

# 位置社交网络中谱嵌入增强的兴趣点推荐算法

刘真, 王娜娜, 王晓东, 孙永奇

(北京交通大学计算机与信息技术学院, 北京 100044)

**摘要:** 为了有效地捕捉 LBSN 中丰富的签到、社交等多维上下文信息的空间特性, 并深层挖掘用户和 POI 之间的非线性交互, 提出了一种谱嵌入增强的 POI 推荐算法——PSC-SMLP, 设计了偏好增强的谱聚类算法 PSC 和谱嵌入增强的神经网络 SMLP。在 2 个经典数据集上与现有的 POI 推荐算法相比, PSC-SMLP 可以深度学习用户对 POI 的个性化偏好, 在准确率、召回率、nDCG、平均精度等指标中均获得较大提升。

**关键词:** 基于位置的社交网络; POI 推荐; 谱聚类; 谱嵌入; 神经网络

中图分类号: TP391

文献标识码: A

doi: 10.11959/j.issn.1000-436x.2020053

## Spectral clustering and embedding-enhanced POI recommendation in location-based social network

LIU Zhen, WANG Na'na, WANG Xiaodong, SUN Yongqi

School of Computer and Information Technology, Beijing Jiaotong University, Beijing 100044, China

**Abstract:** In order to effectively capture the spatial characteristics of multi-dimensional context information in LBSN, and deeply explore the non-linear interaction between users and POIs, a spectral embedding enhanced POI recommendation algorithm, namely PSC-SMLP, was proposed. A preference enhanced spectral clustering algorithm (PSC) and a novel spectral embedded enhanced neural network (SMLP) was designed to solve the above problems. Compared with state-of-the-art algorithms on two datasets, PSC-SMLP has better performance in terms of the precision, recall, nDCG and mean average precision.

**Key words:** location-based social network, POI recommendation, spectral clustering, spectral embedding, neural network

### 1 引言

基于位置的社交网络 (LBSN, location-based social network) 中不仅包含原有传统社交网络中的社交网络关系和用户标注信息, 还包含基于 GPS 服务收集的用户签到位置轨迹及相关位置的标注信息<sup>[1]</sup>。用户的移动行为模式、行动轨迹呈现一定的规律及特点<sup>[2]</sup>。随着 LBSN 服务中用户数量的增加, 包含多维度信息的 LBSN 签到数据信息量也急剧增加, 感兴趣的位置点 (POI, point of interest) 推荐成为 LBSN 中的重要研究方向。为了满足用户寻找感兴趣地点的需求, POI 推荐使用用户历史签到位

置、轨迹等一系列时空信息预测用户当下可能感兴趣且尚未访问过的位置<sup>[3]</sup>, 例如酒店、餐厅、博物馆、商场等。

LBSN 中的多维度签到信息包括用户地理位置 (Geo)、时间 (temporal)、POI 类别信息和社交关系<sup>[4-7]</sup>。通过对 LBSN 数据的深度挖掘, 可以揭示更深层次的用户 POI 偏好。利用这些信息为用户推荐 POI 可以有效帮助用户过滤掉不感兴趣的位置点, 提高推荐准确率。

目前基于 LBSN 的 POI 推荐研究采用的模型主要有基于矩阵分解的协同过滤模型、概率模型以及神经网络模型。Cheng 等<sup>[8]</sup>综合考虑地理因素和社

收稿日期: 2019-11-04; 修回日期: 2020-02-26

基金项目: 国家重点研发计划基金资助项目 (No.2019YFB2102501)

Foundation Item: The National Key Research and Development Program of China (No.2019YFB2102501)

交因素,使用多中心高斯模型对地理因素建模,使用概率矩阵分解处理社交因素,最后将这两者融入广义矩阵分解框架中。Zheng 等<sup>[9]</sup>提出了一种新的概率方法,从用户签到记录挖掘隐藏的主题,基于该主题采用跨区域协同过滤方法以推荐新的 POI。

近年来,神经网络应用于推荐系统中并取得较大进展。Ma 等<sup>[10]</sup>为融合上下文信息(如社交信息、地理信息等)和对用户-POI 之间的交互进行非线性建模,提出了一种基于自动编码器的模型。Zhao 等<sup>[11]</sup>提出了一种最大边际度量地理社交多媒体网络表示学习框架。Yang 等<sup>[12]</sup>将协同过滤与半监督学习相结合提出了一种基于神经网络的模型 PACE (preference and context embedding),该模型通过对相邻用户和 POI 进行平滑缓解数据稀疏,构造上下文信息图以共同学习用户和 POI 的嵌入,从而预测用户对 POI 的偏好。Ying<sup>[13]</sup>等提出了一种基于秩的方法 PGRank,它将用户地理偏好和潜在偏好集成到贝叶斯个性化排名框架中。

现有研究中还存在以下 2 个问题。

1) LBSN 中包含丰富的签到、社交等上下文信息,现有的融合上下文信息的推荐模型如果不能很好地捕捉数据的多维空间特性,将难以准确地捕获用户最近邻。

2) 矩阵分解模型中用户对 POI 的交互被处理为其潜在特征向量的内积,而内积只反映了潜在空间中向量之间的线性关系,忽视了用户和 POI 之间存在的非线性交互<sup>[14]</sup>。

基于上述分析,本文提出谱嵌入增强的 POI 推荐算法 PSC-SMLP (preference enhanced spectral clustering and spectral embedding enhanced multi-layer perceptron)。该算法由两部分组成:偏好增强的谱聚类算法 PSC 和谱嵌入增强的多层感知机 SMLP。一方面,与传统的社交网络推荐算法不同,LBSN 丰富的信息有助于捕获用户之间的偏好紧密程度。因此,借助谱聚类能在任意形状的样本空间上聚类且收敛于全局最优解的优点,提出了融合上下文信息的偏好增强的谱聚类算法 PSC,以更准确地获得用户最近邻,便于更好地学习用户对 POI 的偏好。另一方面,本文提出谱嵌入增强的神经网络 SMLP,通过捕捉用户和 POI 的二分图关系进行谱嵌入,以增强 MLP (multi-layer perceptron) 学习用户与 POI 之间的非线性交互能力。使用谱聚类后用户最近邻所形成的用户-POI 对的拼接向量作为

SMLP 网络的输入,通过谱嵌入和神经网络的网络结构和非线性激活函数对用户与 POI 之间的复杂交互进行非线性建模,以学习用户的 POI 个性化偏好。

## 2 融合上下文信息的 POI 推荐模型框架

### 2.1 问题描述

对融合上下文信息(签到信息、社交信息)的 POI 推荐定义如下。

**定义 1** 用户签到。假设  $u$  为用户,  $p$  为 POI,  $u_{ID}$  为用户  $u$  的 ID 标识,  $p_{ID}$  为  $p$  的 ID 标识,则用户  $u$  在位置点  $p$  的一次签到可以用一个三元组来表示:  $\langle u_{ID}, p_{ID}, t \rangle$ , 其中,  $t$  为签到时间。进一步地,用户  $u$  的签到 POI 集合可以表示为

$$P_u = \{p_{ID} | \exists \langle u_{ID}, p_{ID}, t \rangle\}$$

**定义 2** 社交关系。是指用户之间互为好友,对于一对互为好友的用户  $u$  和用户  $v$ , 他们之间的社交关系可以用一个二元组来表示,即  $\langle u, v \rangle$ 。进一步地,用户  $u$  的好友集合可以表示为  $F_u = \{v | \exists \langle u, v \rangle\}$ 。

**定义 3** POI 推荐。给定用户  $u$  及其签到的 POI 集合  $P_u$  和好友集合  $F_u$ , POI 推荐为预测用户  $u$  对所有未有签到记录的 POI 点  $p$  的偏好值,按偏好值排序的前  $K$  个 POI 则为对用户  $u$  推荐的结果。

### 2.2 PSC-SMLP 推荐模型框架

本文提出的 PSC-SMLP 模型框架如图 1 所示。图 1 中,通过设计偏好增强的谱聚类算法 PSC 提出 SP 相似度从用户签到到偏好和社交偏好 2 个方面捕捉数据的多维空间特性,更准确地捕获用户最近邻,继而使用谱聚类获得用户群组;进一步构造谱嵌入增强的神经网络 SMLP 挖掘用户和 POI 的非线性交互。SMLP 共分五部分,分别是输入层、谱嵌入层、拼接层、隐藏层和输出层。将用户群组中的用户-POI 标记对输入谱嵌入层,通过用户和 POI 二分图的谱进行潜在因子建模,获得用户和 POI 的谱特征向量表示。然后,将用户和 POI 谱特征向量进行拼接,构造拼接向量作为隐藏层的输入,使用多个隐藏层深度模拟用户和 POI 之间的交互。最后采用 softmax 层作为输出层产生用户对 POI 的偏好预测。

## 3 偏好增强的谱聚类算法 PSC

LBSN 中用户与用户之间的关系可以表示为社交网络图  $G$ , 如图 2 所示。图  $G$  中的顶点有两类,分别是用户和 POI; 边有三类,分别为用户之间表

示社交关系的边，用户和 POI 之间表示签到关系的边，POI 之间表示关联关系的边。

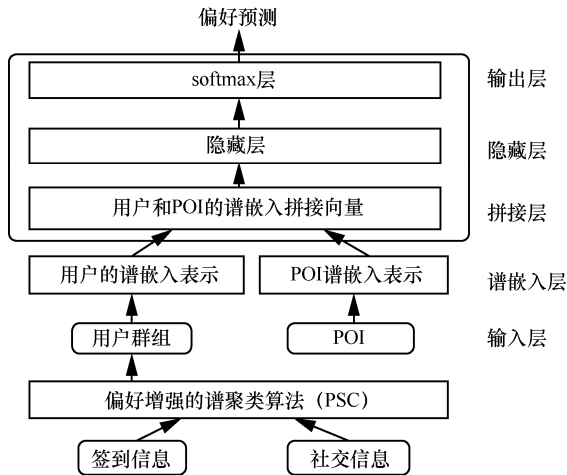


图 1 PSC-SMLP 模型框架




图 2 LBSN 社交网络 G

以 LBSN 标准离线数据集 Brightkite 为例，对其社交信息的分析结果分别如表 1 和图 3 所示。

表 1 社交信息分析结果

用户类别	平均共同签到数量/个
好友之间	3.977
非好友之间	0.517




图 3 社交信息分析统计结果

从表 1 中可知好友之间的平均共同签到数量远大于非好友之间的平均共同签到数量，这反映出好

友之间有更大的签到相似性。图 3 中，纵坐标是用户数量，横坐标表示用户访问其好友曾经访问过位置的概率，即用户第一次访问该位置之前该位置已被其好友访问过的概率。由图 3 可知，用户初次访问的位置中 90% 以上曾被其好友访问过的用户数量位居第三。

经过上述分析可知，社交好友之间拥有更相似的签到偏好，用户在选择新的访问地点时，更偏向于访问其好友访问过的位置。

因此，本文从签到偏好和社交偏好两方面挖掘用户偏好的相似程度，构造偏好相似矩阵，继而采用常用于图领域、可识别任意形状空间并且能收敛于全局最优解的谱聚类算法挖掘用户最近邻，提出了偏好增强的谱聚类（PSC）算法。

### 3.1 PSC 算法

PSC 算法框架如图 4 所示。

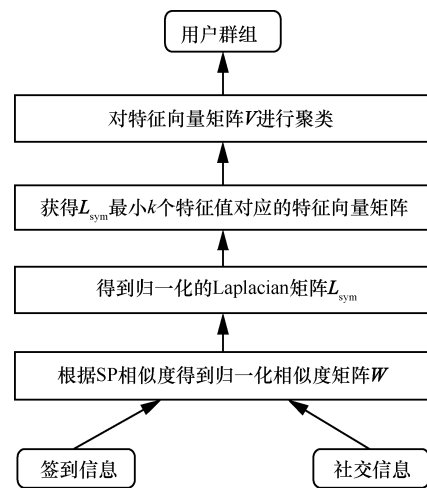


图 4 PSC 算法框架

PSC 算法详细步骤如下。

#### 1) 偏好提取归一化相似度矩阵 W

图 2 中用户和用户之间的边定义为偏好相似程度，本文提出同时考虑签到关系和好友关系的 sp 相似度来度量用户与用户之间的边权值，如式(1)~式(3)所示。

$$up = \frac{|P_{u_1} \cap P_{u_2}|}{\sqrt{|P_{u_1}|} \sqrt{|P_{u_2}|}} \quad (1)$$

$$uf = \frac{|F_{u_1} \cap F_{u_2}|}{\sqrt{|F_{u_1}|} \sqrt{|F_{u_2}|}} \quad (2)$$

$$sp(u_1, u_2) = up \cdot uf \quad (3)$$

其中,式(1)中 $|P_{u_1} \cap P_{u_2}|$ 代表  $u_1$  和  $u_2$  共同签到的 POI 个数,  $up$  表示两用户的兴趣偏好相似度的程度; 式(2)中 $|F_{u_1} \cap F_{u_2}|$ 代表  $u_1$  和  $u_2$  共同好友个数,  $uf$  表示两者的好友关系程度; 式(3)中  $sp$  相似度由  $up$  和  $uf$  两部分的乘积计算得到。进一步采用随机游走的思想将用户和用户之间的相似度进行归一化, 构造用户与用户的相似度矩阵  $U$  以作为归一化的相似度矩阵  $W$ , 如式(4)所示。

$$W = \tilde{D}^{-1}U \quad (4)$$

其中,  $U$  为通过  $sp$  相似度得到的用户相似度矩阵,  $\tilde{D}$  为  $U$  的对角矩阵。

### 2) 归一化的 Laplacian 矩阵 $L_{sym}$

谱聚类算法将聚类问题看作图分割问题, 图分割的最优化问题与求解 Laplacian 矩阵特征向量问题等价, 因此要得到用户相似度矩阵对应的 Laplacian 矩阵。本文归一化的相似度矩阵  $W$  为对称矩阵, 故选择归一化 Laplacian 矩阵  $L_{sym}$ , 根据式(5)可以计算得到。

$$L_{sym} = D^{-\frac{1}{2}} L D^{-\frac{1}{2}} \quad (5)$$

其中,  $D$  为  $W$  的对角矩阵,  $L=D-U$ 。通过特征值处理, 获得用户相似度矩阵对应 Laplacian 矩阵  $L_{sym}$  的特征向量矩阵  $V^T=[x_1, x_2, \dots, x_n]$ , 采用  $K$ -means 对  $V^T$  中的列向量进行聚类, 聚类结果中  $x_1, x_2, \dots, x_n$  分别所属的类别对应用户所属的类别。将隶属于相同类别的用户归为一个群组, 从而获得用户最近邻构成的群组。

### 3.2 PSC 算法伪代码

PSC 算法伪代码如算法 1 所示。

#### 算法 1 PSC 算法

输入 用户签到矩阵  $R$ 、社交矩阵  $S$

输出 用户群组

- 1)  $P_u \leftarrow \text{getPointlist}(R)$
- 2)  $F_u \leftarrow \text{getFriendlist}(S)$
- 3)  $\text{common\_users} \leftarrow R \cap S$
- 4) for  $i \in \text{common\_users}$  do
- 5)   for  $j \in \text{common\_users}$  do
- 6)     根据式(1)和式(2)计算  $up$  和  $uf$
- 7)      $SP(u_i, u_j) = up \times uf$
- 8)      $U_{ij} \leftarrow SP(u_i, u_j)$
- 9)   end for
- 10) end for

11)  $W \leftarrow \text{normalized}(U)$  //根据式(4)计算

12)  $L_{sym} \leftarrow \text{Laplacian}(W, U)$  //根据式(5)计算

13)  $V^T \leftarrow \text{eigenvec}(L_{sym})$  //根据  $L_{sym}$  的  $k$  个最小特征值计算得到特征向量矩阵  $V^T$

14)  $\text{clustering}(V^T)$ ;

15) return 用户群组

## 4 SMLP 神经网络设计

一些研究进展<sup>[10-12]</sup>证明了神经网络在处理信息检索和推荐任务中挖掘用户和物品之间非线性潜在关系的有效性。

本文构建了谱嵌入增强的神经网络 SMLP, 网络结构如图 1 所示。SMLP 的网络结构包括输入层、谱嵌入层、拼接层、隐藏层和输出层。通过 PSC 算法获得的用户群组及其签到过的 POI 形成用户-POI 对分别输入到谱嵌入层, 将获得用户和 POI 的谱嵌入表示, 通过拼接层, 获得用户-POI 对的谱嵌入式拼接向量。在隐藏层中, 对拼接向量进行学习, 最后在 softmax 层输出用户对 POI 的偏好预测。

### 4.1 谱嵌入层

图 2 中的用户和 POI 之间的签到关系可以表示为二分图, 包含丰富的用户和 POI 的直接或间接连通信息, 间接隐含的连通度对挖掘偏好也具有重要意义。图的谱侧重于反映图的连通性, 有助于更好地挖掘潜在连通性。

图的谱即是图拉普拉斯矩阵的特征向量所组成的矩阵<sup>[15]</sup>。本文提出的谱嵌入层通过连通信息图的谱对用户和 POI 进行谱映射, 从而获得用户和 POI 的谱嵌入向量。具体设计如式(6)所示。

$$\begin{bmatrix} e_{new}^u \\ e_{new}^p \end{bmatrix} = SE \begin{bmatrix} e^u \\ e^p \end{bmatrix} \quad (6)$$

其中,  $SE = Ef_{\alpha}(A)E^T$ ,  $A = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_n\}$ ,  $f_{\alpha}(A) = \text{diag}\{\alpha_1 \lambda_1, \alpha_2 \lambda_2, \dots, \alpha_n \lambda_n\}$ 。  $E$  和  $A$  分别是用户-POI 签到二分图对应拉普拉斯矩阵的特征向量矩阵和特征值矩阵,  $f_{\alpha}(A)$  对特征值进行参数化以获得更好的特征表示,  $e^u$  和  $e^p$  是指定嵌入维度使用高斯分布随机初始化的用户特征向量和 POI 特征向量,  $e_{new}^u$  和  $e_{new}^p$  分别代表用户谱嵌入向量和 POI 谱嵌入向量。

### 4.2 其他各层的设计

本文使用神经网络来拟合输入用户-POI 对和

输出 POI 预测结果之间的关系。本文选用非线性激活函数，通过隐藏层层数的不断加深可以使神经网络逼近任意复杂函数，从而可以更加明确地描述输入与输出之间的关系，并将神经元的输出映射到有界的区域。

因此，SMLP 神经网络各层的输出为

$$\begin{aligned} \mathbf{x} &= \mathbf{h}^0 = [\mathbf{u}_i, \mathbf{p}_j]^T \\ \mathbf{h}^1(x) &= \text{ReLU}(\mathbf{W}^1 \mathbf{h}^0 + \mathbf{b}^1) \\ \mathbf{h}^2(x) &= \text{ReLU}(\mathbf{W}^2 \mathbf{h}^1(x) + \mathbf{b}^2) \\ \mathbf{h}^q(x) &= \text{ReLU}(\mathbf{W}^q \mathbf{h}^{q-1}(x) + \mathbf{b}^q) \end{aligned} \quad (7)$$

其中， $\mathbf{W}^q, \mathbf{b}^q$  是第  $q$  层的参数。当  $q=0$  时， $\mathbf{x}$  为用户-POI 对的拼接向量。

POI 推荐属于 OCCF (one class collaborative filtering) 问题<sup>[16]</sup>。为了特别处理 POI 推荐中隐式反馈的单类性质，在隐藏层的顶部连接了一个二进制 softmax 层。softmax 层是一个使用 sigmoid 函数的逻辑回归层，因此在输入层也使用 sigmoid 函数来获得用户对 POI 的偏好程度  $\hat{y}_{ij}$ ，如式(8)所示。

$$\hat{y}_{ij} = \sigma(\mathbf{h}^q(\mathbf{x})) \quad (8)$$

本文选用对数损失函数 (logloss) 作为 SMLP 神经网络的目标函数，如式(9)所示。

$$\begin{aligned} \text{logloss} &= - \sum_{(u,p) \in \mathcal{Y}^+} \log \hat{y}_{up} - \sum_{(u,p) \in \mathcal{Y}^-} \log(1 - \hat{y}_{up}) = \\ &- \sum_{(u,p) \in \mathcal{Y} \cup \mathcal{Y}^-} y_{up} \log \hat{y}_{up} + (1 - y_{up}) \log(1 - \hat{y}_{up}) \end{aligned} \quad (9)$$

## 5 实验及结果分析

### 5.1 实验设置

#### 5.1.1 数据集分析

本文实验部分数据集采用的是 LBSN 中 2 个经典的数据集 (Gowalla 和 Yelp)。

Gowalla 数据集为斯坦福大学研究人员在 Gowalla 平台上获得的 2009 年 2 月至 2010 年 10 月在全球范围内生成的真实签到数据。过滤掉签到 POI 次数少于 15 的用户及被签到次数少于 10 的

POI，过滤后的数据集包括 18 737 个用户，32 510 个 POI，1 278 274 次签到。平均每个用户签到 68 个 POI，每个 POI 被 40 个用户签到过。

Yelp 数据集包含大量的 POI 和若干个城市内的签到记录。过滤掉签到 POI 次数少于 10 的用户，过滤后的数据集包含 30 887 个用户，18 995 个 POI 和 860 888 次签到。平均每个用户签到 27 个 POI，每个 POI 被 45 个用户签到过。

Gowalla 和 Yelp 数据集中都包括好友关系和签到记录，其中互为好友关系的用户成对出现。对数据进行预处理后的基本信息如表 2 所示，表中稀疏度表示为用户-POI 签到次数矩阵中空白项和所有项的比例。

针对 Gowalla 和 Yelp 这 2 个数据集，对用户签到 POI 数量和 POI 被签到的用户数量进行统计，如图 5 所示。图 5 中纵轴表示参与统计的用户数量或 POI 数量，横轴表示签到数量。

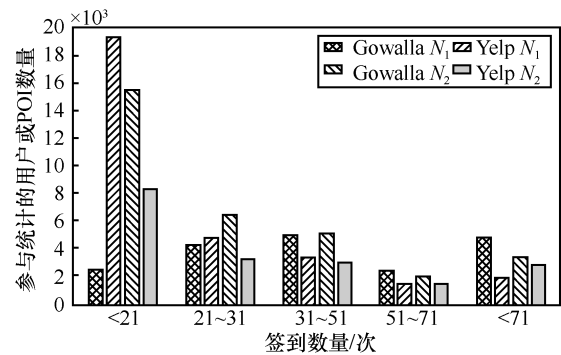


图 5  $N_1$  和  $N_2$  的数量

将用户签到 POI 数量标记为  $N_1$ ，POI 被签到到用户数量标记为  $N_2$ 。从图 5 可看出在 Gowalla 数据集上用户签到 POI 数量为 31~51 的用户数目最多，而在 Yelp 数据集上，用户签到 POI 数量范围为 0~20 的用户数量最多。

#### 5.1.2 对比算法

本文采用以下 8 个算法与本文提出的 PSC-SMLP 算法进行对比。

1) iGSLR (personalized geo-social location recommendation)<sup>[17]</sup>。使用 KDE (kernel density estimation) 为用户签到行为的地理因素进行个性化

表 2 数据集基本信息

数据集	用户数/个	POI 数/个	签到数/次	稀疏度	用户平均签到数量/次	POI 平均被签到数量/个
Gowalla	18 737	32 510	1 278 274	0.997 90	68	40
Yelp	30 887	18 995	860 888	0.998 53	27	45

建模,然后将用户偏好、社交和地理因素融合到统一的框架中。

2) LFBCA (location-friendship bookmark-coloring algorithm) [18]。基于 4 种因素,分别为用户的历史行为、地理因素、社交因素和相似用户,使用 PPR (personalized page rank) 算法,计算过程使用书签着色算法 (bookmark-coloring algorithm)。

3) LORE (location recommendation) [19]: 从用户的签到行为中挖掘顺序影响,将顺序、社交和地理影响融合到统一的推荐框架 LORE 中。

4) USG (user social geographical) [20]。考虑到用户偏好、社交及地理影响,分别使用 UserCF (user collaborative filtering)、FCF (friend collaborative filtering) 和幂律分布对其进行建模,最后将多个模型融合到统一的推荐框架 USG 中。

5) IRenMF (instance-region neighborhood matrix factorization) [21]。通过将相邻特征合并到加权 MF (matrix factorization) 中来对地理影响建模。

6) ASMF (augmented square error based matrix factorization) 和 ARMF (augmented ranking error based matrix factorization) [22]。考虑到社交影响、分类影响、地理影响,提出了基于平方误差的 MF 模型和基于增强的排名误差的 MF 模型。

7) PACE (preference and context embedding) [12]。考虑到 LBSN 中的多种上下文因素(重点是社交影响和地理影响),将协同过滤和半监督学习相结合提出了一种通用的推荐框架。

8) LOCABAL (local and global) [13]。利用 2 种社会关系社交朋友和全球声誉较高的用户使用 MF 进行建模。

本文使用了 4 个评价指标用于衡量算法的性能,即准确率 (Pre@K)、召回率 (Rec@K)、归一化折扣累积增益 (nDCG@K) 和平均精度 (MAP@K),其中, K 表示推荐列表的大小。

### 5.2 参数设置实验

采用留一法方案 [12],根据文献 [23] 的策略为每个用户真实签到的 POI 随机选择 100 个未签到的 POI 作为负样本,然后将真实签到的 POI 和负样本混合构造测试集。

#### 5.2.1 PSC 中聚类簇数 k 的设置

本文选择常用的聚类评估指标。CH 指标 (Calinski-Harabaz index) 分数来进行聚类簇数 k 的评价。CH 指标分数越大说明聚类效果越好。

对于 k 个簇,CH 指标分数由簇间离散平均值与簇内离散之比得出

$$s(k) = \frac{T_r(\mathbf{B}_k) N - k}{T_r(\mathbf{W}_k) k - 1} \quad (10)$$

其中, N 是数据集的数量,  $\mathbf{B}_k$  是簇内离散矩阵,  $\mathbf{W}_k$  是簇间离散矩阵。 $\mathbf{B}_k$  和  $\mathbf{W}_k$  的定义如式(11)和式(12)所示。

$$\mathbf{B}_k = \sum_q n_q (C_q - c)(C_q - c)^T \quad (11)$$

$$\mathbf{W}_k = \sum_{q=1}^k \sum_{x \in C_q} (x - C_q)(x - C_q)^T \quad (12)$$

其中,  $C_q$  是簇 q 的中心, c 是数据集的中心,  $n_q$  是簇 q 的数据点的数量。

假设 k 分别为 2、5、8、10、15,对数据集 Gowalla 和 Yelp 使用 CH 指标分数来评估聚类效果,结果如图 6 所示。从图 6 中可以看出,对于数据集 Gowalla,当聚类簇数 k 为 8 时聚类效果最好。对于 Yelp 数据集,当 k 为 2 时,聚类效果最好,但是考虑到该数据集的整体平均情况,选择聚类效果次优的 k=8 的值。因此,设置聚类簇数 k 为 8。选用用户数量最多的群组分别进行后续实验,最后在 Gowalla 和 Yelp 数据集上分别选用用户群组 2 和用户群组 1,这 2 个群组的用户数量分别为 8 302 和 9 233。




图 6 聚类簇数 k 对聚类效果的影响

#### 5.2.2 神经网络结构的评估

本文通过改变神经网络架构中隐藏层的层数以及每个隐藏层的容量(即神经网络的深度和宽度)来讨论 PSC-SMLP 中学习用户偏好的有效性。

本文设置用户和 POI 嵌入到共享维度空间 [16]。输入层是用户和 POI 的联结向量,所以隐藏层的输入层容量是 2 的倍数,受文献 [12] 启发,将隐藏层

以 2 的指数衰减进行架构的设计。

1) 首先令聚类簇数  $k=8$ ，按照  $32 \rightarrow 16 \rightarrow 8 \rightarrow 4$  设计神经网络的架构（为避免过饱和，设置较为适中的网络结构），设推荐列表数量为 10，以 Gowalla 为数据集讨论迭代次数对于损失函数值 loss 和命中率 HitRatio@10 的影响，如图 7 所示。从图 7 中可以发现随着迭代次数的增加，训练目标函数的 loss 越来越小，且在迭代次数为 20 时，loss 急剧下降。综合考虑 HitRatio@10 和 loss，本文将迭代次数设为 50。

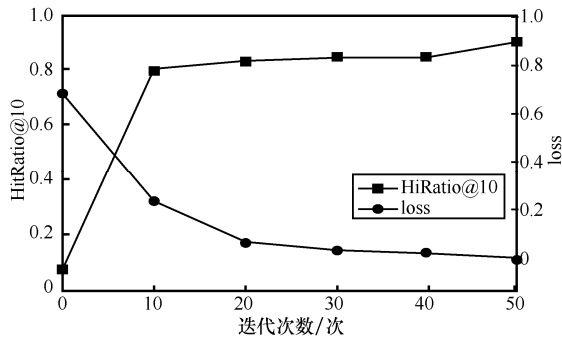


图 7 迭代次数对命中率和损失值的影响

2) 在 Gowalla 数据集上对所有数据使用 accuracy 来评估神经网络深度和宽度的影响。accuracy 通过预测值和实际值之间差值来衡量神经网络在不同网络结构下的训练效果，如表 3 所示，其中  $h$  为神经网络层数。

设置其它参数，如学习率为 0.000 1。从表 3 中可以看出，当只使用一层神经网络时，神经元的个数越多，accuracy 越高。一般来说，固定最后一层的容量大小，随着层数的增加，accuracy 增大。当最后一层的容量较大时，隐藏层层数的增加会给模型带来饱和，例如表 3 中当层数为 4，最后一层神经元的个数为 64 时，本文提出的神经网络模型对于已固定的其他参数而言，达到了饱和状态。

### 5.3 性能比较

#### 5.3.1 与对比算法的比较

图 8 表示在 Gowalla 和 Yelp 这 2 个数据集上 PSC-SMLP 与其他算法的性能，PSC-SMLP 在各项指标上均优于其他模型。图 8(a)~图 8(d)所示在 Gowalla 数据集上的各个算法性能均优于图 8(e)~图 8(h)所示在 Yelp 数据集上的算法性能，这是因为 Gowalla 数据集的签到信息和社交信息较 Yelp 数据集更为丰富，充分表明利用 PSC 融合上下文信息给模型带来的优势。

表 3 不同神经网络结构的 accuracy

神经元个数/个	accuracy				
	$h=1$	$h=2$	$h=3$	$h=4$	$h=5$
4	0.48	0.612 2	0.731 7	0.843	0.871
8	0.620 4	0.782 9	0.825	0.852	0.878
16	0.744 0	0.841 3	0.852 1	0.865	0.903
32	0.874 9	0.891 4	0.901	0.910	0.915
64	0.892 0	0.912	0.921	0.935	0.93

对比算法中 PACE 属于神经网络模型，其他算法模型都是基于传统的协同过滤矩阵分解模型。PSC-SMLP 和 PACE 在各指标上性能的优越性充分表明了神经网络结构和非线性激活函数对于复杂交互场景下的学习能力。PSC-SMLP 在 Gowalla 数据集 Rec@K 中平均提高约 3%，最高达 13%。在 Pre@K 中提高最高达 1.9%。在 Yelp 数据集中 Rec@K 中平均提高约 4%，在 Pre@K 中提高最高达 2.1%，从在同一数据集上算法的性能提升来看，PSC-SMLP 算法在稀疏数据集上比 PACE 模型的有效性更明显。一方面是因为 PSC 不仅从用户签到偏好和社交影响 2 个方面捕捉相似用户获得用户群组，而且从聚类角度缓解数据稀疏；另一方面，模型的 SMLP 部分有效地利用神经网络和非线性激活函数的优势捕获用户和 POI 之间的复杂交互，更好地学习了用户偏好。

充分利用签到信息和社交信息，更有利于提高算法的性能。PSC-SMLP 在 Gowalla 上的平均性能比 IReNMF 提高约 3%，其中，在 Recall@10 上的改进高达 7.9%。在 Yelp 数据集上，PSC-SMLP 优于 IReNMF 约 3.2%，可以发现 PSC-SMLP 在稀疏度更大的 Yelp 数据集上实现的性能提高优于在 Gowalla 数据集上实现的提高，这也说明利用更多的上下文信息，PSC-SMLP 可以缓解数据稀疏。

#### 5.3.2 PSC-SMLP 与 SMLP 的比较

在 Gowalla 数据集和 Yelp 数据集上，从 Pre@K 和 Rec@K 这 2 个指标来对比 PSC-SMLP 和 SMLP 算法，以衡量 PSC 谱聚类所起的作用，如图 9 所示。从图 9 可以发现，PSC-SMLP 在 2 个指标上均优于 SMLP，在 Gowalla Pre@K 上，性能提升约为 0.2%~1.6%；在 Gowalla Rec@K 上性能最高提升约为 2.11%。在 Yelp Pre@K 指标上 PSC-SMLP 性能提升约为 0.5%~1.8%；在 Yelp Rec@K 上性能最高提升约为 3.08%。从这些数据中可发现，PSC-SMLP

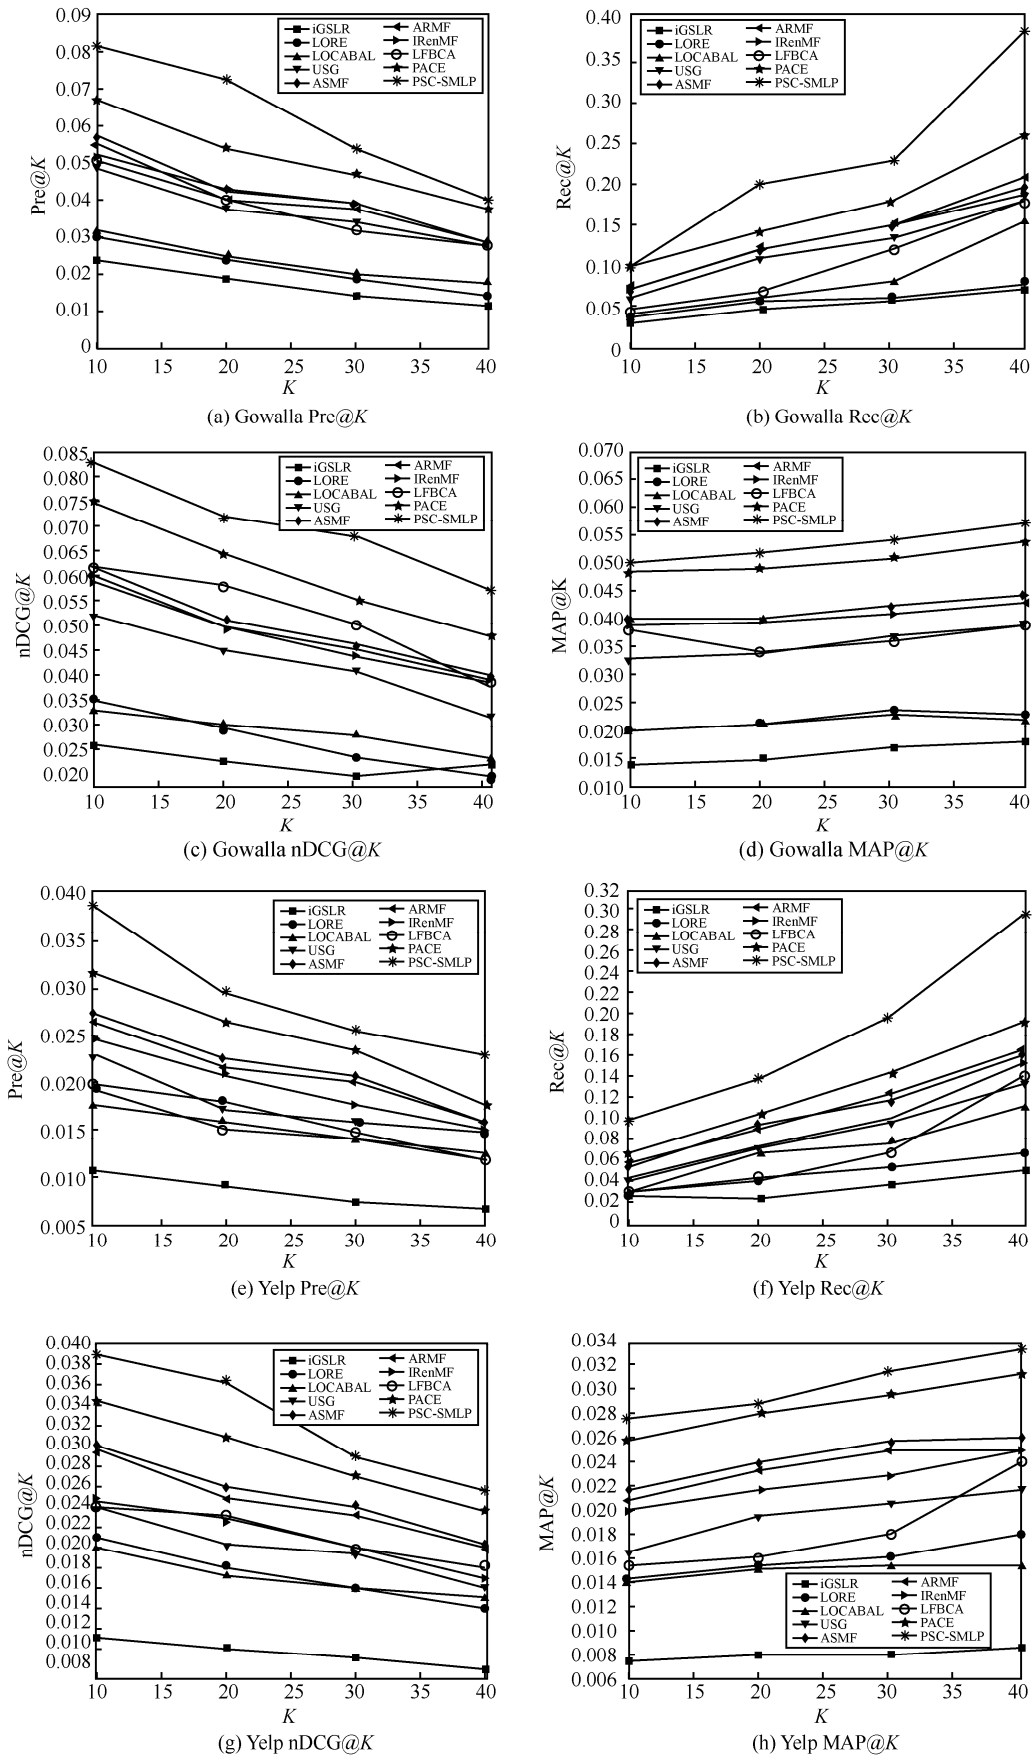


图 8 Gowalla 和 Yelp 数据集上的性能对比

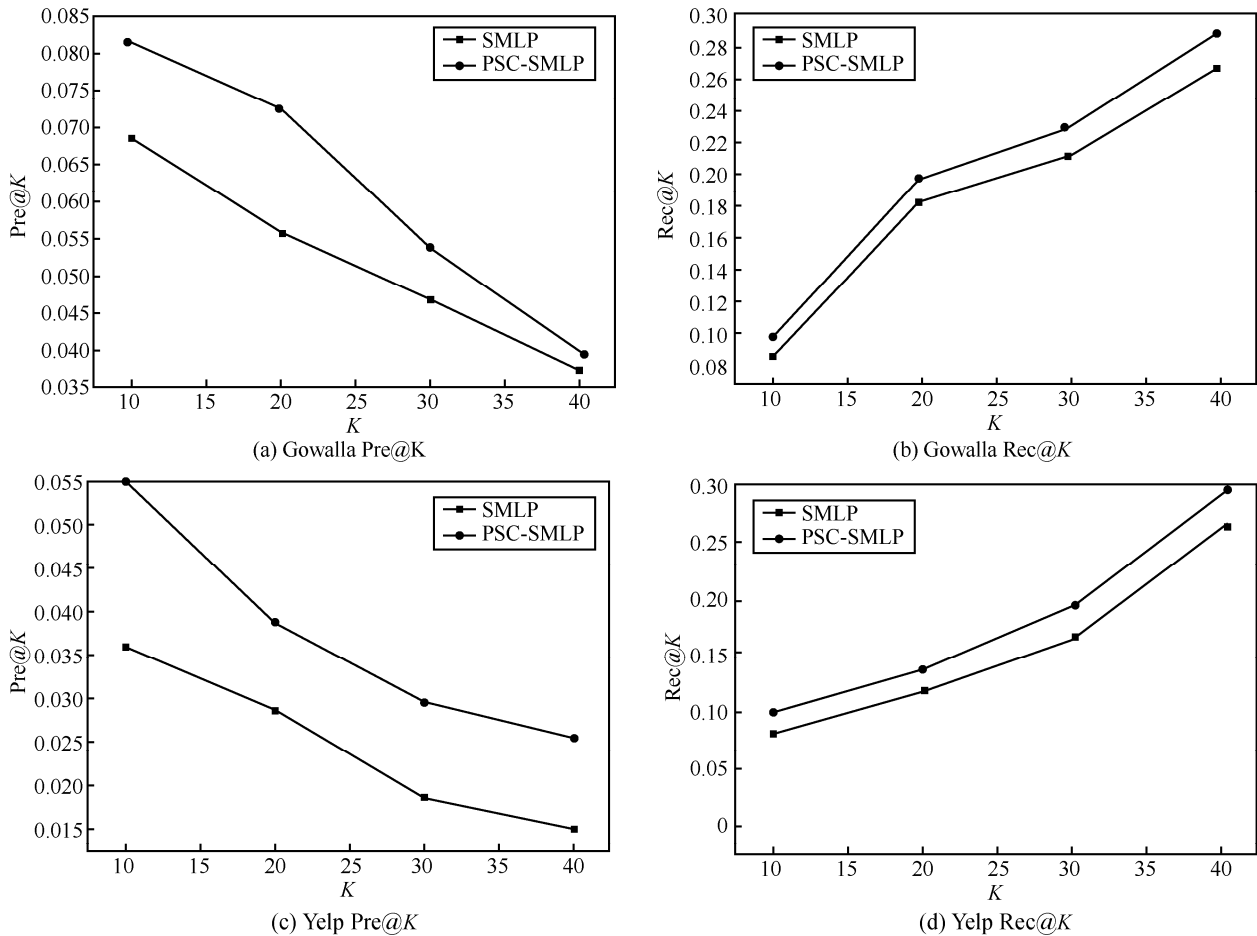


图 9 PSC-SMLP and SMLP 的对比

相比于 SMLP 在 Yelp 上性能改进均大于 Gowalla。由此可知，在数据稀疏度大于 Gowalla 的 Yelp 数据集上，PSC 能更有效地捕捉数据的多维空间特性，准确地定位用户最近邻。

## 6 结束语

LBSN 中丰富的上下文信息（签到信息、社交信息）为充分学习用户偏好，提高 POI 推荐算法的准确率提供了机遇。然而将上下文信息直接融入到推荐模型中会引起数据维度增大，也将增加用户和 POI 非线性交互的挖掘难度。本文提出了一种新的 POI 推荐算法 PSC-SMLP。在图模型基础上提出了偏好增强的谱聚类算法 PSC 进行用户偏好上下文的挖掘，PSC 可从用户偏好和社交偏好 2 个方面捕捉用户对 POI 签到的相似性，基于谱聚类的 PSC 也能在多维数据构成的任意形状空间中具有良好的空间识别能力。本文进一步构造了谱嵌入增强的神经网络 SMLP，谱嵌入层通过连通信息图的谱对用户群组和 POI 进行谱映射，更好地捕捉用户和 POI

之间的连通信息，从而获得用户和 POI 的谱嵌入向量，构造的深层网络结构和非线性激活函数基于谱嵌入层充分学习了用户对 POI 的偏好。在 Gowalla 和 Yelp 这 2 个数据集中与传统的协同过滤和复合模型算法进行了对比，在多个评价指标上，本文算法推荐性能更优。

更进一步的研究将考虑自注意力模型，从多个层次来捕获用户对不同 POI 的关注度，以进一步提高推荐准确率。

## 参考文献：

- [1] 刘树栋, 孟祥武. 基于位置的社会化网络推荐系统[J]. 计算机学报, 2015, 38(2): 322-336.  
LIU S D, MENG X W. Recommender systems in location-based social networks[J]. Journal of Computers, 2015, 38(2): 322-336.
- [2] 蒋仲安, 王明, 陈雅. 基于地理坐标和轨迹数据的路径推荐方法[J]. 通信学报, 2017, 38(5): 165-171.  
JIANG Z A, WANG M, CHEN Y. Path recommendation based on geographic coordinates and trajectory data[J]. Journal of Communications, 2017, 38(5): 165-171.
- [3] MOHAMMAD A,CRESTANI F. Personalized context-aware point of

- interest recommendation[J]. ACM Transactions on Information Systems, 2018, 36(4): 28.
- [4] LI X, GAO C, LI XL, et al. Rank-GeoFM: a ranking based geographical factorization method for point of interest recommendation[C]// ACM Special Interest Group on International Retrieval. New York: ACM Press, 2015: 433-442.
- [5] LIAN D, ZHENG K, GE Y, et al. GeoMF++: scalable location recommendation via joint geographical modeling and matrix factorization[J]. ACM Transactions on Information Systems, 2018, 36(3): 1-29.
- [6] FAN W, LI Q, CHENG M. Deep modeling of social relations for recommendation[C]// AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2018: 8075-8076.
- [7] CHEN C, ZHANG M, WANG C, et al. An efficient adaptive transfer neural network for social-aware recommendation[C]// ACM Special Interest Group on International Retrieval. New York: ACM Press, 2019: 225-234.
- [8] CHENG C, YANG H, KING I, et al. Fused matrix factorization with geographical and social influence in location-based social networks[C]// AAAI Conference on Artificial Intelligence. Palo Alto: AAAI Press, 2012: 1-8.
- [9] ZHENG N, JIN X, LI L. Cross-region collaborative filtering for new point-of-interest recommendation [C]// Proceedings of the 22nd International Conference on World Wide Web. New York: ACM Press, 2013: 45-46.
- [10] MA C, ZHANG Y, WANG Q, et al. Point-of-Interest recommendation: exploiting self-attentive auto encoders with neighbor-aware influence[C]// Proceedings of the 27th ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2018: 697-706.
- [11] ZHAO Z, YANG Q, LU H, et al. Learning max-margin geosocial multimedia network representations for point-of-interest suggestion[C]// Proceedings of the 40th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM Press, 2017: 833-836.
- [12] YANG C, BAI L, ZHANG C, et al. Bridging collaborative filtering and semi-supervised learning: a neural approach for POI recommendation[C]// Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM Press, 2017: 1245-1254.
- [13] YING H, CHEN L, XIONG Y, et al. PGRank: personalized geographical ranking for point-of-interest recommendation[C]// Proceedings of the 25th International Conference Companion on World Wide Web. New York: ACM Press, 2016: 137-138.
- [14] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering[C]// Proceedings of the 26th International Conference Companion on World Wide Web. New York: ACM Press, 2017: 173-182.
- [15] ZHENG L, CHUN T L, JIANG F, et al. Spectral collaborative filtering[C]// Proceedings of the 12th ACM Conference on Recommender Systems. New York: ACM Press, 2018: 311-319.
- [16] XIE M, YIN H, WANG H, et al. Learning graph-based POI embedding for location-based recommendation[C]// Proceedings of the 25th ACM International on Conference on Information and Knowledge Management. New York: ACM Press, 2016: 15-24.
- [17] ZHANG J D, CHOW C Y. iGSLR: personalized geo-social location recommendation: a kernel density estimation approach[C]// Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York: ACM Press, 2013: 334-343.
- [18] WANG H, TERROVITIS M, MAMOULIS N. Location recommendation in location-based social networks using user check-in data[C]// Proceedings of the 21st ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York: ACM Press, 2013: 374-383.
- [19] ZHANG J D, CHOW C Y, LI Y. Lore: exploiting sequential influence for location recommendations[C]// Proceedings of the 22nd ACM SIGSPATIAL International Conference on Advances in Geographic Information Systems. New York: ACM Press, 2014: 103-112.
- [20] YE M, YIN P, LEE W C, et al. Exploiting geographical influence for collaborative point-of-interest recommendation[C]// Proceedings of the 34th international ACM SIGIR conference on Research and development in Information Retrieval. New York: ACM Press, 2011: 325-334.
- [21] LIU Y, WEI W, SUN A, et al. Exploiting geographical neighborhood characteristics for location recommendation[C]// Proceedings of the 23<sup>rd</sup> ACM International Conference on Information and Knowledge Management. New York: ACM Press, 2014: 739-748.
- [22] JONATHAN L H, JOSEPH A K, LOREN G T, et al. Evaluating collaborative filtering recommender systems[J]. ACM Transactions on Information Systems, 2004, 22(1): 5-53.
- [23] TANG J, HU X, GAO H, et al. Exploiting local and global social context for recommendation[C]// Proceedings of the 23rd International Joint Conference on Artificial Intelligence. New York: ACM Press, 2013: 2712-2718.

#### [作者简介]



刘真(1977-),女,江西南昌人,博士,北京交通大学副教授,主要研究方向为社会网络计算、推荐系统、大数据分析 & 挖掘。

王娜娜(1995-),女,山东潍坊人,北京交通大学硕士生,主要研究方向为推荐系统、基于位置的社交网络。

王晓东(1995-),男,湖北黄冈人,北京交通大学硕士生,主要研究方向为社交网络与社会计算。

孙永奇(1969-),男,河南洛阳人,博士,北京交通大学教授,主要研究方向为大数据分析 & 挖掘、高性能计算。

## 收录声明

本刊对发表的文章,拥有出版电子版、网络版版权,并拥有和其他网站交换信息的权利。本刊支付的稿酬中已经包含上述费用。

*Journal on Communications* has the copyright to publish electronic edition, online edition of the published articles, and has the right to exchange information with other sites. The expenses have been included in the fee paid by editorial department.

## 道德声明

本刊发表的论文是作者独立取得的原创性研究成果,无一稿多投;论文内容不涉及国家机密;未曾以任何形式用任何文种在国内外公开发表过;论文内容不侵犯他人著作权和其他权利。若发生一稿多投、侵权、泄密等问题,论文作者将承担全部责任。

The authors of *Journal on Communications* guarantee that their submitted articles are original and contain nothing confidential. The said article is only submitted to *Journal on Communications*. The said article has not been published before and has not been submitted elsewhere for print or electronic publication consideration. The said article is no way whatever a violation or an infringement of any existing copyright or license from the third party. Otherwise, the authors of the said article shall take the blame for the violation or infringement of the related copyright and the leakage of secrets.