



# 计算机科学

COMPUTER SCIENCE

## 基于人群移动模式先验的兴趣点推荐

伊秋华, 高浩然, 陈馨琪, 孔祥杰

引用本文

伊秋华, 高浩然, 陈馨琪, 孔祥杰. [基于人群移动模式先验的兴趣点推荐](#)[J]. 计算机科学, 2023, 50(9): 139-144.

YI Qiu Hua, GAO Haoran, CHEN Xinqi, KONG Xiangjie. [Human Mobility Pattern Prior Knowledge Based POI Recommendation](#) [J]. Computer Science, 2023, 50(9): 139-144.

---

## 相似文章推荐 (请使用火狐或 IE 浏览器查看文章)

**Similar articles recommended (Please use Firefox or IE to view the article)**

[面向纵向图联邦学习的数据重构攻击方法](#)

Data Reconstruction Attack for Vertical Graph Federated Learning

计算机科学, 2023, 50(7): 332-338. <https://doi.org/10.11896/jsjcx.220900038>

[基于对比预测的自监督动态图表示学习方法](#)

Self-supervised Dynamic Graph Representation Learning Approach Based on Contrastive Prediction

计算机科学, 2023, 50(7): 207-212. <https://doi.org/10.11896/jsjcx.220500093>

[探索站点时空移动模式:长短期交通预测框架](#)

Exploring Station Spatio-Temporal Mobility Pattern:A Short and Long-term Traffic Prediction Framework

计算机科学, 2023, 50(7): 98-106. <https://doi.org/10.11896/jsjcx.220900109>

[结合残差与自注意力机制的图卷积小样本图像分类网络](#)

Graph Neural Network Few Shot Image Classification Network Based on Residual and Self-attention Mechanism

计算机科学, 2023, 50(6A): 220500104-5. <https://doi.org/10.11896/jsjcx.220500104>

[基于增强AST的图神经网络函数级代码漏洞检测方法](#)

Function Level Code Vulnerability Detection Method of Graph Neural Network Based on Extended AST

计算机科学, 2023, 50(6): 283-290. <https://doi.org/10.11896/jsjcx.220600131>

# 基于人群移动模式先验的兴趣点推荐

伊秋华<sup>1</sup> 高浩然<sup>2</sup> 陈馨琪<sup>3</sup> 孔祥杰<sup>1</sup>

1 浙江工业大学计算机科学与技术学院 杭州 310023

2 大连理工大学软件学院 辽宁 大连 116000

3 浙江大华技术股份有限公司 杭州 310051

(qiuhuayi@outlook.com)

**摘要** 兴趣点推荐是基于位置的社交网络中的一项重要任务,为用户提供个性化的地点推荐。然而,当前的兴趣点推荐方法主要学习用户在兴趣点上的签到历史和用户间的社交关系网络,城市人群出行规律无法得到有效利用。首先提出了人群移动模式提取框架(Human Mobility Pattern Extraction, HMPE),利用图神经网络作为人群移动模式的提取器,引入注意力机制捕获城市交通模式的时空信息。HMPE通过制定下游任务,设计上采样模块将表征向量还原为任务目标,实现端到端的框架学习训练,完成人群移动模式提取器的预训练。其次,提出了兴趣点推荐算法 HMRec(Human Mobility Recommendation),引入了人群移动模式的先验知识,使得推荐结果更符合城市中的人类出行意愿。对比实验结果显示, HMRec 的表现优于基线模型。最后,讨论了兴趣点推荐存在的问题和未来的研究方向。

**关键词:** 兴趣点推荐; 人群移动模式; 图神经网络

**中图法分类号** TP311

## Human Mobility Pattern Prior Knowledge Based POI Recommendation

YI Qiuhua<sup>1</sup>, GAO Haoran<sup>2</sup>, CHEN Xinqi<sup>3</sup> and KONG Xiangjie<sup>1</sup>

1 College of Computer Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China

2 School of Software, Dalian University of Technology, Dalian, Liaoning 116000, China

3 Zhejiang Dahua Technology Co., Ltd, Hangzhou 310051, China

**Abstract** Point of interest(POI) recommendation is a fundamental task in location-based social networks, which provides users with personalized place recommendations. However, the current point of interest recommendation is mostly based on learning the user's check-in history at the point of interest in the social network and the user relationship network for recommendation, and the travel rules of urban crowds cannot be effectively used. To solve the above problem, firstly, a human mobility pattern extraction(HMPE) framework is proposed, which takes advantage of graph neural network to extract human mobility pattern. Then attention mechanism is introduced to capture the spatio-temporal information of urban traffic pattern. By establishing downstream tasks and designing upsampling modules, HMPE restores representation vectors to task objectives. An end-to-end framework is built to complete pre-training of human mobility pattern extraction module. Secondly, the human mobility recommendation(HM-Rec)algorithm is proposed, which introduces the prior knowledge of crowd movement patterns, so that the recommendation results are more in line with human travel intentions in cities. Extensive experiments show that HMRec is superior to baseline models. Finally, the existing problems and future research directions of interest point recommendation are discussed.

**Keywords** POI recommendation, Human mobility pattern, Graph neural network

## 1 引言

由于移动定位设备(智能手机)的普及,基于位置的社交网络(Location-based Social Network, LBSNs)快速发展,用户能够在社交网络上通过在兴趣点(Point of Interest, POI)签到

来共享定位数据。大量的兴趣点定位数据能够反映出用户群体的偏好。兴趣点推荐是辅助用户探索周围环境以提升用户体验的重要方式。兴趣点推荐算法通过学习用户历史数据,来为用户提供个性化推荐服务。目前主流的兴趣点推荐系统关注于从用户历史的社交网络数据中学习用户的偏好来进行

到稿日期:2022-09-11 返修日期:2022-11-27

基金项目:国家自然科学基金(62072409);浙江省自然科学基金(LR21F020003)

This work was supported by the National Natural Science Foundation of China(62072409) and Natural Science Foundation of Zhejiang Province, China(LR21F020003).

通信作者:孔祥杰(xjkong@ieee.org)

推荐。但是,这种方式得出的结果可能是反常识的,例如在非工作日的晚上推荐商业区的咖啡厅。因此,兴趣点推荐工作应该结合人群移动模式的先验知识。

若想高效地挖掘人群移动模式,城市中的各种数据(交通轨迹数据、地图数据、定位数据、社交媒体数据和消费数据等)都应该被有效地利用。目前,如何对城市的多源异构数据间的关系进行有效表示,如何对多源异构数据关系进行特征提取和分析,依然是目前人群移动模式研究中重要和亟待解决的问题。此外,纯粹以提取人群移动模式为目的的研究比较少见,人群移动模式往往是用来完成某项具体下游任务而产生的一个中间结果。如何选取下游任务并验证获取人群移动模式的质量也是本文面临的问题。

为解决上述问题,本文首先对城市中普遍存在的人群移动模式进行提取。针对城市中多元的时空数据难以结构化表示的问题,本文提出了时空图这一新的时空数据结构;随后提出了人群移动模式提取(HMPE)架构,用于学习人群移动模式并提取其特征;设计了交通拥堵预测这一下游任务,在纽约真实的出租车数据集上设计并进行了交通拥堵预测实验,验证了端到端架构学习人群移动模式特征的可行性。为了将人群移动模式先验知识应用到实际的推荐过程中,本文提出了基于人群移动模式的兴趣点推荐算法(HMRec),并在 Four-square 数据集上验证了该方法优于现有算法。

本文第2章介绍了兴趣点推荐系统的研究背景和意义,叙述了人群移动模式发现和兴趣点推荐的国内外研究现状;第3章介绍了相关理论,重点阐述了人群移动模式发现、兴趣点推荐算法和所涉及的相关理论和技术;第4章给出了实验设计和结果分析;第5章总结了本文的具体贡献和意义,并讨论了未来可能的研究方向。

## 2 相关工作

本章介绍了兴趣点推荐和人群移动模式两个方面的最新进展。

### 2.1 兴趣点推荐

兴趣点推荐的发展可以归结于数据的融合方式的不断创新:从地理位置信息到用户社交关系,再到城市的时空模式,越来越多的关键要素被研究人员发掘出来,并将其作为推荐算法的新特征。早期的兴趣点推荐算法使用用户的签到频率进行推荐<sup>[1]</sup>。Berjani等<sup>[2]</sup>使用正则化的矩阵分解为社交网络中的用户提供个性化推荐。然而POI推荐的原始数据数值有非常大的变化范围,此外,用户签到矩阵的稀疏度远大于物品评分矩阵,例如Netflix数据集的稀疏度为99%,而Gowalla的稀疏度为 $2.08 \times 10^{-4}$ 。这些情况促进了数据融合的POI推荐<sup>[3]</sup>。在数据融合方式中,最早引入兴趣点推荐的是地理位置信息。对于POI推荐系统来说,地理学第一定律表现为:用户更加偏向于对地理距离与自己更近的POI感兴趣,并且对自己感兴趣的POI附近的POI兴趣也会更高。Si等<sup>[4]</sup>提出了一种结合用户活动和空间特征的自适应POI推荐方法,该方法可以根据用户活动自适应运行。Liu等<sup>[5]</sup>提出了Geo-ALM模型,该模型利用地理信息对抗学习,将地理特征和生成式对抗网络融合。在LBSNs中,一些POI推荐

工作利用社交关系网络来提高推荐质量<sup>[6]</sup>。Zhang等<sup>[7]</sup>把多标签、社会和地理影响分别形成LBSN的三层模型,最后将多维度的信息融合进矩阵分解框架。Zhang等<sup>[8]</sup>提出了一种上下文图注意力模型用于POI推荐。然而,兴趣点推荐的研究还处于初步阶段,尽管现有的各项工作考虑到了空间、社交、时间等因素对兴趣点推荐效果的影响,但是推荐的目标偏向于拟合用户个体的历史签到行为,无法学习到城市中人群的出行规律,最终得到的推荐结果不符合常识。

### 2.2 人群移动模式

为了高效地挖掘人群移动模式并将其引入到兴趣点推荐任务中,城市中的各种数据都应该被有效地利用,因此需要解决城市多元数据融合和人群移动模式挖掘这两个问题。对于城市多元数据融合,Zhang等<sup>[9]</sup>利用出租车数据、共享单车数据和路网数据分阶段检测异常区域,在任务处理流程的不同阶段使用不同的数据,以达到数据融合的目的。Liu等<sup>[10]</sup>提出了一种深度卷积自编码架构,使得编码层学习到不同数据的特征。Das等<sup>[11]</sup>利用协同过滤的思想,建立不同数据源之间的关系,并进行数据融合。多元数据的融合需要算法拥有很强的扩展性,然而目前还没有满足需求的通用方法。人群移动模式自身也是一种时空模式,时空模式挖掘直接影响了兴趣点推荐的质量。为了适配不同的时空网络,Li等<sup>[12]</sup>提出了一种高效的时空神经结构搜索方法,尝试自动构建适合城市不同时空预测任务的通用神经网络。由于使用深度神经网络产生的时空数据特征缺少语义性,因此Wang等<sup>[13]</sup>提出了一种新的基于粒子群优化的深度学习框架。可以看出,人群移动模式的研究往往与人的出行行为和人的轨迹相关,并且人类出行模式挖掘结果的优劣往往需要下游任务来进行验证和支撑。

## 3 基于人群移动模式先验的兴趣点推荐算法

### 3.1 人群移动模式发现

#### 3.1.1 时空图

受到图(Graph)这一广泛使用的数据结构启发,本文提出的时空图数据结构能够较准确地表示城市的时空属性。只要是能够使用图来结构化的数据,一般都可以适配时空图。我们公式化地把时空图定义为 $G_{seq} = \{G_0, G_1, G_2, \dots\}$ ,可以看出,时空图由多个时间片段聚合的空间图的序列组成。空间图定义为 $G_t(V_t, E_t, A_t)$ ,其中, $V_t$ 代表时间片内所有节点的集合, $E_t$ 代表时间片内边的集合, $A_t$ 代表时间片内节点的属性集合。本文采用时空图来结构化表示城市的人群移动模式和城市区域的功能属性。

#### 3.1.2 人群移动模式发现架构

人群移动模式发现框架使用下游任务的预测来对人群移动模式提取模块进行预训练,使得人群移动模式提取模块获得特定城市数据分布下的时空模式表示能力。同时,下游任务自身的预测结果可以辅助检验人群移动模式的表征效果。整体架构如图1所示。人群移动模式提取框架有3个主要部分:人群移动模式提取模块、基于多头注意力机制的编码解码模块、适配下游任务的上采样模块。3个模块组成统一的端到端模型,产生的中间隐层向量包含了人群移动

模式的时空上下文关系。




图1 人群移动模式发现架构

Fig. 1 Human mobility pattern discovery architecture

人群移动模式提取模块由一个共享权重的图卷积神经网络和一个前馈神经网络构成。给出图  $G(V, E)$ , 其中  $V$  和  $E$  分别是图  $G$  的点集和边集, 点集合大小  $n = |V|$ , 边集合大小  $m = |E|$ 。图  $G$  的邻接矩阵  $A \in \mathbb{R}^{n \times n}$ , 假设节点  $i, j$  之间存在相连的边, 则  $A_{ij} = 1$ , 否则  $A_{ij} = 0$ 。可得图  $G$  的度矩阵为  $D = \text{diag}(d_1, d_2, \dots, d_n)$ , 其中  $d_i$  是节点  $i$  在图  $G$  中的度, 可得图的拉普拉斯矩阵  $L = D - A$ 。对  $L$  进行特征值分解得  $L = UAU^T$ 。定义图信号  $x = [x_1, x_2, \dots, x_n]^T$ , 对任意图信号  $x$ , 有:

$$\begin{aligned} x^T L x &= x^T D x - x^T A x = \sum_i d_i x_i^2 - \sum_{(i,j) \in E} A_{ij} x_i x_j \\ &= \sum_{(i,j) \in E} (x_i - x_j)^2 \end{aligned} \quad (1)$$

至此, 可以推导图信号的傅里叶变换  $\hat{x} = U^T x$  相应的逆变换  $x = U \hat{x}$ 。可以得到图信号  $x$  与卷积核  $h$  在图  $G$  上的卷积形式, 如式(2)所示:

$$x * h = U \cdot \text{diag}(\hat{h}) \cdot U^T x \quad (2)$$

将上述的  $\text{diag}(\hat{h})$  替换为  $\sum_{k=0}^K \alpha_k \mathbf{A}^k$ , 其中  $\{\alpha_k\}_{k=0}^K$  是可学习的参数。至此, 得到了不需要特征分解且计算复杂度为  $O(n)$  的图卷积神经网络模型:

$$\begin{aligned} y &= \sigma(U \cdot (\sum_{k=0}^K \alpha_k \mathbf{A}^k) \cdot U^T x) \\ &= \sigma(\sum_{k=0}^K \alpha_k L^k x) \end{aligned} \quad (3)$$

在本模块中, 图信号指城市区域的功能属性分布向量, 邻接矩阵为城市区域间流量的时空图。设城市栅格化后的矩阵有  $r \times r$  个区域, 每个区域的属性向量有  $d_f$  个维度, 图卷积后的区域表征维度  $d_o$ 。在本模块中使用的图神经网络框架可以简化为:

$$Y = \sigma(\hat{D}^{-1} \hat{A} X W) \quad (4)$$

其中,  $X \in \mathbb{R}^{r^2 \times d_f}$  为城市功能属性矩阵,  $A \in \mathbb{R}^{r^2 \times r^2}$  为流量邻接矩阵,  $\hat{A} = A + I$ ,  $\hat{D}$  是  $\hat{A}$  对应的度矩阵,  $W \in \mathbb{R}^{d_f \times d_o}$  是待学习的网络参数。  $XW$  将节点的特征向量进行了线性变化,  $\hat{A} X W$  将变换的节点特征传播至邻居,  $\hat{D}^{-1} \hat{A} X W$  对节点接收到的特征进行归一化处理。

本文对每一个时间片所属的图卷积神经网络共享参数权重, 仅训练和维护一个图神经网络, 对于不同时间片的输入的反向传播梯度, 采用了加和平均处理。图神经网络学习到的人群移动模式提取策略适用于所有的时间片。

由于编码模块的输入数据为由单独的时间片下城市人群移动模式表征向量组成的序列而非整图表示, 因此本文使用前馈神经网络模块来实现 DGI<sup>[14]</sup> 中的 ReadOut 模块的功能, 以获取整图的隐向量表示。

基于多头注意力机制的编码解码模块参考了 Transformer 的编码解码结构<sup>[15]</sup>。使用人群移动模式的表征向量序列作为输入表征, 使用下游任务的目标数据表征作为输出表征。注意力机制如下:

$$\text{Attention}(Q, K, V) = \text{softmax}\left(\frac{QK^T}{\sqrt{d_k}}\right)V \quad (5)$$

设原始注意力模块复制  $h$  次, 即  $h$  头注意力。对多头注意力模块输入相同的数据得到  $h$  个单头注意力的结果。将多头结果拼接, 并经过线性层转换得到融合的特征输出。多头注意力的表达式如下:

$$\text{MultiHead}(Q, K, V) = \text{Concat}(\text{head}_1, \text{head}_2, \dots, \text{head}_h) W^o \quad (6)$$

本文使用人群移动模式提取模块代替 Transformer 原有的 Embedding 速查表, 由原始数据直接提取出表征, 输出模块由下游任务特征提取模块代替。上采样模块将预测的表征向量还原为与真实数据相同的结构。本文使用反卷积网络作为上采样模块, 由预测的表征向量  $\hat{emb} \in \mathbb{R}^d$  生成城市交通拥堵情况地图, 记  $S \in \mathbb{R}^{r \times r}$ 。计算得到  $r \times r$  个节点在时间段内的平均车速, 每一个时间片内的节点平均速度可以视为一张城市交通拥堵状态的地图快照, 记时间片  $t$  对应的城市交通拥堵状态快照为  $S_t \in \mathbb{R}^{r \times r}$ 。由此, 我们公式化地描述城市交通拥堵状态评估任务, 给定交通流时空图序列  $G_{\text{seq}} = \{G_1, G_2, \dots, G_t\}$ , 每个区域对应的功能分布  $A \in \mathbb{R}^{r^2 \times d_f}$ , 城市交通

拥堵状态序列  $S_{seq} = \{S_1, S_2, \dots, S_{t-1}\}$ , 来预测时间片  $t$  的城市交通拥堵状态  $S_t$ . 设由整体框架输出的结果为  $\hat{S}_t$ , 期望  $\hat{S}_t$  与  $S_t$  尽可能地接近, 则整体框架的优化目标是:

$$L = \|\hat{S}_t - S_t\| \quad (7)$$

为了适配数据特点, 本文的下游任务特征提取模块采用卷积神经网络, 上采样模块使用反卷积神经网络。

### 3.2 基于人群移动模式先验的 POI 推荐算法

在一个典型的基于地理位置的社交网络 (LBSNs) 中, POI 推荐系统由  $N$  个用户的集合  $U = \{u_1, u_2, \dots, u_N\}$ , 和  $M$  个地理位置集合  $L = \{l_1, l_2, \dots, l_M\}$  组成, 也称为兴趣点集合。用户  $u$  访问的兴趣点集合用  $L_u$  表示。每个地理位置  $l_i$  都用 (经度, 纬度) 进行地理编码。一般地, 将用户的签到信息 (check-in) 转化为用户-兴趣点签到频率矩阵  $C$ ,  $C$  的每个条目  $c_{ui}$  代表用户  $u$  在地点  $i$  签到的频率, 签到频率反映了用户对不同兴趣点的偏好。通常情况下, 用户只访问了小部分地点, 因此矩阵  $C$  稀疏。

我们保留人群移动模式提取器模型的权重, 将其单独拆分出来, 作为推荐算法的城市人群移动特征提取部分。HM-Rec 借鉴了 Wide&Deep 模型<sup>[16]</sup>, 模型的具体结构如图 2 所示。

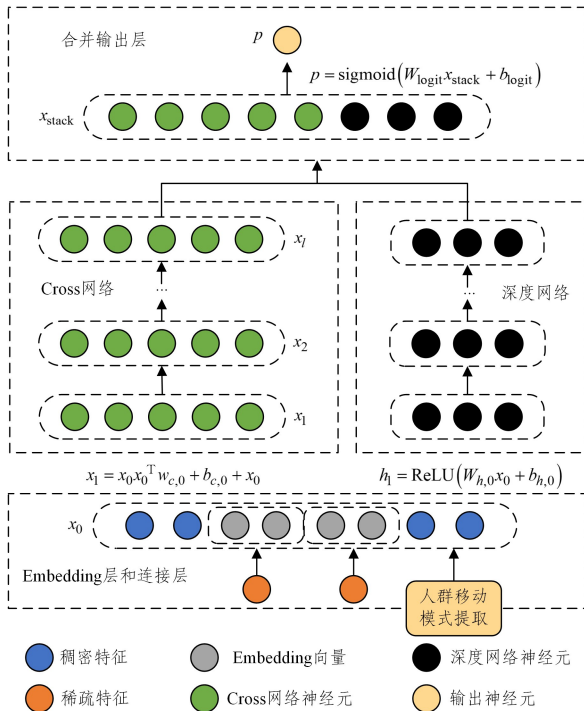


图 2 HMRec 算法的结构图

Fig. 2 HMRec algorithm structure

HMRec 模型利用多个交叉层 (Cross Layer) 进行特征交叉<sup>[17]</sup>. 若第  $l$  个交叉层的输出向量为  $x_l$ , 那么第  $l+1$  层的输出为:

$$x_{l+1} = x_0 x_l^T W_l + b_l + x_l \quad (8)$$

交叉层的二阶操作类似于 PNN 模型中的外积操作, 在此之上添加量外积操作的权重  $w_l$ , 以及输入  $x_l$  和偏置  $b_l$ . 可以看出, 交叉层的叠加对于参数量的累计影响还是比较缓慢的, 每一层仅增加了  $n$  维权重向量  $w_l$ ,  $n$  是输入向量的维度。

此外, 在每一层都保留了原始的输入向量  $x_l$ , 这样使得输入输出之间变化较小。多层交叉层组成的 Cross 网络在 Wide 的基础之上完成了特征的自动化交叉<sup>[18]</sup>. 整体的算法流程如算法 1 所示。

#### 算法 1 HMRec 算法

输入: 城市人群移动模式特征  $f_h$ , 兴趣点 ID, 用户 ID, 稠密特征  $f_d^1$ ,

$f_d^2, \dots, f_d^m$ , 离散特征  $f_s^1, f_s^2, \dots, f_s^n$

输出: 用户  $j$  在兴趣点  $i$  签到的预测分数  $p$

1.  $f_d^{m+k} = \text{Embedding}(f_s^k)$
2.  $f_d = \text{Cat}(f_d^1, f_d^2, \dots, f_d^{m+n}, f_h)$
3.  $h_0 = \text{ReLU}(W_0 f_d + b_0)$
4.  $h_{l+1} = \text{ReLU}(W_l h_l + b_l)$
5.  $x_{l+1} = x_0 x_l^T W_l + b_l + x_l$
6.  $x_c = \text{Cat}(h, x)$
7.  $p = \text{sigmoid}(W x_c + b)$

## 4 实验设计与结果分析

### 4.1 城市交通拥堵状态评估任务

本文中, 为了保证时空模式提取框架能够学习到城市时空特征, 同时能够评估这个特征的学习效果, 设计了城市拥堵情况预测作为提取框架的下游任务。这也是评估编码解码框架中间隐层向量表征效果的通用做法。

本文使用了纽约市 2012 年 5 月和 6 月的 Yellow 出租车数据以及 POI 数据来进行对比实验。本文选取了纽约市经度  $-74.0108 \sim -73.9600$ , 纬度  $40.7333 \sim 40.7700$  的空间范围进行实验。在实验选定的时间空间范围内, 出租车轨迹数据量约为 900 万条, 兴趣点数据量为 1 612, 兴趣点种类有 18 种。

本小节设计了相关消融实验来验证 HMPE 算法的有效性。本文采用了类似无监督学习验证的方式, 以模型在下游任务中的表现结果来评价模型对目标隐向量的学习效果。由于本文提出的 HMPE 算法框架主要需要验证的是人群移动模式提取模块和时序特征提取模块这两个部分, 因此消融实验的对照部分设置为各部分的具有代表性的算法。

对于人群移动模式提取模块, 在框架中有两个部分: 1) 带属性的图表征算法; 2) ReadOut. 将 Node2Vec 算法<sup>[19]</sup> (可扩展的网络特征学习) 作为无属性的、纯结构化表征一类算法的代表。使用 ANRL<sup>[20]</sup> (基于深度神经网络的属性网络表示学习) 来比较带属性的图卷积算法与带属性的随机游走算法的差异。在 ReadOut 部分, 用卷积神经网络来验证城市范围内全局视野 (MLP) 和局部视野 (CNN<sup>[21]</sup>) 在城市时空场景中的差异。对于时序特征提取模块, 将长短期记忆网络中的 GRU<sup>[22]</sup> 作为代表算法, 比较了城市时空场景下只学习单一长短期记忆向量和使用注意力机制区别对待各时段特征这两种方式的不同。本文使用 Mean Absolute Percentage Error (MAPE) 和 Rooted Mean Square Error (RMSE) 作为框架效果的评价指标。

从表 1 可以看出, 本文提出的 HMPE 框架在指标 RMSE 和 MAPE 上均优于其他的基线模型, 这表明了 HMPE 框架的表现是符合预期的, 有效地提取了城市中的人群移动模式。

与使用 Node2Vec 的结构相比, HMPE 更好地利用了城市功能区的特征。与使用 CNN 作为 ReadOut 的结构相比, HMPE 使用 MLP 来达到全局的感受野, 替代了局部的感受野, 取得了更好的结果。由于采用 Node2Vec 和 ANRL 两个结构属于分阶段的模型, HMPE 的端到端训练得到的结果明显占优。注意到 GCN-MLP-GRU 的表现也相当不错, 这一定程度上说明了城市时空特征的良好表示对下游任务有很大的帮助。

表 1 城市交通拥堵预测结果

Table 1 Results of urban traffic congestion prediction

评价 指标	GCN-CNN- Trans	N2V-MLP- Trans	ANRL-MLP- Trans	GCN-MLP- GRU	HMPE
RMSE/%	16.93	15.17	18.07	14.73	14.66
MAPE/%	34.70	28.39	44.71	26.06	25.65

### 4.2 基于人群移动模式先验的 POI 推荐

本文选择了纽约市 2012 年 5 月和 6 月的出行数据和签到数据进行实验。用户签到数据来自于 Kaggle 上公开的 Foursquare 数据集, 含有用户签到数据 227428 条。

对比实验基线模型包括深度因子分解机(DeepFM)<sup>[23]</sup>、表征多层感知机(EmbeddingMLP)、基于深度学习的协同过滤模型(NeuralCF)<sup>[24]</sup>、Wide&Deep 模型和双塔模型<sup>[25]</sup>。在兴趣点推荐模型的对比实验中, 本文采用准确率(ACC)和两种 AUC 值(ROC 和 PR)作为实验的指标。

实验结果如表 2 所列。从表中可以明显看出, 本文提出的 HMRec 算法在准确率和受试者工作特征曲线(ROC)两个指标上取得了超过所有基线模型的结果, 这证明了人群移动模式这种城市时空属性对兴趣点推荐起到了一定的作用。值得注意的是, HMRec 在精确率-召回率曲线(PR)上的表现略差于 DeepFM 算法, 这是因为 DeepFM 模型未加入人群移动模式先验信息, 进而对正样本的拟合程度较高。在所有的基线模型中, 双塔模型的表现较差, 这可能是因为样本较为稀疏的情况下, 对用户和兴趣点都使用深度网络很容易产生过拟合的结果, 导致在测试集上体现的泛化能力较差。相比之下, NeuralCF 由于模型简单, 反而取得了比双塔模型更好的结果。

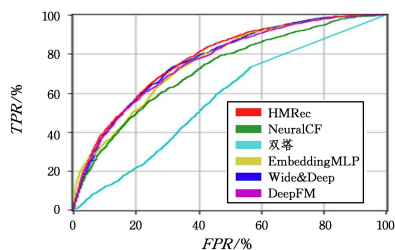
表 2 兴趣点推荐模型对比实验结果

Table 2 Comparison of experimental results of interest point recommendation model

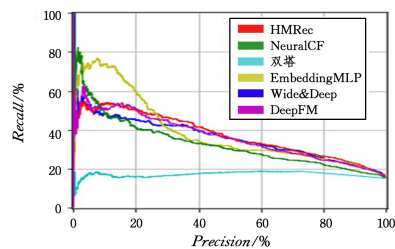
模型算法	准确率(ACC)	AUC(ROC)	AUC(PR)
HMRec	0.8103	0.7331	0.3558
wide&deep	0.7978	0.7271	0.3499
DeepFM	0.8095	0.7253	0.3610
NeuralCF	0.7810	0.7078	0.3097
双塔	0.6922	0.6097	0.1781
EmbeddingMLP	0.7966	0.7103	0.3302

通过可视化 ROC 和 PR 曲线(见图 3)可以看出, 在 ROC 曲线方面 HMRec, Wide&Deep, DeepFM 的表现比较接近。EmbeddingMLP 的曲线在中间的部分有较陡峭的变化, 说明其在预测分数为 0.5 左右时表现不佳。从 PR 曲线中可以看出, HMRec, Wide&Deep, DeepFM 的表现依然是比较稳定的, 其中 Wide&Deep 在召回率升高后不如 HMRec 和 Deep-

FM。NeuralCF 的表现很不稳定, 曲线有很大的起伏。可以看出, 红色线代表的 HMRec 均取得了最优的结果。



(a) ROC



(b) PR

图 3 推荐算法实验结果的 ROC 和 PR 曲线可视化(电子版为彩图)


Fig. 3 ROC and PR curve visualization of experimental results of recommendation algorithms

**结束语** 目前现存的兴趣点推荐算法研究工作将研究重点放在了用户与兴趣点交互历史的挖掘和用户社交关系的研究之上, 忽略了兴趣点推荐所处的城市场景和客观存在的人群移动模式先验规律。为此, 本文提出了人群移动模式提取框架 HMPE, 利用图神经网络和注意力机制, 设计了端到端的预训练流程。本文提出了 HMRec 兴趣点推荐算法, 将人群移动模式先验知识融入兴趣点推荐中, 通过实验验证了人群移动模式在兴趣点推荐中的有效性。后续工作需解决签到数据的稀疏性问题, 此外, 在不同的场景中下游任务的设计也需要进一步研究。

### 参考文献

- [1] ZHANG J Q, SHI W B, XIU C L. Application of POI data in Chinese urban research[J]. Geographical Sciences, 2021, 41(1): 140-148.
- [2] BERJANI B, STRUFE T. A recommendation system for spots in location-based online social networks[C]//Proceedings of the 4th Workshop on Social Network Systems, 2011:1-6.
- [3] YU Y, CHEN X. A survey of point-of-interest recommendation in location-based social networks[C]//Workshops at the Twenty-ninth AAAI Conference on Artificial Intelligence, 2015.
- [4] SI Y, ZHANG F, LIU W. An adaptive point-of-interest recommendation method for location-based social networks based on user activity and spatial features[J]. Knowledge-Based Systems, 2019, 163:267-282.
- [5] LIU W, WANG Z J, YAO B, et al. Geo-ALM: POI Recommendation by Fusing Geographical Information and Adversarial Learning Mechanism[C]//IJCAI. 2019, 7:1807-1813.
- [6] LU L, ZHU F X, GAO R, et al. A joint recommendation algorithm for points of interest based on user-content topic model

- [J]. Computer Engineering and Applications, 2018, 54(4): 154-159.
- [7] ZHANG Z, LIU Y, ZHANG Z, et al. Fused matrix factorization with multi-tag, social and geographical influences for POI recommendation[J]. World Wide Web, 2019, 22(3): 1135-1150.
- [8] ZHANG S, CHENG H. Exploiting context graph attention for poi recommendation in location-based social networks[C]// International Conference on Database Systems for Advanced Applications. Cham: Springer, 2018: 83-99.
- [9] ZHANG H, ZHENG Y, YU Y. Detecting urban anomalies using multiple spatio-temporal data sources[J]. Proceedings of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2018, 2(1): 1-18.
- [10] LIU X, WANG M, ZHA Z J, et al. Cross-modality feature learning via convolutional autoencoder[J]. ACM Transactions on Multimedia Computing, Communications, and Applications (TOMM), 2019, 15(1s): 1-20.
- [11] DAS S, DUTTA S. A Fusion Approach for Collaborative Filtering[C]// Proceedings of the 2019 3rd International Conference on Innovation in Artificial Intelligence. 2019: 263-269.
- [12] LI T, ZHANG J, BAO K, et al. Autost: Efficient neural architecture search for spatio-temporal prediction[C]// Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. 2020: 794-802.
- [13] WANG D, LIU K, MOHAISEN D, et al. Towards Semantically-Rich Spatial Network Representation Learning via Automated Feature Topic Pairing [J]. Frontiers in big Data, 2021, 4: 762899.
- [14] VELICKOVIC P, FEDUS W, HAMILTON W L, et al. Deep Graph Infomax[J]. ICLR(Poster), 2019, 2(3): 4.
- [15] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need[J/OL]. Advances in Neural Information Processing Systems, 2017, 30. [https://proceedings.neurips.cc/paper\\_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2017/file/3f5ee243547dee91fbd053c1c4a845aa-Paper.pdf).
- [16] CHENG H T, KOC L, HARMSSEN J, et al. Wide & deep learning for recommender systems[C]// Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. 2016: 7-10.
- [17] WANG R, FU B, FU G, et al. Deep & cross network for ad click predictions[M]// Proceedings of the ADKDD'17. 2017: 1-7.
- [18] KONG X, DUAN G, HOU M, et al. Deep Reinforcement Learning based Energy Efficient Edge Computing for Internet of Vehicles[J]. IEEE Transactions on Industrial Informatics, 2022, 18(9): 6308-6316.
- [19] GROVER A, LESKOVEC J. Node2vec: Scalable feature learning for networks[C]// Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. 2016: 855-864.
- [20] ZHANG Z, YANG H, BU J, et al. ANRL: Attributed Network Representation Learning via Deep Neural Networks[C]// IJ-CAI. 2018, 18: 3155-3161.
- [21] KRIZHEVSKY A, SUTSKEVER I, HINTON G E. Imagenet classification with deep convolutional neural networks[J/OL]. Advances in neural information processing systems, 2012, 25. [https://proceedings.neurips.cc/paper\\_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf](https://proceedings.neurips.cc/paper_files/paper/2012/file/c399862d3b9d6b76c8436e924a68c45b-Paper.pdf).
- [22] CHO K, VAN MERRIËNBOER B, GULCEHRE C, et al. Learning phrase representations using RNN encoder-decoder for statistical machine translation[J]. arXiv:1406.1078, 2014.
- [23] GUO H, TANG R, YE Y, et al. DeepFM: a factorization-machine based neural network for CTR prediction[J]. arXiv:1703.04247, 2017.
- [24] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering [C]// Proceedings of the 26th International Conference on World Wide Web. 2017: 173-182.
- [25] HUANG P S, HE X, GAO J, et al. Learning deep structured semantic models for web search using clickthrough data[C]// Proceedings of the 22nd ACM International Conference on Information & Knowledge Management. 2013: 2333-2338.



**YI Qihua**, born in 2000, postgraduate, is a member of China Computer Federation. Her main research interests include urban data science, social computing and so on.



**KONG Xiangjie**, born in 1981, Ph. D., professor, Ph.D supervisor, is a distinguished member of China Computer Federation. His main research interests include network science, mobile computing and computational social science.

(责任编辑:喻黎)