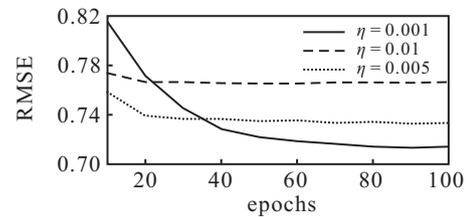


图2 ml-1m上初始学习率对RMSE的影响

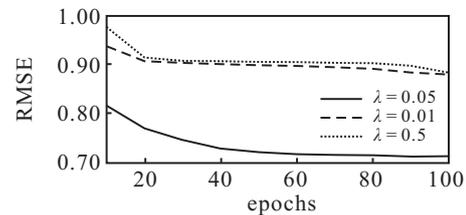


图3 ml-1m上正则化参数对RMSE的影响

由图2可见,学习率 $\eta$ 初始取值较大时,模型能够很快收敛,但是较小的学习率能够获得更高的准确度. 正则化参数通常是为了防止过拟合,较大的正则化参数往往可以使得模型训练准确与测试准确度非常接近,但同时会影响模型准确度. 由图3可见, $\lambda = 0.05$ 时模型准确度最高, $\lambda = 0.01$ 时模型欠拟合, $\lambda = 0.5$ 时模型出现过拟合.

关于时间段数对模型准确度的影响,实验发现: $\eta = 0.001$ , $\beta = 0.4$ , $k = 20$ , $\lambda = 0.05$ ,模型在ml-1m取得了较小的RMSE值0.7146,随着 $|ep|$ 增大, RMSE并没有明显减小. 由此可以得出tFFM-2对 $|ep|$ 的敏感度不是很强.

第2组实验为SVD、libFM、libFFM、iFFM、tFFM在3个数据集上的准确度测试,所有模型中 $k = 20$ , $\lambda = 0.05$ , $\eta = 0.001$ ,实验结果如表1所示.

表1 模型准确度比较

数据集	SVD	libFM	libFFF	iFFM	tFFM-1	tFFM-2
yahoo	0.8989	0.7845	0.7612	0.7257	0.7065	-
ml-1m	0.8560	0.8079	0.7856	0.7654	0.7230	0.7128
ml-10m	0.7950	0.7852	0.7783	0.7369	0.7458	0.7204

由表1,对实验结果分析如下: 1) libFFM比libFM取得了更好的结果,在3个数据集上准确度分别提高了3.0%,2.8%,0.9%,libFFM将相同性质的特征归于同一个场可提高准确度. 2)相比于SVD,libFM预测准确度有很大提高,在3个数据集上准确度分别提高了12.8%,5.6%,1.2%,在ml-10m上提高不大是因为数据集属性特征相对太少. 3)tFFM-1模型因为考虑了用户和物品的偏置,比libFFM取得了更高的准确度,对于3个数据集,tFFM-1得到的RMSE分别减少了7.2%,8.0%和4.2%. 4)对于数据集ml-1m,tFFM-2比tFFM-1准确度提高了1.4%,对于数据集ml-10m,tFFM-2比tFFM-1准确度提高了3.4%,从而可以得出,考虑时间因素能够提高模型预测准确度.

## 5 结论

本文针对FM及FFM相关模型忽视了时间对于偏置和特征的影响,提出了基于时间动态性的模型tFFM. 该模型考虑用户行为和物品流行趋势的变化因素进行动态建模,同时采用统一特征编码方式,设计一种样本数据生成和存取策略,大幅降低了模型的训练和预测时间复杂度. 在未来的研究中,将专注于面向大规模数据集时,tFFM如何应对单机的内存溢出问题,以及多机的并行处理.

## 参考文献(References)

- [1] Bobadilla J, Ortega F, Hernando A, et al. Recommender systems survey[J]. Knowledge-Based Systems, 2013, 46(1): 109-132.
- [2] Gomez-Uribe C A, Hunt N. The netflix recommender system: Algorithms, business value, and innovation[J]. ACM Transactions on Management Information Systems, 2016, 6(4): 1-11.
- [3] 尹祎, 冯丹, 施展. 一种基于效用的个性化文章推荐方法[J]. 计算机学报, 2017, 40(12): 2797-2811. (Yin W, Feng D, Shi Z. A personalized paper recommendation method based on utility[J]. Chinese Journal of Computers, 2017, 40(12): 2797-2811.)
- [4] 黄璐, 林川杰, 何军, 等. 融合主题模型和协同过滤的多样化移动应用推荐[J]. 软件学报, 2017, 28(3): 708-720. (Huang L, Lin C J, He J, et al. Diversified mobile app recommendation combining topic model and collaborative filtering[J]. Journal of Software, 2017, 28(3): 708-720.)
- [5] Rendle S. Factorization machines with libfm[J]. ACM Transactions on Management Information Systems, 2012, 3(3): 1-22.
- [6] Juan Y, Zhuang Y, Chin W S, et al. Field-aware factorization machines for CTR prediction[C]. The 10th ACM Conference on Recommender Systems. New York: ACM, 2016: 43-50.
- [7] Yan C, Zhang Q, Zhao X, et al. An intelligent field-aware factorization machine model[C]. The 22nd International Conference on Database Systems for Advanced Applications. Berlin: Springer, 2017: 309-323.
- [8] He R, Fang C, Wang Z, et al. Vista: A visually, socially, and temporally-aware model for artistic recommendation[C]. The 10th ACM Conference on Recommender Systems. New York: ACM, 2016: 309-316.
- [9] He R, McAuley J. Ups and Downs: Modeling the visual evolution of fashion trends with one-class collaborative filtering[C]. The 25th International Conference on World Wide Web. Switzerland: IW3C2, 2016: 507-517.
- [10] Koren Y. Collaborative filtering with temporal dynamics[J]. Communications of the ACM, 2010, 53(4): 89-97.

## 作者简介

燕彩蓉(1978—),女,副教授,博士,从事数据挖掘与机器学习等研究,E-mail: cryan@dhu.edu.cn;

黄颜(1993—),男,硕士生,从事推荐系统模型的研究,E-mail: 286646261@99.com;

徐光伟(1969—),男,副教授,博士,从事云存储等研究,E-mail: gw Xu@dhu.edu.cn;

黄永锋(1971—),男,副教授,博士,从事图像处理等研究,E-mail: yfhuang@dhu.edu.cn.

(责任编辑: 郑晓蕾)