

# 一种结合矩阵分解和深度学习技术的 POI 推荐模型

董丽丽, 秦蕾, 张翔

(西安建筑科技大学 信息与控制工程学院, 西安 710055)

**摘要:** 基于位置社交网络 (LBSN) 的兴趣点 (POI) 推荐算法是近年来的研究热点, 有效的 POI 推荐具有极大的经济和社会效益; 针对 LBSN 中的数据稀疏问题、用户细粒度兴趣 (即用户的长期和短期兴趣) 序列建模问题和联合多种影响因素的 POI 推荐问题, 研究一种结合矩阵分解和带有注意力机制深度学习技术的 POI 推荐模型 (CF-ADNN); 一方面, 构造特征矩阵缓解签到数据稀疏问题, 通过矩阵分解得到隐藏因子, 计算 POI 的特征向量; 另一方面, 构建一种带注意力机制的用户细粒度兴趣的序列建模方式, 有效学习用户长期和短期的兴趣特征, 提高 POI 推荐精确度; 结合上述两种方法, 最终得到可以融合多种影响因素的 POI 推荐模型; 并通过对比试验, 进一步验证模型的推荐效果。

**关键词:** POI 推荐; 矩阵分解; 深度学习; 注意力机制

## A POI Recommendation Model Combining Matrix Factorization and Deep Learning Technology

Dong Lili, Qin Lei, Zhang Xiang

(School of Information and Control Engineering, Xi'an University of Architecture and Technology, Xi'an 710055, China)

**Abstract:** Point-of-Interest (POI) recommendation algorithm based on the Location-based social network (LBSN, location-based social network) is a hot research topic in recent years. Effective POI recommendation has great economic and social benefits. The POI recommendation model (MF-ADNN) which combines matrix factorization and deep learning with attention mechanism is studied, aiming at the data sparsity problem in LBSN, user's fine-grained interest (i. e. long-term and short-term interest) sequence modeling problem and the POI recommendation problem of combining various influencing factors. On the one hand, feature matrix is constructed to alleviate the problem of sparse check-in data, and hidden factors are obtained by matrix factorization to calculate POI feature vectors; On the other hand, construct a sequence modeling method of user's fine-grained interest with attention mechanism, effective learning long-term and short-term interest characteristics of users and improving the accuracy of POI recommendation. Combining the above two methods, the POI recommendation model that can integrate a variety of influencing factors is finally obtained. Through the comparison test, the recommended effect of the model is further verified.

**Keywords:** POI recommendation; matrix factorization; deep learning; attention

### 0 引言

近年来, LBSN 平台吸引了无数用户并产生了大量签到数据。通过对签到数据建模并结合传统推荐技术来实现用户 POI 的推荐, 可以从推荐结果中得出用户的日常喜好和行为模式; 帮助商家发现潜在客户、调整经营策略, 具有极大的经济效益<sup>[1]</sup>。

目前, 基于 LBSN 的用户 POI 推荐研究, 无论是基于传统协同过滤、矩阵分解方法还是基于影响因素或文本信

息考虑的 POI 推荐模型均存在以下的问题:

大部分 POI 推荐研究采用传统协同过滤算法<sup>[2-4]</sup>, 对用户和签到的 POI 进行建模, 给出最后推荐。但这种基于 LBSN 的用户签到信息很容易遭遇数据稀疏问题。又有研究者提出基于矩阵分解的协同过滤算法<sup>[5-6]</sup>。分别用一个隐式向量代表用户和 POI, 隐式向量间的内积表示用户和 POI 之间的线性交互。这些算法有效缓解了数据稀疏问题且对用户和个性化 POI 特征提取做出改进。但由于隐式向量内积操作只是简单向量间的线性乘法, 不足以提取用户和 POI 之间高阶历史交互特征 (非线性特征), 尤其是无法捕捉用户签到的序列特征。

为了解决序列建模的问题, 有研究者<sup>[7]</sup>利用矩阵分解和马尔科夫模型建模用户的序列行为, 但马氏模型只考虑用户访问的最近一个 POI 点信息, 所包含信息量太少, 不能很好表示用户行为特点。深度神经网络能够有效学习和提取多个特征的高阶非线性关系, 特别是循环神经网络 (RNN) 能够很好地对序列进行建模。Q. Liu 等人<sup>[8]</sup>提出 ST-RNN 模型, Zhao 等人<sup>[9]</sup>改进提出 ST-LSTM 模型。

收稿日期: 2019-11-19; 修回日期: 2019-12-10。

**基金项目:** 国家自然科学基金项目 (61701388); 陕西省自然科学基金基础研究计划资助项目 (2018JM6080); 西安市科技局科技创新引导项目 (201805033YD11CG17(1)); 西安市科技局科技创新引导项目 (201805033YD11CG17(2))。

**作者简介:** 董丽丽 (1960-), 女, 福建福州人, 硕士生导师, 教授, 主要从事数据挖掘、机器学习等方向的研究。

张翔 (1972-), 男, 陕西咸阳人, 硕士生导师, 副教授, 主要从事增强现实、机器学习等方向的研究。

这类模型虽然能有效建模用户签到的序列行为，但从用户细粒度兴趣来看：单一的 RNN 无法同时学习用户长期和短期的兴趣特征，从模型整体来看：忽略了多影响因素之间的联合作用。

综合以上问题，文章的具体研究内容如下：1) 针对签到数据的稀疏问题，提出一种基于分解矩阵的协同过滤方法。计算得到 POI 的特征向量；2) 针对用户细粒度兴趣（即长期兴趣和短期兴趣）序列建模问题，提出一个基于注意力机制（Attention）的深度神经网络模型。可分别提取用户长、短期兴趣特征<sup>[10-11]</sup>；3) 针对多影响因素之间的联合作用问题，将矩阵分解提取的 POI 特征向量以及计算得到的用户特征向量按照用户签到序列输入带有注意力机制的深度神经网络进行模型训练。设计得到多特征高阶非线性交互的 POI 推荐模型（MF-ADNN）。该模型可对 LBSN 中的地理、时间、社交和序列影响进行综合考虑，分别对用户签到数据集的 4 阶段（早、午、晚、夜）进行训练，做出不同时间段的 POI 推荐。

### 1 问题定义和用户细粒度兴趣分析

POI 推荐模型旨在为用户推荐其感兴趣的 POI 点。表 1 是本文用到的基本数学符号及含义。

表 1 基本数学符号及含义

符号	含义
$u, p, U, P$	用户, POI, 用户集合, POI 集合
$t$	当前时刻
$D, D_u$	所有签到集合, 用户历史签到
$P_u$	用户 $u$ 访问过的 POI 集
$P_p$	表示访问过兴趣点 $p$ 之后被连续访问的 POI 集合
$l_p, r_p$	$p$ 的地理坐标、类别
$O, G, R$	POI 同现矩阵、位置近似矩阵、类别同属矩阵
$x, m, n$	POI 数量、地理距离阈值、隐向量维数
$e^o, e^s, e^l$	POI 同现特征、位置近似特征、类别特征隐向量
$e_u, e_p$	用户特征向量、POI 特征向量
$N$	预测返回的 POI 个数
$P_{Re}, P_{Tr}$	预测返回的 POI 序列集、用户真实访问序列集

#### 1.1 问题定义

$U = \{u_1, u_2, \dots, u_n\}$  表示用户集合,  $P = \{p_1, p_2, \dots, p_m\}$  表示兴趣点, 给定用户  $u$  的历史签到记录  $D_u$ , 当前的时间  $t$ , 文章所提出的 POI 推荐模型最终的操作是：从 POI 集合  $P$  中返回  $N$  个兴趣点序列  $\{p_{n1}, p_{n2}, \dots, p_{nN}\}$ 。序列集  $p_n$ , 即未来某阶段内用户  $u$  最有可能访问的兴趣点集。

#### 1.2 细粒度兴趣

用户兴趣随着时间的推移可能会发生变化，即用户签到行为可分为长期兴趣和短期兴趣两种，本文称之为用户的细粒度兴趣。

##### 1.2.1 用户长期兴趣

用户的长期兴趣一般指用户周期性访问的 POI。RNN 结构具有记忆功能，能够很好地为用户的签到序列行为特

征进行建模，对于捕获用户的长期兴趣是一个好的选择。但一般的 RNN 存在梯度消失的问题，故采用 LSTM 来捕获用户的长期兴趣。具体模型情况参见第 3.3 节 CF-ADNN 模型的 LM 模块。

##### 1.2.2 用户短期兴趣

用户的短期兴趣最有可能影响后续的兴趣点访问，一般主要指与上一个访问的兴趣点距离和类别相近的 POI。故采用带有 Attention 机制的 seq2seq 架构。将用户历史兴趣点编码成一个向量，利用 Attention 机制关注最相近的几个兴趣点进行解码，最终得到用户的短期兴趣。具体模型情况参见 3.3 节 CF-ADNN 模型的 SM 模块。

### 2 结合矩阵分解和深度学习技术的 POI 推荐模型

本节介绍结合矩阵分解和深度学习的个性化 POI 推荐模型 CF-ADNN 的构建及训练过程。将矩阵分解提取的 POI 特征向量以及计算得到的用户特征向量作为以上两个模块的输入，构建 POI 推荐模型 CF-ADNN，并对该模型进行训练。

#### 2.1 基于矩阵分解的兴趣点特征表示

为了解决签到数据的稀疏问题，利用签到数据集中兴趣点的 ID，地理坐标和所属类别这三个维度信息，建立 POI 同现矩阵、位置近似矩阵以及类别同属矩阵。再基于一种矩阵分解方法得到 POI 在同现、位置和类别特征中的隐向量，将上述三种隐向量拼接成一个整体的 POI 特征向量表示<sup>[12]</sup>。

##### 2.1.1 构造特征矩阵

1) POI 同现矩阵：初始化一个 POI 同现矩阵  $O \in N^{n \times n}$ ，表示 POI 在用户访问模式上的关联关系， $n$  等于 POI 数。具体来说， $O_{pp'}$  表示同时访问过  $p$  和  $p'$  兴趣点的用户个数，对角线元素  $O_{pp}$  表示访问  $p$  的用户个数。一般的， $O_{pp'}$  值越高，表明  $p$  和  $p'$  频繁地被先后访问，则证明关联性越强。

2) 位置近似矩阵：与 POI 同现矩阵类似，初始化一个位置近似矩阵  $G \in N^{n \times n}$ ，表示用户的签到行为和 POI 的地理位置高度关联。引入距离阈值  $m = 10$  km，根据签到点的经纬度坐标计算  $p(lon, lat)$  和  $p'(lon', lat')$  之间的距离  $D$ ，若小于  $m$ ，则  $G_{pp'} = 1$ ；否则  $G_{pp'} = 0$ 。特别的， $G_{pp} = 1$ 。  $D$  的计算公式：

$$C = \sin(lat) * \sin(lat') * \cos(lon - lon') + \cos(lat) * \cos(lat')$$

$$D = R * \text{Arc}\cos(C) * PI / 180 \tag{1}$$

其中： $R$  为地球平均半径 6 371. 004 km。

3) 类别同属矩阵：类别同属矩阵  $R \in N^{n \times n}$ ，表示 POI 在类别信息上的关联，利用了 POI 的内容信息。若  $p$  和  $p'$  属于同一个类别， $R_{pp'} = 1$ ；否则  $R_{pp'} = 0$ 。特别的， $R_{pp} = 1$ 。构建特征矩阵过程示例如图 1 所示。

##### 2.1.2 对称矩阵分解

将上述 3 个对称矩阵进行矩阵分解：

1) POI 同现矩阵分解：对于 POI 同现矩阵  $O \in N^{n \times n}$ ，把这个矩阵分解成两个矩阵的点乘，如公式 (2) 所示：

$$O(n, n) = E_o * E_o^T \tag{2}$$

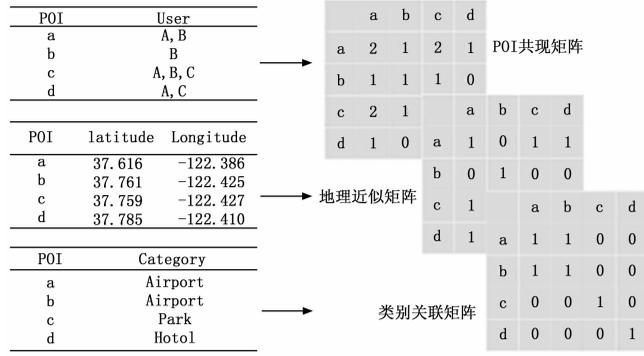


图 1 构建特征矩阵示意图

使两个同阶的矩阵相似程度最小, 得到最接近原始矩阵, 如公式 (3):

$$\min_{E_o} \|O - E_o E^T\|_F^2 + \lambda_o \|E_o\|_F^2 \quad (3)$$

式中,  $\lambda_o$  为正则项参数,  $\|\cdot\|_F$  为矩阵范数,  $E_o \in R^{n \times d}$  为 POI 同现隐藏特征,  $d$  为  $E_o$  中隐向量的维度。矩阵分解后,  $E_o$  中对应的行向量即为 POI 同现特征隐向量, 用符号  $e_p^o$ 。

为了进一步说明对称矩阵分解的优点, 给出两个 POI 隐向量的相似度近似计算公式 (4) ~ (5):

$$\text{Sim}(e_p^o, e_{p'}^o) = \frac{\langle e_p^o, e_{p'}^o \rangle}{\|e_p^o\| \|e_{p'}^o\|} = \frac{\langle e_p^o, e_{p'}^o \rangle}{\sqrt{\langle e_p^o, e_{p'}^o \rangle \langle e_{p'}^o, e_p^o \rangle}} \quad (4)$$

$$\approx \frac{O_{pp'}}{\sqrt{O_{pp} O_{p'p'}}} \quad (5)$$

其中:  $\langle \cdot, \cdot \rangle$  表示计算两个向量内积, 式 (4) 为向量余弦相似度计算公式,  $\langle e_p^o, e_{p'}^o \rangle \approx O_{pp'}$ , 通过替换可得公式 (5)。

通过观察近似公式可知, 隐向量的相似性与用户临近 POI 访问率有关, 说明上述分解方法能够很好地学习、表示兴趣点在该特征空间的相互关联; 同时抑制了热门 POI 对最终推荐结果的影响, 有利于 POI 推荐结果的多样化。

2) 位置近似矩阵分解: 与 POI 同现矩阵分解方法相同, 具体的分解形式如式 (6) 所示:

$$\min_{E_g} \|G - E_g E^T\|_F^2 + \lambda_g \|E_g\|_F^2 \quad (6)$$

式中, 其他参数意义相同,  $E_g \in R^{n \times d}$  是对 POI 类别同属矩阵进行分解后得到的潜在因子矩阵。矩阵分解后,  $E_o$  中对应的行向量即为 POI 在位置特征空间中的隐向量, 用符号  $e_p^g$  表示。

3) 类别同属矩阵分解: 与上述矩阵分解方法相同, 具体的分解如公式 (7) 所示:

$$\min_{E_r} \|R - E_r E^T\|_F^2 + \lambda_r \|E_r\|_F^2 \quad (7)$$

其中:  $E_r \in R^{n \times d}$  对 POI 类别同属矩阵进行分解后得到的潜在因子矩阵。矩阵分解后,  $E_r$  中对应的行向量即为 POI 在地理特征空间中的隐向量, 用符号  $e_p^r$  表示。

### 2.1.3 计算特征向量

拼接上述 3 个矩阵分解所得的隐向量, 得到一个整体的 POI 特征向量表示。具体如公式 (8):

$$e_p = [e_p^o \ e_p^g \ e_p^r] \quad (8)$$

其中:  $e_p^o$ ,  $e_p^g$ ,  $e_p^r$  可分别表示 POI 在同现、位置和类别特征的隐向量。该特征向量表示在实现推荐算法时可以起到缓解数据稀疏和冷启动问题的作用。

### 2.2 用户特征向量计算

计算用户特征向量时, 可结合考虑用户的社交影响因素, 即共同计算用户与用户好友特征向量。文章将用户特征向量表示成该用户与该用户的好友访问过的所有 POI 的特征向量的期望, 从而得到用户特征向量。用户特征向量  $e_u$  计算公式 (9) 如下:

$$e_u = \frac{\sum p \in P_{ue} e_p + \sum p' \in P_{ue'} e_{p'}}{|Pu + Pu'|} \quad (9)$$

$P_u$  和  $P_{u'}$  分别表示用户  $u$  和他的好友  $u'$  访问过的 POI 集合,  $|Pu|$  表示用户  $u$  访问过的 POI 数量。

### 2.3 POI 推荐模型 CF-ADNN

CF-ADNN 模型旨在构建不同的神经网络模型分别学习用户长期和短期兴趣特征。将前两节基于矩阵分解提取的 POI 特征向量, 以及计算得到的用户特征向量按用户签到序列输入模型, 训练模型的高阶交互特征, 预测未来最有可能访问的兴趣点集。

#### 2.3.1 CF-ADNN 模型结构

图 2 展示了 CF-ADNN 模型的整体架构。该模型主要分为两个主要模块: LM 模块获取的是用户的长期兴趣的隐含向量; SM 模块获取的是短期的隐含向量。

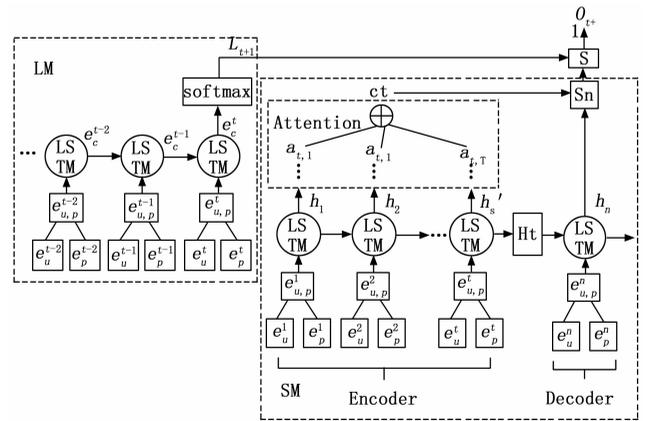


图 2 CF-ADNN 模型整体架构图

#### 1) LM 模块:

用户的长期兴趣主要考虑的是用户周期性访问的模式。为了捕获长期兴趣, 采用 LSTM 来捕获用户的长期兴趣。具体的公式如下:

$$e_{u,p} = e_u^t \oplus e_p^t \quad (10)$$

$$e_c^t = \text{LSTM}(e_{u,p}^t, e_c^{t-1}) \quad (11)$$

$$L_{t+1} = \text{softmax}(e_c^t, e_c^{t-1}) \quad (12)$$

其中:  $e_{u,p}$  为第三节中矩阵分解得到的用户特征向量  $e_u$  及 POI 特征向量  $e_p$  的拼接,  $e_{u,p}^t$  为用户  $u$  在  $t$  时刻签到 POI 点的向量表示, 按照签到时间先后顺序作为 LSTM 单元的输入。预测下一时刻的隐含兴趣  $e_c^t$ , 通过 softmax 函数来进

行最后的预测分类。

2) SM 模块:

用户的短期兴趣主要指与上一个访问的兴趣点相近的(距离和类别)的兴趣点。选择相同类别且两个连续签到点距离小于 10 km 的兴趣点作为用户的短期兴趣。SM 模块采用带有 Attention+seq2seq 架构, seq2seq 架构主要分为 Encoder 和 Decoder。用户的短期兴趣表示方法:通过 Encoder 把用户访问的兴趣点编码成一个向量,编码方式选择 LSTM 网络。编码过程公式如下:

$$e'_{u,p} = e'_u \oplus e'_p \quad (13)$$

$$h_s = \text{LSTM}(e'_{u,p}, h_{s-1}) \quad (14)$$

其中:  $e'_{u,p}$  作为模型的输入,  $h_s$  和  $H_t$  是 LSTM 的输出。利用带有 Attention 机制的 Decoder 着重关注用户的短期兴趣点,即短期兴趣点的权重增加,之前的  $\langle h_1, h_2, \dots, h_t \rangle$  均考虑进来,计算引入注意力的隐藏状态向量从而解码出用户短期目标兴趣点序列。本文默认设置  $\delta$  为 5 用来表示 Attention 机制关注长度,即有 5 个兴趣点被模型关注。

具体公式如下:

$$C_t = \sum_s \alpha_s h_s \quad (15)$$

$$\alpha_s = \frac{\exp(\text{score}(h_n, h_s))}{\sum_{s'=1}^S \exp(\text{score}(h_n, h_{s'}))} \quad (16)$$

$$\text{score}(h_n, h_s) = v^T \tanh(\omega_1 h_n + \omega_2 h_s) \quad (17)$$

其中:  $v^T$ 、 $\omega_1$  和  $\omega_2$  是模型需要学习得到的参数。这里  $C_t$  最为重要,表示通过 Attention 计算得到的上下文向量。进一步计算得到引入注意力的隐藏状态向量:

$$S_n = f(C_t, h_n) = \tanh(W_c[C_t + h_n]) \quad (18)$$

以及解码器生产的目标兴趣点序列:

$$S[y_t | \{y_1, y_2 \dots y_{t-1}\}, C_t] = \text{softmax}(W_c S_n) \quad (19)$$

长期兴趣  $L_{t+1}$  以及短期兴趣序列  $S_{t+1}$  结合起来,得到最终的推荐结果  $O_{t+1}$ :

$$O_{t+1} = L_{t+1} \cup S_{t+1} \quad (20)$$

2.3.2 推荐模型训练

从时间维度分析,为了训练一个模型来适应不同时间段的用户签到,这里将签到数据分为 4 个时间段:夜(0:01-6:00)、早(6:01-12:00)、午(12:01-18:00)、晚(18:01-24:00)分别进行训练,得到适应不同时间段的 POI 推荐模型。

CF-ADNN 推荐模型学习算法

输入:  $e_u$ 、 $e_p$ 、 $t$ 、 $T$

输出:  $O_{t+1}$  (最终的推荐结果)  $L$  (最小损失值)

1. Repeat
2. Foreach  $u \in U$  Do
3. 输入  $e_u$  和  $e_p$ , SM 训练用户短期兴趣 S
4. For  $t < T$  Do
5. 输入  $e_u$  和  $e_p$ , LM 训练用户长期兴趣 L
6. 计算损失值  $l'_u$ 、最终的推荐结果  $O_{t+1}$
7. End for
8. 计算总的损失值  $l_u = \frac{1}{T} \sum_{t=1}^T l'_u$

9. 梯度下降法最小化损失  $l_u$

10. if  $t > T$  or  $l_u$  足够小

11. End for

12. Return  $l_u$ 、 $O_{t+1}$

13. End procedure

CF-ADNN 模型在推荐时,根据获得的最近的兴趣点和用户调整参数  $\delta$  计算短期兴趣向量 S,计算长期兴趣向量 L。结合 S 和 L 得到最终的推荐兴趣点序列  $P_{Re}^u = \{P_{re1}, P_{re2}, \dots, P_{reN}\}$  进行推荐。

3 实验与分析

3.1 实验数据集

本文采用 Foursquare 签到网站的开源数据集作为实验数据,验证模型的有效性。选取美国旧金山市(SFO)的用户签到信息,统计结果如表 2 所示。

表 2 用户签到信息统计表

SFO	数据统计
用户数量	2 327
POI 数量	11 509
签到数量	145 592
POI 类别	270
用户平均访问 POI 个数	62.59
用户-POI 矩阵密度	$5.4 \times 10^{-3}$

训练时,将用户前 80% 的签到数据集作为训练集,最近的 20% 作为测试集。

3.2 评价指标

性能评价指标选用准确率、召回率,分别用 PRE@N, REC@N 表示。对于一个用户  $u$ ,模型的推荐结果是:

$$P_{Re}^u = \{P_{re1}, P_{re2}, \dots, P_{reN}\} \quad (21)$$

用户真实的访问序列是:

$$P_{Tr}^u = \{P_{tr1}, P_{tr2}, \dots, P_{trN}\} \quad (22)$$

其中:  $N$  为模型预测返回的 POI 个数。

则准确率和召回率的公式如下:

$$PRE@N = \frac{1}{|U|} \sum_{u \in U} \frac{|P_{Re}^u \cap P_{Tr}^u|}{N} \quad (23)$$

$$REC@N = \frac{1}{|U|} \sum_{u \in U} \frac{|P_{Re}^u \cap P_{Tr}^u|}{|P_{Tr}^u|} \quad (24)$$

3.3 实验结果及分析

3.3.1 参数影响

训练模型时选取的参数会对推荐结果造成影响。本文主要讨论影响模型最重要的两个参数:

1) 特征向量维度  $d$ :  $e_u$  和  $e_p$  作为模型的输入可以看出,特征向量维度  $d$  是影响整个模型的重要因素。 $d$  越大模型需要的计算量越大。

固定矩阵分解中的正则项参数  $\lambda_o = \lambda_g = \lambda_r = 0.000 01$ ,设置维度  $d$  为 100、150、200、250、300。实验结果如图 3 所示,当维度超过 200 后模型的性能开始降低,故本实验将  $d$  设置成 200。

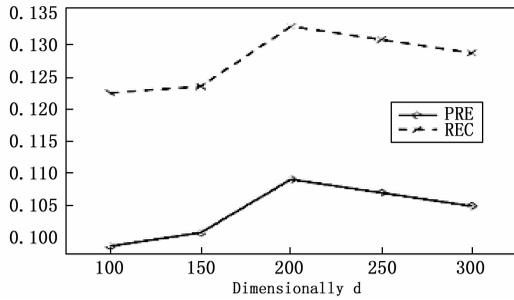


图 3 特征向量维度 d 对模型影响

2) 关注长度  $\delta$ : 用户短期兴趣建模主要用到基于 Attention 机制的序列模型, Attention 关注长度  $\delta$  对模型十分重要。 $\delta$  过长, 模型会变得复杂;  $\delta$  过短, 可能会使得数据不足。

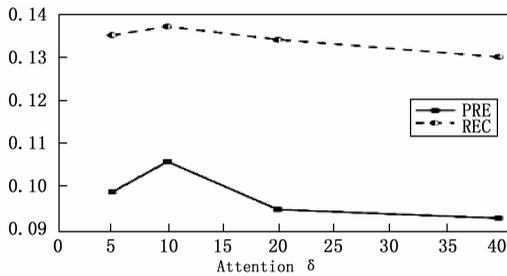


图 4 关注长度  $\delta$  对模型影响

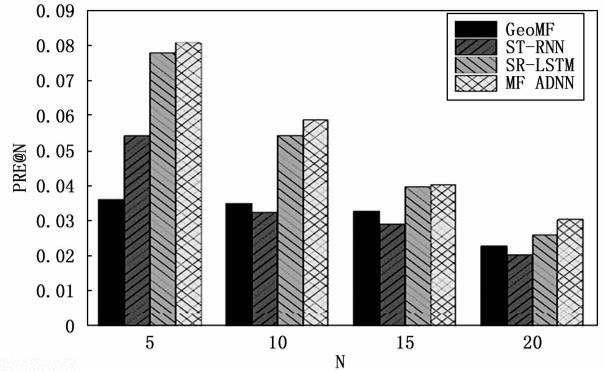
分别设置关注长度  $\delta$  为 5, 10, 20, 40 进行试验, 实验结果如图 4 所示, 当  $\delta$  为 10 模型效果最好。

### 3.3.2 不同推荐模型对比结果

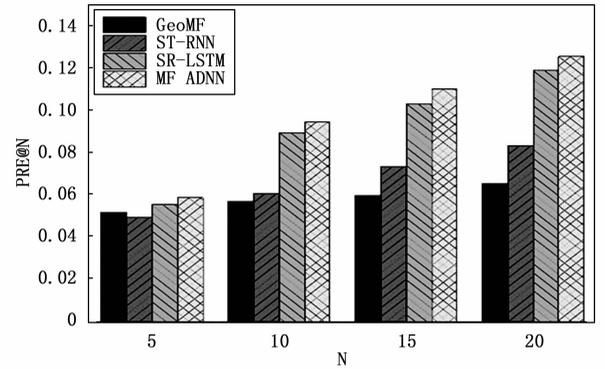
为了验证 CF-ADNN 模型的性能, 文章选择 3 个在矩阵分解和深度学习 POI 推荐算法领域, 具有代表性的模型进行试验对比。GeoMF<sup>[5]</sup>: 基于矩阵分解的地理位置信息 POI 推荐; ST-RNN<sup>[8]</sup>: 基于时空上下文 RNN 模型的 POI 推荐; ST-LSTM<sup>[9]</sup>: 基于时空上下文 LSTM 模型的 POI 推荐。

CF-ADNN 模型与以上 3 种算法的性能对比结果如图 5 所示。

从图 5 的对比结果可知, GeoMF 模型的指标率最低。这说明基于矩阵分解方法的 POI 推荐模型虽然有效缓解了数据稀疏性, 但由于隐式向量内积操作只是简单向量间的线性乘法, 不足以提取用户和 POI 之间高阶历史交互特征尤其无法捕捉用户签到的序列特征。而 ST-RNN 和 ST-LSTM 模型将用户的历史签到记录用序列方式传入 RNN 来学习用户及 POI 的向量表达, 可有效建模用户签到的序列行为, 故推荐性能指标明显高于 GeoMF 模型。同时, ST-LSTM 模型对 ST-RNN 进行改进, 避免了梯度消失, 故 ST-LSTM 模型推荐性能优于 ST-RNN。而 MF-ADNN 结合矩阵分解技术和带有注意力机制的用户签到序列建模技术, 可以降低签到数据的稀疏性; 细粒度建模用户兴趣; 更好学习联合影响因素的高阶非线性交互特征。因此与其它 3 个模型相比, MF-ADNN 在准确率和召回率上均有更



(a) 模型 PRE@N 指标对比结果



(b) 模型 REC@N 指标对比结果

图 5 算法性能对比结果图

优的表现。

## 5 结束语

文章提出一个结合矩阵分解和带有注意力机制深度学习技术的 POI 推荐模型。该模型融合了时间影响、地理影响、社交影响以及序列影响 4 个因素实现用户 POI 推荐。主要任务包括: 通过构建特征矩阵缓解签到数据稀疏问题, 矩阵分解得到隐藏因子, 计算 POI 的特征向量; 构建一种带注意力机制的用户细粒度兴趣的序列建模方式, 有效学习用户长期和短期的兴趣特征, 提高 POI 推荐精确度; 结合上述两种方法, 最终得到可以融合多种影响因素的 POI 推荐模型。试验结果表明, 该 POI 推荐模型具有较好性能。文章未考虑的影响因素还有很多, 如评论信息、文本信息等, 未来的工作将考虑在模型中融入这些特征, 进一步提升推荐算法的性能。

### 参考文献:

[1] Bao J, Zheng Y, Wilkie D, et al. Recommendations in location-based social networks: a survey [J]. *Geo informatica*, 2015, 19 (3): 525-565.

[2] Zhu T, Qin C X, Li Z H. Research on collaborative filtering personalized recommendation method based on user classification [J]. *New Technology of Library and Information Service*, 2015, 31 (6): 13-19.