

## 基于深度学习的混合兴趣点推荐算法

冯浩<sup>①</sup> 黄坤<sup>①</sup> 李晶<sup>\*②</sup> 高榕<sup>②</sup> 刘东华<sup>②</sup> 宋成芳<sup>②</sup>

<sup>①</sup>(中国舰船研究设计中心 武汉 430064)

<sup>②</sup>(武汉大学计算机学院 武汉 430072)

**摘要:** 针对现有兴趣点推荐的初始化和忽视评论信息语义上下文信息的问题, 将深度学习融入推荐系统中已经成为兴趣点推荐研究的热点之一。该文提出一种基于深度学习的混合兴趣点推荐模型(MFM-HNN)。该模型基于神经网络融合评论信息与用户签到信息来提高兴趣点推荐的性能。具体地, 利用卷积神经网络学习评论信息的特征表示, 利用降噪自动编码器对用户签到信息进行初始化。进而, 基于扩展的矩阵分解模型融合评论信息特征和用户签到信息的初始值进行兴趣点推荐。在真实签到数据集上进行实验, 结果表明所提MFM-HNN模型比其他先进的兴趣点推荐具有更好的推荐性能。

**关键词:** 推荐算法; 兴趣点; 矩阵分解; 神经网络; 深度学习

中图分类号: TP311

文献标识码: A

文章编号: 1009-5896(2019)04-0880-08

DOI: 10.11999/JEIT180458

## Hybrid Point of Interest Recommendation Algorithm Based on Deep Learning

FENG Hao<sup>①</sup> HUANG Kun<sup>①</sup> LI Jing<sup>②</sup> GAO Rong<sup>②</sup>  
LIU Donghua<sup>②</sup> SONG Chengfang<sup>②</sup>

<sup>①</sup>(China Ship Development and Design Center, Wuhan 430064, China)

<sup>②</sup>(Computer School, Wuhan University, Wuhan 430072, China)

**Abstract:** When modeling user preferences, the current researches of recommendation ignore the problem of modeling initialization and the review information accompanied with rating information for recommender models, integrating deep learning into the recommendation system becomes a hotspot of Point-Of-Interest (POI) recommendation. In this paper, a new POI recommendation model called Matrix Factorization Model integrated with Hybrid Neural Networks (MFM-HNN) is proposed. The model improves the performance of POI recommendation by fusing review text and check-in information based on Neural Network (NN). Specifically, the convolutional neural network is used to learn the feature representation of the review text and the check-in information is initialized by using the stacked denoising autoencoder. Furthermore, the extended matrix factorization model is exploited to fuse the review information feature and the initial value of the check-in information for POI recommendation. As is shown in the experimental results on real datasets, the proposed MFM-HNN achieves better recommendation performances than the other state-of-the-art POI recommendation algorithms.

**Key words:** Recommendation algorithm; Point-Of-Interest (POI); Matrix factorization; Neural Network (NN); Deep learning

### 1 引言

随着智能手机及其智能设备的飞速发展, 微

信、微博、Facebook、Flickr等社交网络吸引数十亿用户互相交流和共享信息。近年来社交网络应用的一个明显进步是引入空间技术, 促发了位置社交网络(Location-Based Social Network, LBSN)的出现, 如Foursquare, Twinkle和GeoLife<sup>[1]</sup>。在位置社交网络中基于空间技术的位置也被称为兴趣点<sup>[2]</sup>(Point-Of-Interest, POI), 例如餐馆、商店和博物馆等。兴趣点推荐广泛研究用户和兴趣点的相关信息对于用户行为的影响, 不仅帮助用户在位置社交

收稿日期: 2018-05-14; 改回日期: 2018-11-26; 网络出版: 2018-12-05

\*通信作者: 李晶 leejingcn@163.com

基金项目: 国家自然科学基金(41201404), 中央高校基本科研业务费专项资金(2042015gf0009)

Foundation Items: The National Natural Science Foundation of China (41201404), The Fundamental Research Funds for the Central Universities of China (2042015gf0009)

网络的海量数据中找到自己感兴趣的信息, 从而探索新的兴趣点和新的地理区域(如城市), 丰富用户的生活体验。同时也帮助相关服务提供商向潜在用户提供个性化服务, 从而提高营业收入<sup>[3]</sup>。

近年来, 针对位置社交网络中的兴趣点推荐问题, 大量的研究已经展开, 但是已有的兴趣点推荐算法存在如下的问题:

(1) 大多数POI推荐工作<sup>[4-6]</sup>将评论信息与签到信息关联起来降低数据的稀疏性, 然而, 评论信息在相关POI研究工作中还没有得到充分利用。大多数利用评论信息的推荐系统的工作都集中在使用狄利克雷分配模型(Latent Dirichlet Allocation, LDA)<sup>[7,8]</sup>挖掘评论信息的主题。但是, 该模型通常利用词袋模型处理评论信息, 忽视了评论信息的语义上下文信息。而且, 当数据过于稀疏时, LDA模型学习的潜在特征表示可能不是非常有效, 性能无法令人满意<sup>[9-11]</sup>。

(2) 大多数基于机器学习的POI推荐的研究都是利用矩阵分解技术来进行兴趣点的推荐<sup>[12-14]</sup>。基于矩阵分解模型的方法对用户和兴趣点潜在特征矩阵的初始化很敏感<sup>[15]</sup>。然而, 大多数基于矩阵分解的推荐工作回避或忽视了这个问题, 采用非常简单的方法(如随机或零初始化)初始化用户和项目的潜在特征。

因此, 本文提出一种利用深度学习技术融合用户评论信息的兴趣点推荐算法(MFM-HNN)。本文的内容如下:

(1) 利用卷积神经网络(Convolutional Neural Network, CNN)<sup>[10,16]</sup>自动获取评论信息中兴趣点的深层次特征, 并且可以同时考虑词序和上下文信息对提取的用户潜在兴趣特征的影响, 生成比LDA模型更好的潜在特征表示。特别是在用户-签到矩阵比较稀疏时, CNN的使用有助于深入了解评论信息, 产生更好的潜在模型。

(2) 提出一种通过逐层非监督学习的预训练数据的隐层表示的初始化方法。利用深度堆栈降噪自动编码器(Stacked Denoising AutoEncoder, SDAE)<sup>[11,17]</sup>通过对用户或兴趣点相关的签到信息进行重构学习用户或兴趣点的最佳初始值, 从而有效提高矩阵分解过程的学习效率和性能。

(3) 提出一种基于深度学习模型和经典矩阵分解模型框架融合兴趣点相关信息和签到信息, 并将其用于用户对于兴趣点偏好的评分预测, 给出具体的建模过程。基于两个真实的LBSN签到数据集进行大量实验, 验证本文所提算法的推荐性能。实验结果表明本文所提推荐算法优于其他先进的兴趣点推荐算法。

## 2 基于混合神经网络矩阵分解的兴趣点推荐模型

本节介绍MFM-HNN模型如图1所示, 左侧的虚线边框表示签到信息预处理组件, 右侧的虚线边框表示评论信息特征学习组件。输入用 $(\tilde{u}, \tilde{i}, \mathbf{x})$ 三元组, 其中,  $\tilde{u} = [u_1, u_2, \dots, u_m]$ 表示用户集合,  $\tilde{i} = [i_1, i_2, \dots, i_n]$ 表示兴趣点集合,  $\mathbf{x} = [x_1, x_2, \dots, x_n]$ 表示评论信息集合。具体地, 通过SDAE学习用户 $\tilde{u}$ 和兴趣点 $\tilde{i}$ 的初始化参数, 得到最优化的用户签到特征 $\mathbf{u}_{L/2}$ 和兴趣点签到特征 $\mathbf{i}_{L/2}$ ; 通过CNN网络学习评论信息 $\mathbf{x}$ 得到潜在特征向量 $\mathbf{z}$ 。然后融合签到特征 $\mathbf{i}_{L/2}$ 和兴趣点潜在特征 $\mathbf{z}$ , 得到兴趣点的特征 $\mathbf{v}$ 进行兴趣点评分预测。下面对模型的各个组件的学习过程进行详细的介绍。

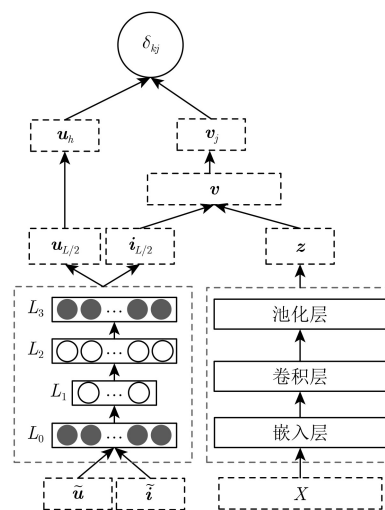


图1 基于混合神经网络矩阵分解的兴趣点推荐模型

### 2.1 评论信息特征学习组件

卷积层: 任意一个兴趣点的评论信息的集合表示为 $x_i = \{w_1, w_2, \dots, w_n\}$ , 利用词向量模型将 $x_i$ 中每个单词 $w_i$ 按出现的先后顺序映射为相应的词向量 $\mathbf{w}_i \in \mathbb{R}^{p \times 1}$ ,  $x_i$ 就转换为词序不变的词向量矩阵 $\mathbf{D} \in \mathbb{R}^{p \times l}$

$$\mathbf{D} = [\mathbf{w}_0 \ \mathbf{w}_1 \ \dots \ \mathbf{w}_{n-1}] \quad (1)$$

其中,  $p$ 表示单词 $w_i$ 的嵌入维度,  $\mathbf{w}_i$ 表示在 $x_i$ 的 $i$ 处的单词的词向量,  $l$ 是 $x_i$ 的长度。假设卷积窗口的大小为 $w_d$ ,  $x_i$ 的第 $i$ 个上下文特征 $c_i^j$  ( $c_i^j \in \mathbb{R}$ )是由第 $j$ 个共享权重 $\mathbf{W}_c^j \in \mathbb{R}^{p \times w_d}$ 通过卷积窗口对 $x_i$ 的第 $i$ 步的内容 $\mathbf{D}_{(:, i:(i+w_d-1))}$ 进行卷积得到的。即

$$c_i^j = f(\mathbf{W}_c^j * \mathbf{D}_{(:, i:(i+w_d-1))} + b_c^j) \quad (2)$$

其中,  $*$ 表示卷积操作,  $b_c^j$ 是偏置项,  $f$ 表示激活函数。多次卷积之后得到兴趣点特征向量 $\mathbf{c}^j \in \mathbb{R}^{l-w_d+1}$ 表示为

$$\mathbf{c}^j = [c_1^j, c_2^j, \dots, c_{l-w_d+1}^j] \quad (3)$$

池化层: 从上下文特征向量中提取最大的特征

向量表示该兴趣点的潜在特征。一个兴趣点的评论信息 $x_i$ 的上下文特征表示为 $\mathbf{d}_j$ ，即

$$\mathbf{d}_j = \left[ \max(\mathbf{c}_j^1), \max(\mathbf{c}_j^2), \dots, \max(\mathbf{c}_j^{n_c}) \right] \quad (4)$$

输出层：将池化层提取的特征向量映射到不同维度的向量空间，用于不同的任务。这里将特征向量 $\mathbf{d}_j$ 映射到 $k_d$ 维向量空间用于本文的推荐任务。

$$\mathbf{z} = \tanh \left( \mathbf{W}_{f_2} \left\{ \tanh \left( \mathbf{W}_{f_1} \mathbf{d}_j + \mathbf{b}_{f_1} \right) \right\} + \mathbf{b}_{f_2} \right) \quad (5)$$

其中， $\mathbf{z} \in \mathbb{R}^{k_d}$ ， $\mathbf{W}_{f_1} \in \mathbb{R}^{f \times n_c}$ ， $\mathbf{W}_{f_2} \in \mathbb{R}^{k_d \times f}$ 是映射矩阵， $\mathbf{b}_{f_1} \in \mathbb{R}^f$ ， $\mathbf{b}_{f_2} \in \mathbb{R}^{k_d}$ 是偏移向量。最终，完成了兴趣点评论信息 $x_i$ 的上下文特征的提取。因此，通过CNN学习兴趣点上下文特征的目标函数表示为

$$\mathcal{L}_{\text{cnn}} = \sum_i^n \left\| (\mathbf{v}_i - \text{cnn}(\mathbf{W}, x_i)) \right\|^2 + \lambda_{\mathbf{W}}^{\text{cnn}} \sum_i^{|W|} \left\| \mathbf{W}_i \right\|^2 \quad (6)$$

## 2.2 签到信息预处理组件

给定输入 $\mathbf{S}^u$ 和 $\mathbf{S}^v$ 分别表示用户偏好特征和兴趣点特征，每个用户偏好特征表示为 $\mathbf{s}_i^u = [f_{i,1}, f_{i,2}, \dots, f_{i,n}]^T$ ，每个兴趣点的特征表示为 $\mathbf{s}_i^v = [f_{1,i}, f_{2,i}, \dots, f_{m,i}]^T$ 。降噪自动编码器随机破坏 $\mathbf{S}^u$ 和 $\mathbf{S}^v$ 获得 $\tilde{\mathbf{S}}^u$ 和 $\tilde{\mathbf{S}}^v$ ，破坏后每个用户的偏好特征和每个兴趣点的特征分别表示为： $\tilde{\mathbf{s}}_i^u = [\tilde{f}_{i,1}, \tilde{f}_{i,2}, \dots, \tilde{f}_{i,n}]^T$ 和 $\tilde{\mathbf{s}}_i^v = [\tilde{f}_{1,i}, \tilde{f}_{2,i}, \dots, \tilde{f}_{m,i}]^T$ 。具体过程可以表示为

$$\left. \begin{aligned} \mathbf{h}_u &= g(\mathbf{W}_1 \tilde{\mathbf{s}}^u + \mathbf{b}_u) \\ \mathbf{h}_v &= g(\mathbf{V}_1 \tilde{\mathbf{s}}^v + \mathbf{b}_v) \\ \hat{\mathbf{s}}^u &= f(\mathbf{W}_2 \mathbf{h}_u + \mathbf{b}_{\hat{u}}) \\ \hat{\mathbf{s}}^v &= f(\mathbf{V}_2 \mathbf{h}_v + \mathbf{b}_{\hat{v}}) \end{aligned} \right\} \quad (7)$$

其中， $\tilde{\mathbf{s}}^u$ 和 $\tilde{\mathbf{s}}^v$ 表示破坏后的 $\mathbf{s}^u$ 和 $\mathbf{s}^v$ ， $\hat{\mathbf{s}}^u$ 和 $\hat{\mathbf{s}}^v$ 表示重构的 $\mathbf{s}^u$ 和 $\mathbf{s}^v$ ， $\mathbf{h}_u$ 和 $\mathbf{h}_v$ 表示输入的潜在表示。 $\mathbf{W}$ ， $\mathbf{V}$ 表示权重矩阵， $\mathbf{b}$ 表示偏置向量。 $g(\cdot)$ 和 $f(\cdot)$ 表示激活函数。如图1所示，堆栈降噪自动编码器多个隐藏层可以表示为

$$\mathbf{h}_l = g(\mathbf{W}_l \mathbf{h}_{l-1} + \mathbf{b}_l) \quad (8)$$

其中， $\mathbf{h}_0$ 为破坏的输入， $l \in \{1, 2, \dots, L-1\}$ 。对于输入 $\tilde{\mathbf{s}}^u$ 和 $\tilde{\mathbf{s}}^v$ ，第 $L$ 层的输出为

$$\left. \begin{aligned} \hat{\mathbf{s}}^u &= f(\mathbf{W}_L \mathbf{h}_L + \mathbf{b}_{\hat{u}}) \\ \hat{\mathbf{s}}^v &= f(\mathbf{V}_L \mathbf{h}_L + \mathbf{b}_{\hat{v}}) \end{aligned} \right\} \quad (9)$$

其中，前 $L/2$ 层作为编码器，后 $L/2$ 层作为解码器。因此，重构数据的损失函数为

$$\begin{aligned} & \arg \min_{\mathbf{W}_l, \mathbf{V}_l, \mathbf{b}_l} \left\| \mathbf{S}^u - \hat{\mathbf{S}}^u \right\|_{\text{F}}^2 + \left\| \mathbf{S}^v - \hat{\mathbf{S}}^v \right\|_{\text{F}}^2 \\ & + \lambda_U \left( \sum_l \left\| \mathbf{W}_l \right\|_{\text{F}}^2 + \left\| \mathbf{b}_l \right\|_{\text{F}}^2 \right) \\ & + \lambda_V \left( \sum_l \left\| \mathbf{V}_l \right\|_{\text{F}}^2 + \left\| \mathbf{b}_l \right\|_{\text{F}}^2 \right) \end{aligned} \quad (10)$$

其中， $\mathbf{W}_l$ ， $\mathbf{V}_l$ 表示权重矩阵， $\mathbf{b}_l$ 表示偏置向量， $\lambda_U$ ， $\lambda_V$ 表示正则化参数。因此，MFM-HNN模型的最终目标函数为

$$\begin{aligned} \mathcal{L} = & - \sum_{hj} (R_{hj} - \mathbf{u}_h^T \mathbf{v}_j)^2 - \lambda_m^h \sum_{u=1}^m (\mathbf{s}_h^u - \hat{\mathbf{s}}_h^u)^2 \\ & - \lambda_n^j \sum_{j=1}^n (\mathbf{s}_j^v - \hat{\mathbf{s}}_j^v)^2 - \lambda_w^h \sum_h (\left\| \mathbf{W}_h \right\|_{\text{F}}^2 + \left\| \mathbf{b}_h \right\|_{\text{F}}^2) \\ & - \lambda_w^j \sum_j (\left\| \mathbf{V}_j \right\|_{\text{F}}^2 + \left\| \mathbf{b}_j \right\|_{\text{F}}^2) \\ & - \lambda_{\text{cnn}} \sum_{j=1}^n \left\| (\tilde{\mathbf{v}}_j - \text{cnn}(\mathbf{W}, x_j)) \right\|_{\text{F}}^2 \\ & - \lambda_w^{\text{cnn}} \sum_{j=1}^{|\mathbf{W}_{\text{cnn}}|} \left\| \mathbf{W}_{\text{cnn}} \right\|_{\text{F}}^2 - \lambda_h \sum_{h=1}^m \left\| \mathbf{u}_h \right\|_{\text{F}}^2 \\ & - \lambda_j \sum_{j=1}^n \left\| \mathbf{v}_j \right\|_{\text{F}}^2 \end{aligned} \quad (11)$$

## 2.3 参数学习

对于参数 $\mathbf{u}_h$ ， $\mathbf{v}_j$ 的更新，本文利用随机梯度下降法进行学习， $\mathcal{L}(\mathbf{U}, \mathbf{V})$ 表示目标函数。假设与 $\mathbf{u}_h$ ， $\mathbf{v}_j$ 无关的变量为定值。更新规则为

$$\left. \begin{aligned} \mathbf{u}_h &= \mathbf{u}_h - \eta \frac{\partial}{\partial \mathbf{u}_h} \mathcal{L}(\mathbf{U}, \mathbf{V}) \\ \mathbf{v}_j &= \mathbf{v}_j - \eta \frac{\partial}{\partial \mathbf{v}_j} \mathcal{L}(\mathbf{U}, \mathbf{V}) \end{aligned} \right\} \quad (12)$$

其中， $\eta$ 是学习率，梯度更新的结果为

$$\left. \begin{aligned} \frac{\partial}{\partial \mathbf{u}_h} \mathcal{L}(\mathbf{U}, \mathbf{V}) &= - \sum_{hj} (R_{hj} - \mathbf{u}_h^T \mathbf{v}_j) (-\mathbf{v}_j) \\ & \quad - \lambda_m^h \sum_{u=1}^m (\mathbf{s}_h^u - \hat{\mathbf{s}}_h^u) \frac{\partial \hat{\mathbf{s}}_h^u}{\partial \mathbf{u}_h} - \lambda_h \mathbf{u}_h \\ \frac{\partial}{\partial \mathbf{v}_j} \mathcal{L}(\mathbf{U}, \mathbf{V}) &= - \sum_{hj} (R_{hj} - \mathbf{u}_h^T \mathbf{v}_j) (-\mathbf{u}_h^T) \\ & \quad - \lambda_n^j \sum_{j=1}^n (\mathbf{s}_j^v - \hat{\mathbf{s}}_j^v) \frac{\partial \hat{\mathbf{s}}_j^v}{\partial \mathbf{v}_j} \\ & \quad - \lambda_{\text{cnn}} \sum_{j=1}^n (\tilde{\mathbf{v}}_j - \text{cnn}(\mathbf{W}, x_j)) \\ & \quad \frac{\partial \tilde{\mathbf{v}}_j}{\partial \mathbf{v}_j} - \lambda_j \mathbf{v}_j \end{aligned} \right\} \quad (13)$$

通过学习用户和兴趣点的潜在特征表示，兴趣点潜在特征表示和偏好预测为

$$\hat{R}_{u,i} \approx (\mathbf{u}_u)^T \mathbf{v}_i = (\mathbf{u}_u)^T \left( \text{cnn}(\mathbf{W}, x_i) + \mathbf{s}_{L/2}^i \right) \quad (14)$$

本文提出模型的学习算法过程如表1所示。

表1 MFM-HNN模型学习算法

输入: $x_i, S^u, S^v, \tilde{S}^u, \tilde{S}^v, T, B$
输出: $\mathcal{L}$
(1) For $t < T$ Do
(2) 从兴趣点评论中随机选取一个兴趣点的评论矩阵 $x_i$ 进行训练, 训练批次大小为 $\beta_0$ , 每一个批次的大小为 $B$ , 计算训练过程中的损失 $\mathcal{L}_{cm}$
(3) if $t > T$ or $\mathcal{L}_{cm}$ 足够小
(4) end
(5) for $t < T$ Do
(6) 从兴趣点评分中随机选取一个兴趣点的用户-兴趣点对 $(\tilde{s}_i^u, \tilde{s}_i^v)$ 进行训练, 训练批次大小为 $\beta_1$ , 每一个批次的大小为 $B$ , 计算训练过程中的损失 $\mathcal{L}_{ui}$
(7) if $t > T$ or $\mathcal{L}_{ui}$ 足够小
(8) end
(9) 计算最终的损失值 $\mathcal{L} = \mathcal{L}_{cm} + \mathcal{L}_{ui}$
(10) return $\mathcal{L}$

## 2.4 复杂度分析

在更新卷积权重学习文本的潜在特征向量时, 卷积神经网络的复杂度为  $O(n_c p l N)$ , 其中  $N$  表示兴趣点评论信息的数量,  $p$  表示嵌入的维度,  $l$  表示一个兴趣点评论信息的长度,  $n_c$  表示学习的上下文特征的数量。编码器更新用户和兴趣点的复杂度为  $O(2\eta k_1)$ , 其中  $\eta$  是词汇量大小,  $k_1$  是输出的潜在维度。更新权重和偏差的复杂度为  $O(m\eta k_1 + n\eta k_1)$ 。因此, 总的复杂度为  $O(m\eta k_1 + n\eta k_1 + n_c p l N + 2\eta k_1)$ 。

## 3 实验

### 3.1 实验数据集

本文选用公开的Foursquare<sup>[18]</sup>的两个数据集验证模型的有效性。Foursquare数据集是对美国洛杉矶(LA)和纽约(NYC)的签到的统计, 如表2所示。针对签到(评论)采用类似于文献[9,19]的方法对文本信息进行预处理。

### 3.2 评价指标

本文采用准确率和召回率作为位置推荐的评价指标来评估推荐算法的性能, 分别用  $P@k$  和  $RC@k$  来表示。对一个用户  $u$ ,  $dl$  表示观察到的兴趣点数量,  $vl$  表示已访问的兴趣点数量,  $P@k$  和  $RC@k$  定义为

$$P@k = \frac{dl}{k} \quad (15)$$

表2 数据集统计

数据统计	LA	NYC
用户数量	30,208	47,240
兴趣点数量	142,798	203,765
签到数量(评论)	244,861	388,954
用户-位置矩阵密度	$5.68 \times 10^{-5}$	$4.04 \times 10^{-5}$

$$RC@k = \frac{dl}{vl} \quad (16)$$

其中, 对模型在不同参数下的性能时进行多次评估。在实验中, 选择  $P@1$ ,  $P@5$  和  $P@10$ , 以及  $RC@1$ ,  $RC@5$ , 和  $RC@10$  作为评估指标。

### 3.3 实验设计

本文采用3种不同的策略从不同的角度进行测试, 以验证本文算法的有效性。

(1)与主流先进的算法进行对比: 本文与4种先进主流兴趣点推荐算法进行比较, 从而验证算法的高效性。

(2)潜在特征预处理的测试: 通过对矩阵分解过程中矩阵交互的潜在特征的预处理, 验证本文所提初始化方法的有效性。

(3)SDAE层数的测试: 类似于文献[9]验证SDAE的层数对模型性能的影响。

首先, 选定了4个兴趣点推荐算法用于对比:

(1)IRenMF: 文献[20]提出利用两个层次的地理邻域关系进行地理位置信息的建模, 其中假设签到到兴趣点的地理邻域兴趣点更适合推荐给用户。

(2)ASMF: 文献[21]根据朋友的类别(社交朋友、位置朋友和邻居朋友)提出一个两阶段框架来进行基于用户社交信息的兴趣点推荐。

(3)LCARS: 文献[7]基于LDA主题模型利用用户的签到数据和评论文本信息来构建兴趣点推荐系统。

(4)CDL: 文献[9]提出的一种层次贝叶斯模型, 该模型提取内容的有效深度特征表示, 同时捕捉相似度以及物品(和用户)之间的隐含关系。本文实验中, 基于这种方法建模用户签到行为。

其次, 将4种经典方法初始化方法与本文提出的初始化方法进行比较:

(1)随机初始化(random initialization): 文献[18]提出基于用户随机设置。

(2)零初始化(zero initialization): 文献[18]提出初始值设置为零。

(3)K-means初始化(K-means initialization): 文献[22]提出基于K-means方法进行初始化设置。

(4)归一化切割初始化(Normalized-CUT initialization, NCUT): 文献[23]提出基于NCUT的方法进行初始化设置。

最后基于不同的层数验证对于本文模型推荐性能的影响。

### 3.4 参数设置

对于不同的模型参数设置为: 对于IRenMF:  $K=100$ ,  $\alpha=0.4$ ,  $\lambda_1=\lambda_2=0.015$ ,  $\lambda_3=1$ ,  $\#NN=10$ ,  $\#clusters=50$ ; 对于ASMF:  $K=100$ ,  $\alpha=0.4$ ,  $\lambda_u=\lambda_v=0.01$ ,  $\lambda_q=0.1$ ,  $\zeta=0.4$ ,  $\gamma=0.4$ ,  $\varepsilon=0.4$ ; 对于

LCARS:  $K=100$ ,  $\alpha=\alpha'=50/K$ ,  $\beta=\beta'=0.01$ ,  $\gamma=\gamma'=0.5$ ; 对于两层的CDL模型:  $\lambda_h=0.1$ ,  $\lambda_j=1$ ,  $\lambda_w^j=0.0001$ ,  $\lambda_n^j=100$ , 对于SDAE的设置与本文提出的MFM-HNN相同。

对于本文所提MFM-HNN模型, SDAE采用30%的噪声擦除以从清洁输入 $s$ 获得损坏的输入 $\tilde{s}$ 。丢弃率为0.1以实现自适应正则化, 防止过拟合。隐藏单元数 $K_l$ 为1000, 中间层数为200。潜在因子的数量为 $|u_h|=|v_j|=|v_k|=200$ 。学习率为0.2。  $\lambda_h=0.01$ ,  $\lambda_j=0.1$ ,  $\lambda_w^j=0.0001$ ,  $\lambda_n^j=5$ 可以实现良好的性能。

### 3.5 实验结果分析

#### 3.5.1 推荐模型的比较与分析

网络结构的设置为: 8000-1000-200-1000-8000, SDAE的编码层为3时, 本文MFM-HNN模型与现有主流先进算法的性能对比结果如图2所示。

(1) IRenMF: 这种方法受到数据集数据缺失的影响很大, 如表1, 本文两个数据集的用户-兴趣点的矩阵密度相对偏低。因此, 如图2所示, IRenMF相对于其他4种方法体现出最差的推荐性能。

(2) LCARS: 这种方法依然受到数据稀疏性的影响, 同时数据过于稀疏时, 基于LDA模型无法有效学习兴趣点的潜在特征, 同时相比社交信息和地理信息对于POI推荐性能的影响, 评论文本信息的影响是最小。因此, 如图2所示, LCARS的方法相对于其他4种方法表现出排名第3的推荐性能。

(3) ASMF: ASMF的表现不如IRenMF模型,

如图2所示, ASMF的方法相对于其他4种方法表现出排名第4的推荐性能。可能的解释是因为ASMF侧重于利用社交信息。

(4) CDL: CDL可以产生比上述模型, 特别是LCARS模型更优的推荐结果。但是, 在对评论文本信息的潜在特征进行学习时没有考虑词序对学习的潜在特征的影响, 因此, 导致CDL模型最终体现出第2好的推荐结果。

(5) MFM-HNN: 如图2所示, 基于2个数据集MFM-HNN模型在推荐性能上表现最好。MFM-HNN模型在对评论信息的潜在特征进行学习时, 充分考虑词序及上下文信息对学习的潜在特征表示的影响, 克服LDA模型的先验分布建模前难以定义, 以及当评论信息非常稀少时主题的比例不能有效地代表项目的潜在特征的问题。同时, MFM-HNN模型在进行矩阵分解实现用户-兴趣点特征的交互时, 特征的初始值采用本文所提基于神经网络方法进行选取, 避免了优化时陷入局部最优解。因此, MFM-HNN模型最终体现出最好的推荐效果。

#### 3.5.2 预训练初始化参数的影响

为了验证本文所提利用自动编码器进行初始化的有效性, 将本文所提初始化方法与几种经典的初始化方法进行对比实验, 例如随机初始化、零初始化、K-means初始化和归一化切割初始化。本文所提参数初始化方法与以上提到的几种初始化方法的对比结果如图3所示。

从图3可以看出, 本文所提初始化模型降噪编

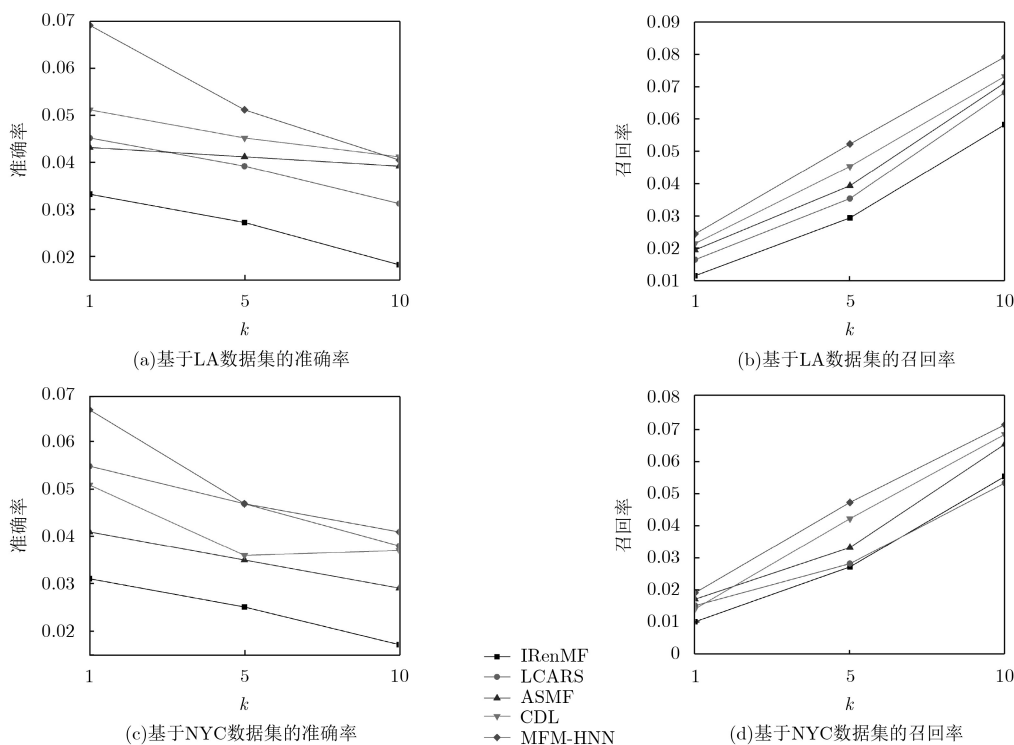


图2 MFM-HNN模型基于LA数据集和NYC数据集与其他4个模型的推荐性能对比

码器预处理方法优于其他的初始化方法，有效避免了矩阵分解过程中由于初始值造成的局部最优问题。主要原因在于：(1)本文提出的模型应用原始用户、兴趣点特征向量学习用户和兴趣点的特征，相当于学习模型的全局最小化；(2)学习的初始化向量可以更好地体现用户和兴趣点原始的相似关系。

### 3.5.3 编码器层数的影响

为了研究编码器的层数变化对本文所提模型的影响，本文设计了不同层数的编码器的实验，验证编码器层数的变化对推荐性能的影响。其中，DA-1, DA-2等表示编码器的层数，实验结果如图4所示。

图4显示了基于不同数据集LA和NYC，随着编

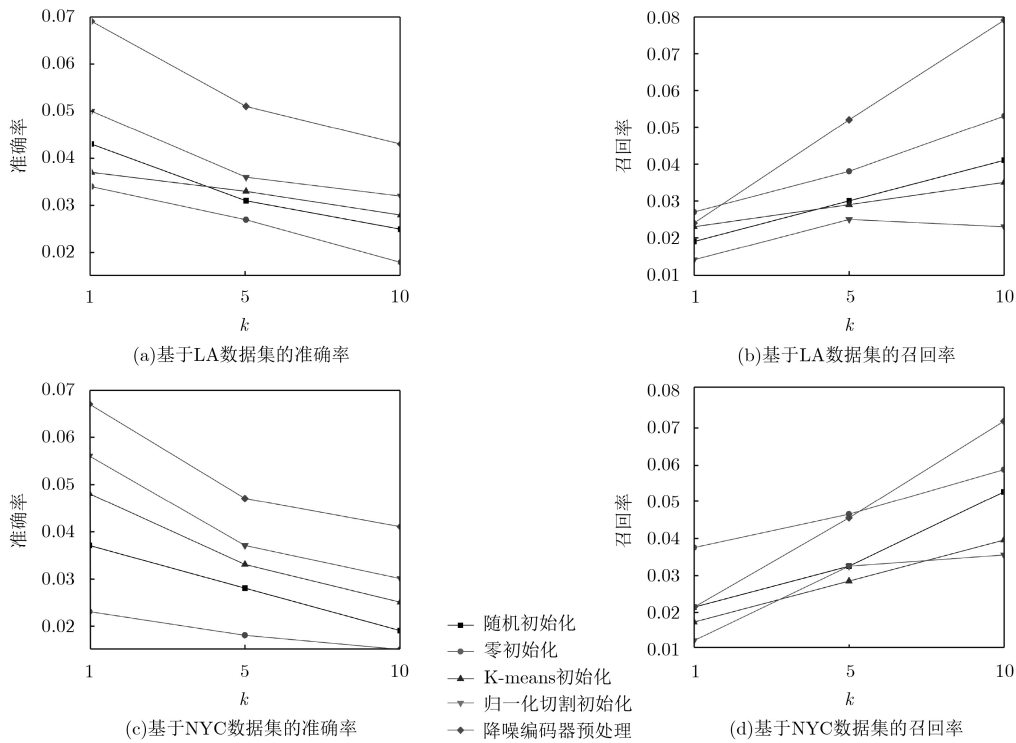


图3 基于LA和NYC数据集的5个初始化方法的性能对比

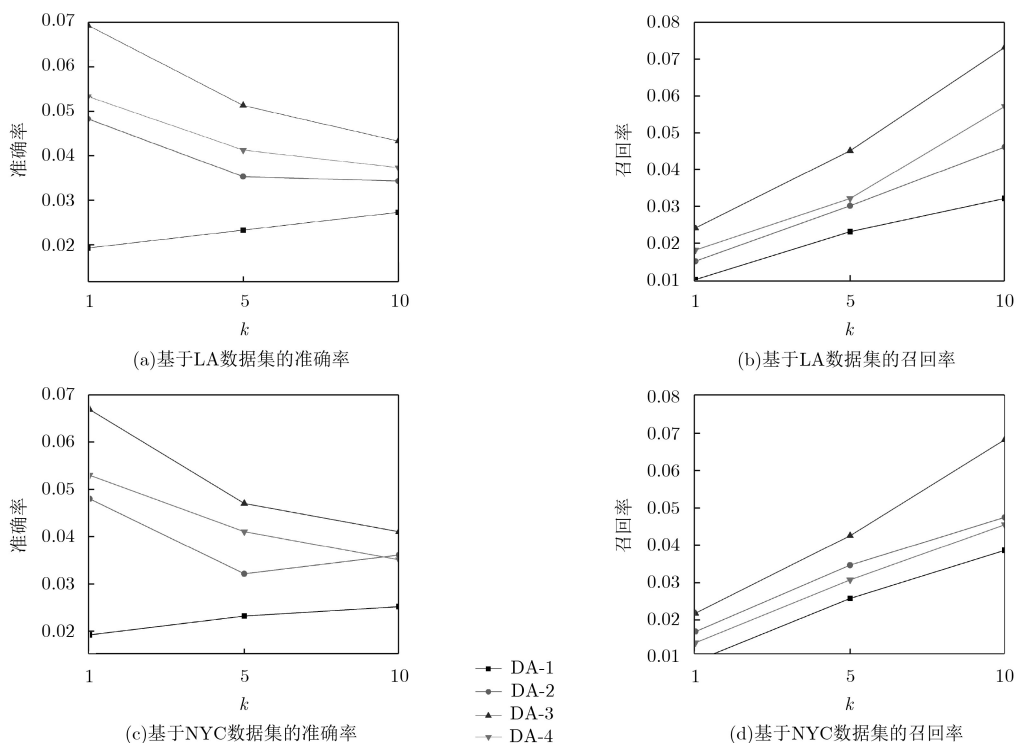


图4 MFH-HNN模型基于LA数据集和NYC数据集在不同层数的性能对比

码器层数的变化, 召回率和准确率的变化情况。从图4中可以看出, 当层数为1和2时, 召回率和准确率都相当低, 而随着层数的增加, 召回率和准确率都在一定程度上得到了提高。即当反馈矩阵非常稀疏时, 兴趣点推荐的性能取决于潜在特征表示的质量。当层数为3时, 召回率和准确率达到最佳值, 表明MFM-HNN模型利用SDAE作为预处理组件可以有效提高推荐的精确度。当层数为4, 开始出现拟合, 降低了MFM-HNN模型的推荐性能。因此, 本文设置层数为3是合理的。

#### 4 结束语

本文提出了一种基于深度学习的混合兴趣点推荐算法(MFM-HNN)用于兴趣点的推荐, 以及利用深度自动编码器来学习矩阵分解过程中用户和兴趣点的潜在特征向量初始值。MFM-HNN模型采用卷积神经网络模型学习评论信息的上下文特征, 从而提取了更精确的特征表示实现了评论信息的建模。对于矩阵分解模型中用户和兴趣点交互的建模, 则利用降噪自动编码器学习用户和兴趣点的潜在特征向量的最佳初始值有效避免矩阵分解的过程中陷入局部最优解。最终利用矩阵分解技术融合上述2种建模实现对用户提供兴趣点推荐服务。在未来的工作中, 基于深度学习框架融合多种上下文信息将是一个值得关注的方向。

#### 参 考 文 献

- [1] LI Jun, BENEDIKTSSON J A, ZHANG Bing, *et al.* Spatial technology and social media in remote sensing: A survey[J]. *Proceedings of the IEEE*, 2017, 105(10): 1855–1864. doi: [10.1109/JPROC.2017.2729890](https://doi.org/10.1109/JPROC.2017.2729890).
- [2] YANG, C, BAI Lanxiao, ZHANG Chao, *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, Halifax, Canada, 2017: 1245–1254. doi: [10.1145/3097983.3098094](https://doi.org/10.1145/3097983.3098094).
- [3] LIU Yiding, PHAM T A N, CONG Gao, *et al.* An experimental evaluation of point-of-interest recommendation in location-based social networks[J]. *Proceedings of the VLDB Endowment*, 2017, 10(10): 1010–1021. doi: [10.14778/3115404.3115407](https://doi.org/10.14778/3115404.3115407).
- [4] MAZUMDAR P, PATRA B K, BABU K S, *et al.* Hidden location prediction using check-in patterns in location-based social networks[J]. *Knowledge and Information Systems*, 2017, 57(3): 571–601. doi: [10.1007/s10115-018-1170-5](https://doi.org/10.1007/s10115-018-1170-5).
- [5] 余永红, 高阳, 王皓. 基于Ranking的泊松矩阵分解兴趣点推荐算法[J]. *计算机研究与发展*, 2016, 53(8): 1651–1663. doi: [10.7544/issn1000-1239.2016.20160202](https://doi.org/10.7544/issn1000-1239.2016.20160202).
- [6] YU Yonghong, GAO Yang, and WANG Hao. A ranking based Poisson matrix factorization model for point-of-interest recommendation[J]. *Journal of Computer Research and Development*, 2016, 53(8): 1651–1663. doi: [10.7544/issn1000-1239.2016.20160202](https://doi.org/10.7544/issn1000-1239.2016.20160202).
- [7] LIM K H, CHAN J, LECKIE C, *et al.* Personalized trip recommendation for tourists based on user interests, points of interest visit durations and visit recency[J]. *Knowledge and Information Systems*, 2018, 54(2): 375–406. doi: [10.1007/s10115-017-1056-y](https://doi.org/10.1007/s10115-017-1056-y).
- [8] YIN Hongzhi, SUN Yizhou, CUI Bin, *et al.* LCARS: A location-content-aware recommender system[C]. Proceedings of the 19th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Chicago, USA, 2013: 221–229. doi: [10.1145/2487575.2487608](https://doi.org/10.1145/2487575.2487608).
- [9] ZHANG Jiadong, CHOW Chiyin, and ZHENG Yu. ORec: An opinion-based point-of-interest recommendation framework[C]. Proceedings of the 24th ACM International Conference on Information and Knowledge Management, Melbourne, Australia, 2015: 1641–1650. doi: [10.1145/2806416.2806516](https://doi.org/10.1145/2806416.2806516).
- [10] WANG Hao, WANG Naiyan, and YEUNG D Y. Collaborative deep learning for recommender systems[C]. Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, Sydney, Australia, 2015: 1235–1244. doi: [10.1145/2783258.2783273](https://doi.org/10.1145/2783258.2783273).
- [11] KIM D, PARK C, OH J, *et al.* Convolutional matrix factorization for document context-aware recommendation[C]. Proceedings of the 10th ACM Conference on Recommender Systems, Boston, USA, 2016: 233–240. doi: [10.1145/2959100.2959165](https://doi.org/10.1145/2959100.2959165).
- [12] DONG Xing, YU Lei, WU Zhonghuo, *et al.* A hybrid collaborative filtering model with deep structure for recommender systems[C]. Proceedings of the 31st AAAI Conference on Artificial Intelligence, San Francisco, USA, 2017: 1309–1315.
- [13] 任星怡, 宋美娜, 宋俊德. 基于位置社交网络的上下文感知的兴趣点推荐[J]. *计算机学报*, 2017, 40(4): 824–841. doi: [10.11897/SP.J.1016.2017.00824](https://doi.org/10.11897/SP.J.1016.2017.00824).
- [14] REN Xingyi, SONG Meina, and SONG Junde. Context-aware point-of-interest recommendation in location-based social networks[J]. *Chinese Journal of Computer*, 2017, 40(4): 824–841. doi: [10.11897/SP.J.1016.2017.00824](https://doi.org/10.11897/SP.J.1016.2017.00824).
- [15] GAO Rong, LI Jing, LI Xuefei, *et al.* A personalized point-of-interest recommendation model via fusion of geo-social information[J]. *Neurocomputing*, 2018, 273: 159–170. doi: [10.1016/j.neurocom.2018.05.045](https://doi.org/10.1016/j.neurocom.2018.05.045).

- [10.1016/j.neucom.2017.08.020](https://doi.org/10.1016/j.neucom.2017.08.020).
- [14] LIAN Defu, ZHENG Kai, GE Yong, *et al.* GeoMF++: Scalable location recommendation via joint geographical modeling and matrix factorization[J]. *ACM Transactions on Information Systems*, 2018, 36(3): 33. doi: [10.1145/3182166](https://doi.org/10.1145/3182166).
- [15] ZDUNEK R. Initialization of nonnegative matrix factorization with vertices of convex polytope[C]. Proceedings of the 11st International Conference on Artificial Intelligence and Soft Computing, Zakopane, Poland, 2012: 448–455. doi: [10.1007/978-3-642-29347-4\\_52](https://doi.org/10.1007/978-3-642-29347-4_52).
- [16] YANG Cheng, SUN Maosong, ZHAO W X, *et al.* A neural network approach to jointly modeling social networks and mobile trajectories[J]. *ACM Transactions on Information Systems*, 2017, 35(4): 36. doi: [10.1145/3041658](https://doi.org/10.1145/3041658).
- [17] DENG Shuiguang, HUANG Longtao, XU Guangdong, *et al.* On deep learning for trust-aware recommendations in social networks[J]. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(5): 1164–1177. doi: [10.1109/TNNLS.2016.2514368](https://doi.org/10.1109/TNNLS.2016.2514368).
- [18] GAO Huiji, TANG Jiliang, HU Xia, *et al.* Content-aware point of interest recommendation on location-based social networks[C]. Proceedings of the 29th AAAI Conference on Artificial Intelligence, Austin, Texas, 2015: 1721–1727.
- [19] ZHANG Fuzheng, YUAN N J, ZHENG Kai, *et al.* Exploiting dining preference for restaurant recommendation[C]. Proceedings of the 25th International Conference on World Wide Web, Montréal, Canada, 2016: 725–735. doi: [10.1145/2872427.2882995](https://doi.org/10.1145/2872427.2882995).
- [20] LIU Yong, WEI Wei, SUN Aixin, *et al.* Exploiting geographical neighborhood characteristics for location recommendation[C]. Proceedings of the 23rd ACM International Conference on Information and Knowledge Management, Shanghai, China, 2014: 739–748. doi: [10.1145/2661829.2662002](https://doi.org/10.1145/2661829.2662002).
- [21] LI Huayu, GE Yong, HONG Richang, *et al.* Point-of-interest recommendations: Learning potential check-ins from friends[C]. Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining, San Francisco, USA, 2016: 975–984. doi: [10.1145/2939672.2939767](https://doi.org/10.1145/2939672.2939767).
- [22] ORCHAND M. Least square quantization in PCM[J]. *IEEE Transaction on Information Theory*, 1982, 28(2): 129–137. doi: [10.1109/TIT.1982.1056489](https://doi.org/10.1109/TIT.1982.1056489).
- [23] SHI J and MALIK J. Normalized cuts and image segmentation[J]. *IEEE Transactions on Pattern Analysis and Machine Intelligence*, 2000, 22(8): 888–905. doi: [10.1109/34.868688](https://doi.org/10.1109/34.868688).
- 冯浩: 男, 1979年生, 博士, 高级工程师, 研究方向为体系结构和系统工程。
- 黄坤: 男, 1979年生, 博士, 高级工程师, 研究方向为人工智能和系统工程。
- 李晶: 男, 1967年生, 博士, 教授, 研究方向为数据挖掘和多媒体技术。
- 高榕: 男, 1981年生, 博士, 研究方向为数据挖掘和智能推荐。
- 刘东华: 女, 1989年生, 博士生, 研究方向为数据挖掘和智能推荐。
- 宋成芳: 男, 1978年生, 博士, 讲师, 研究方向为可视化分析和位置服务。