



天津科技大学学报

Journal of Tianjin University of Science & Technology

ISSN 1672-6510, CN 12-1355/N

《天津科技大学学报》网络首发论文

题目: 融合时空注意力关系网络的兴趣点推荐
作者: 张贤坤, 王金涛
DOI: 10.13364/j.issn.1672-6510.20250154
收稿日期: 2025-10-15
网络首发日期: 2026-09-03
引用格式: 张贤坤, 王金涛. 融合时空注意力关系网络的兴趣点推荐[J/OL]. 天津科技大学学报. <https://doi.org/10.13364/j.issn.1672-6510.20250154>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。



融合时空注意力关系网络的兴趣点推荐

张贤坤, 王金涛

(天津科技大学人工智能学院, 天津 300457)

摘要: 随着基于位置的社交网络(LBSN)日益流行, 个性化的兴趣点推荐已然成为一项关键任务。为减轻兴趣点推荐里的空间稀疏性问题, 本研究设计了一种融合时空注意力关系网络的兴趣点推荐模型 ISTARN (integrated spatio-temporal attention relation network, ISTARN)。首先, 构建签到序列的时空关系矩阵, 借助多模态嵌入学习用户、位置、时间以及时空效应的密集表示; 接着, 运用时间间隔自注意力网络和时空融合注意力网络, 通过引入高斯核函数显式建模时间相关性的平滑衰减, 使模型能够有效容忍用户行为的时间偏移, 从而精准捕获非连续访问间的潜在周期性关联, 减轻签到数据稀疏所造成的困难; 最后, 在 Foursquare 数据集上进行验证, 实验结果显示, 本文模型优于其他先进基准模型, 可以有效提升推荐性能。

关键词: 基于位置的社交网络; 兴趣点推荐; 自注意力机制; 时间间隔

中图分类号: TP391 **文献标志码:** A **文章编号:** 1672-6510 (0000)00-0000-00

Integrated Spatio-Temporal Attentive Relation Network for POI

Recommendation

ZHANG Xiankun, WANG Jintao

(College of Artificial Intelligence, Tianjin University of Science & Technology, Tianjin 300457, China)

Abstract: With the increasing popularity of location-based social networks (LBSN), personalized point-of-interest (POI) recommendation has become a crucial task. To alleviate the spatial sparsity problem in POI recommendation, this paper proposes an integrated spatio-temporal attention relation network (ISTARN) model. First, a spatio-temporal relation matrix of check-in sequences is constructed, and multi-modal embedding is leveraged to learn dense representations of users, locations, time, and spatio-temporal effects. Next, the model employs a temporal interval self-attention network and a spatio-temporal fusion attention network. By introducing a Gaussian kernel function to explicitly model the smooth decay of temporal correlations, the model effectively tolerates temporal drifts in user behaviors, thereby accurately capturing potential periodic correlations between non-consecutive visits and mitigating the challenges caused by sparse check-in data. Finally, experiments conducted on Foursquare datasets demonstrate that the proposed model outperforms other state-of-the-art baselines, effectively improving recommendation performance.

Key words: location-based social networks(LBSN); Points of Interest; self-attention; spatio-temporal interval

随着移动互联网技术的快速发展, 基于位置的社交网络(location-based social networks, LBSNs)^[1]已演

变成用户开展位置签到以及兴趣点探索的关键平台, 兴趣点(point-of-interest, POI)推荐系统也受到学术界

收稿日期: 2025-10-15; 修回日期: 2026-03-04

基金项目: 国家自然科学基金项目(62377036)

作者简介: 张贤坤(1970—), 男, 安徽人, 教授, zhxkun@tust.edu.cn

和工业界的普遍关注。尽管 LBSN 可为用户提供丰富的兴趣点数据,但从海量信息里挑选出契合个人喜好的兴趣点辅助决策,依旧面临极大挑战^[2]。这个过程耗费时间且效率不高,如何有效挖掘用户潜在感兴趣的地理位置成为研究热点。

与传统的商品推荐或视频推荐系统不同, LBSN 中用户的签到数据记录了用户在真实物理空间中的活动轨迹。由于该类行为具有较强的时空约束性,用户签到数据集通常呈现出比常规交互数据更为稀疏的特征分布。针对数据稀疏性问题,现有研究大多采用融合时空上下文信息的办法进行优化。Liu 等^[3]提出在循环神经网络(RNN)框架中加入时空转换矩阵,用来捕捉用户签到行为中的时空动态特征。Huang 等^[4]开发的 ATST-LSTM 模型借助向量嵌入技术整合时空特征,并且运用注意力机制提高的长短期记忆网络实现多维度联合建模。Zhao 等^[5]提出的 STGN 模型则创新性地在长短期记忆网络(LSTM)架构里设计了双组时空门控单元,可以对近期签到行为影响权重的动态进行调节。然而,上述基于 RNN 的方法主要依赖序列的递归迭代,不仅存在梯度消失问题,而且难以捕捉长距离的非连续依赖,在面对高度稀疏的签到数据时,其推荐性能往往受限。

为了克服 RNN 的局限性,近年来的研究开始转向图神经网络(GNN)和自注意力机制(self-attention)。Wang 等^[6]通过构建时空邻域图并利用门控机制捕捉多级依赖,Feng 等^[7]则利用复数空间的旋转机制建模时间周期性。

虽然这些方法在性能上取得了突破,但也存在一些局限性。一方面,在处理连续的时空信息嵌入时,现有的方法大多数采用传统的等距离散化策略,忽略了 LBSN 数据中普遍存在的长尾分布特征,导致在数据密集区由于分辨率不足而丢失了细粒度信息,而在稀疏区又由于区间过宽加剧了特征的稀疏性挑战;另一方面,现有的注意力机制大多把时间视为离散的序列步长,采用硬性的匹配规则,忽略了签到行为中不规则的时间间隔和时间偏移现象,很难精准捕捉到用户在连续时间域上的真实偏好波动。

针对上述问题,本文从用户签到行为中连续时空依赖关系的建模机制出发,提出一种融合时空注意力关系的兴趣点推荐模型 ISTARN (integrated spatio-temporal attention relation network, ISTARN),并在两个真实世界数据集上进行实验验证。主要工作

如下:第一,针对签到数据中连续时间间隔与空间距离分布高度不均匀的问题,提出一种基于数据密度的自适应分位数划分策略,并结合线性插值方法构建时空关系矩阵,实现对用户、位置以及连续时空特征的多粒度密集表示,有效缓解签到数据稀疏性对模型学习的影响;第二,在自注意力框架下设计一种基于高斯核平滑衰减的时间间隔自注意力机制,对签到点之间的连续时间相关性进行显式建模,使模型具备容忍用户行为时间偏移的能力,从而能够在非连续访问行为中精准捕获潜在的周期性关联。

1 相关工作

1.1 传统的兴趣点推荐

早期关于兴趣点推荐的研究,主要是依据兴趣点流行度指标^[8]为用户生成推荐列表,这种方法可以给用户提供热门地点参考,不过存在数据分布不均衡以及个性化不足的问题。为了克服这些缺点,研究者陆续把协同过滤^[9-10]以及矩阵分解^[11]等传统推荐算法引入到这个领域。然而,这些方法只是把用户历史签到数据当作无序的集合,没有有效捕捉签到行为之间的时序关联。用户后续的签到行为大多会受到前期访问记录的影响,呈现较为突出的序列依赖性。针对这一特性,Rendle 等^[12]创造性地将矩阵分解与马尔可夫链模型融合,借助矩阵分解构建用户长期偏好特征,借助马尔可夫链模型学习兴趣点之间的转移概率矩阵,以此实现对用户序列行为的有效建模。

1.2 基于深度学习的兴趣点推荐

近年来,随着大数据技术的不断发展,机器学习模型不断优化,深度学习在推荐系统领域应用有了新进展,多种基于循环神经网络和深度神经网络的创新办法被提出。Lai 等^[13]的 AT-LSTM 模型通过 LSTM 捕捉用户签到序列的时间特性,并引入注意力机制对短期偏好进行加权建模,从而融合用户的短期和长期兴趣特征。Wang 等^[14]的 DSDRec 模型通过提示工程和预训练语言模型提取轨迹序列的深度语义特征,引入时空区域编码以捕捉全局时空关系,改进扩散模型增强轨迹表示的抽象交互信息。Qin 等^[15]将状态空间模型引入 POI 推荐,利用 Mamba 架构的线性复杂度优势,克服了 Transformer 的计算瓶颈,在处理超长签到序列和多粒度地理交互时实现了效率与精度的双重提升。Xia 等^[16]引入时空信息作为自注意力结构

的偏置, 捕捉签到间的相对关系。沈学利等^[17]提出的方法创新性结合自注意力机制与长短期用户偏好做序列推荐, 不过其模型架构没充分考虑时间间隔和空间间隔等关键特征信息。

2 问题描述及定义

2.1 问题描述

在 POI 推荐中, 对于每个用户 $u \in U$, 给定目标用户的历史签到序列 $tra(u_i) = \{r_1, r_2, \dots, r_R\}$, POI 预测目标是给目标用户推荐下一步可能会访问的 POI 列表。

2.2 问题定义

$U = \{u_1, u_2, \dots, u_U\}$ 和 $P = \{p_1, p_2, \dots, p_M\}$ 分别表示用户集合和位置集合, 其中 $p_i = (lon_i, lat_i)$ 为一组 GPS 经纬度坐标, lon_i 表示经度, lat_i 表示纬度, $T = \{t_1, t_2, \dots, t_T\}$ 和 $L = \{l_1, l_2, \dots, l_L\}$ 分别表示时间集合和兴趣点集合。用户每次的签到记录 r_k 用四元组 (u, t, p, l) 表示, 代表了用户 u 在时间 t 时刻访问了位于坐标 p 处的兴趣点 l 。用户的轨迹集合 $tra(u_i) = \{r_1, r_2, \dots, r_R\}$ 即用户的签到记录, 其中 R 为用户 u_i 的轨迹序列长度, 在这里设定最大轨迹长度为 n , 构建标准化签到序列 $C(u_i) = \{r_1, r_2, \dots, r_n\}$, 对不同用户的不同轨迹长度进行统一处理: 当 $R < n$ 时, 进行零值填充并采用掩码机制处理; 当 $R > n$ 时, 截取最近的 n 条记录。签到数据所蕴含的时空信息对于 POI 推荐有着重要意义, 因此借助构建时间间隔矩阵 ΔT 和地理距离矩阵 ΔD , 对用户轨

迹中的时空依赖关系进行建模, 为

$$\Delta T = \begin{bmatrix} \Delta t_{11} & \Delta t_{12} & \dots & \Delta t_{1n} \\ \Delta t_{21} & \Delta t_{22} & \dots & \Delta t_{2n} \\ \vdots & \vdots & \dots & \vdots \\ \Delta t_{n1} & \Delta t_{n2} & \dots & \Delta t_{nn} \end{bmatrix}, \Delta D = \begin{bmatrix} \Delta d_{11} & \Delta d_{12} & \dots & \Delta d_{1n} \\ \Delta d_{21} & \Delta d_{22} & \dots & \Delta d_{2n} \\ \vdots & \vdots & \dots & \vdots \\ \Delta d_{n1} & \Delta d_{n2} & \dots & \Delta d_{nn} \end{bmatrix} \quad (1)$$

在这里把用户 u 的第 i 次签到时间与第 j 次签到时间的间隔记为 $\Delta t_{ij} = |t_i - t_j|$, 并且运用半正矢函数 Haversine 计算两次签到兴趣点之间的地理距离, 其表达式为 $\Delta d_{ij} = \text{Haversine}(p_i - p_j)$, 此函数可以精确度量地球表面任意两点间的球面距离。

3 ISTARN 模型

本文构建一种用于 POI 推荐的融合时空注意力关系网络(ISTARN)。首先, 针对数据分布的不均匀性, 设计了基于数据密度的自适应分位数划分策略, 结合线性插值技术构建时空关系矩阵, 实现了对用户、位置及连续时空特征的多粒度密集表示, 从而有效缓解了数据稀疏性问题; 其次, 针对时间的不规则性, 在时间间隔自注意力网络中引入高斯核函数显式建模时间相关性的平滑衰减, 赋予模型容忍时间偏移的能力, 从而在非连续访问间精准捕获潜在的周期性关联。网络主要由嵌入层、时间间隔自注意力层以及时空融合注意力加权预测层 3 个部分构成, 模型的整体框架如图 1 所示。




图 1 ISTARN 模型框架图

Fig. 1 Architecture of the ISTARN model

3.1 嵌入层

嵌入层由用户轨迹嵌入和时空信息嵌入这两部分组成。

3.1.1 用户轨迹嵌入层

在用户轨迹嵌入层里, 针对用户签到记录当中的多维特征进行编码, 借助非线性变换把离散标量映射至 d 维密集向量空间, 分别将其记作用户嵌入 e^u 、位置嵌入 e^p 、时间嵌入 e^t 以及兴趣点嵌入 e^l 。同时将 1

周的时间按小时 (24×7) 划分为 168 维, 表示 1 周或 1 天中的准确时间, 用来挖掘用户行为的周期性并减少计算量。

因此, 用户嵌入 e^u 的输入维度为 U , 位置嵌入 e^p 的输入维度为 P , 时间嵌入 e^t 和兴趣点嵌入 e^l 的输入维度则分别为 168 和 L 。用户的历史签到 r 嵌入 $e^r = e^u + e^p + e^t + e^l \in R^d$, 即用户嵌入、位置嵌入、时间嵌入以及兴趣点嵌入的加和。用户历史签到序列 $C(u_i) = \{r_1, r_2, \dots, r_n\}$ 嵌入可以表示为 $E^u = \{e^{r_1}, e^{r_2}, \dots, e^{r_n}\} \in R^{n \times d}$ 。

3.1.2 时空信息嵌入层

在时空信息嵌入层当中, 连续间隔表示会产生计算复杂度以及数据稀疏性方面的问题。为了解决这些问题, 采用基于线性插值的离散化处理方法。传统的等距划分策略^[18]在处理非均匀分布数据时往往陷入分辨率与稀疏性的权衡困境。针对这一局限, 本文设计自适应分位数划分策略。该策略不再使用固定的区间宽度, 而是依据训练数据的真实分布特征, 将连续的时空间隔动态划分为 K 个子区间, 核心原则是确保每个子区间内包含近似相等的样本数量。这种“等频”划分机制实现了对数据密度的自适应感知: 在数据密集区域自动收窄区间, 以提供更精细的粒度表示, 而在数据稀疏区域拓宽区间, 以提高模型的泛化能力。边界点依靠计算训练数据的分位数确定: 对于包含 n 个样本的时空间隔集合 $S = \{x_1, x_2, \dots, x_n\}$, 先将其按升序排列得到 $\text{sorted}(S)$, 按照式 (2) 计算 $K+1$ 个边界点。

$$b_k = \text{sorted}(S) \left\lceil \left\lfloor \frac{k}{K} \cdot n \right\rfloor \right\rceil, k=0, 1, 2, \dots, K \quad (2)$$

其中: b_0 和 b_K 分别表示最小和最大边界值。这种方式把连续的时空间隔划分成多个自适应的子区间, 只需要针对各子区间的边界点学习嵌入向量表示, 对于任意具体的时空间隔, 其嵌入向量可借助边界向量的线性组合计算得出, 为

$$e^\Delta = \frac{e_{k+1} \cdot (b_{k+1} - \Delta) + e_k \cdot (\Delta - b_k)}{b_{k+1} - b_k} \quad (3)$$

时空关系嵌入层的输入数据是由签到到序列的时空间隔矩阵 ΔT 以及空间距离矩阵 ΔD 共同组成, 借助式 (3), 针对这两个矩阵里的每一个元素展开特征转换操作, 最终生成维度为 $n \times n \times d$ 的时空关系嵌入表示 $E(\Delta T)$ 与 $E(\Delta D)$ 。其中, e^Δ 代表着时间间隔 $e^{\Delta T_{ij}}$ 和空间距离 $e^{\Delta D_{ij}}$ 的嵌入向量, $b_k \leq \Delta \leq b_{k+1}$, b_k 与 b_{k+1} 界

定子区间的边界范围, 而 e_{k+1} 和 e_k 分别对应着上边界和下边界的嵌入表示。

3.2 时间间隔自注意力层

在时间间隔自注意力层里, 本文以自注意力机制框架为基础, 提出一种基于高斯核平滑衰减的时间间隔建模机制, 精准捕捉用户历史轨迹中签到点之间复杂的时空依赖特征。该网络的核心在于突破了传统离散时间槽的限制, 通过聚合相关签到信息动态更新节点表征, 从而构建有时空关联特性的综合权重矩阵^[19]。

$$W = W^P \odot W^T \odot W^D \quad (4)$$

在构建权重矩阵时, 时间周期权重矩阵 W^P 、时间间隔权重矩阵 W^T 以及空间距离权重矩阵 W^D 是三个关键参数矩阵, 具体参数计算为

$$w_{ij}^P = \exp\left(-\frac{(\Delta T_{ij} - [\Delta T_{ij}])^2}{2\tau^2}\right) \quad (5)$$

其中: $w_{ij}^P \in (0, 1]$ 表示第 i 次签到和第 j 次签到的时间周期性权重, 参数 τ 控制着对时间偏移的容忍度。 τ 将离散的时间点转化为一个连续的概率分布窗口: 当 τ 取值适中时, 高斯核能够对非严格对齐的时间点 (即存在日常时间波动) 赋予平滑衰减的高权重, 从而使模型具备容忍时间偏移的能力, 能够使挖掘非连续访问间的周期性关联的鲁棒性更强。

$$w_{ij}^T = e^{-\alpha \Delta T_{ij}} \quad (6)$$

$$w_{ij}^D = e^{-\beta \Delta D_{ij}} \quad (7)$$

其中: w_{ij}^T 表示第 i 次签到和第 j 次签到的时间间隔权重, w_{ij}^D 表示第 i 次签到和第 j 次签到的地理距离权重。如果两次签到之间具有更短的时间间隔或者更小的地理距离, 则表明这两次签到具有更强的关联性。衰减系数 α 表示时间衰减率, β 表示空间衰减率, 二者用来控制 w_{ij}^P 和 w_{ij}^D 随时间和距离增长的衰减速度。

通过由式 (4) 得到的时空综合权重矩阵 W 与点积注意力生成注意力权重矩阵, 计算矩阵中向量的加权和, 从而更新用户历史轨迹表示, 为

$$S = \text{softmax}\left(\frac{QK^T \odot W}{\sqrt{d}}\right)V \quad (8)$$

其中: $Q = E^u W_Q, K = E^u W_K, V = E^u W_V, W_Q, W_K, W_V \in R^{d \times d}$ 是投影矩阵, $\odot$ 表示 Hadamard 乘积运算。

3.3 时空融合注意力加权预测层

对于候选兴趣点而言, 历史签到和目标兴趣点的关联程度是不一样的, 关联性更强的签到行为对用户访问决策的影响更大。因此, 使用时空融合注意力网

络, 依靠动态评估候选兴趣点和历史签到的相关性, 实现用户轨迹签到的自适应聚合, 构建更具判别力的用户偏好表示, 为

$$w_{ij}=w_{ij}^P*w_{ij}^T*w_{ij}^D \quad (9)$$

$$a_{ij}=\exp(e^j \cdot S_i \cdot w_{ij}) \quad (10)$$

$$P_{u,j}=\sum_{i=1}^n \frac{a_{ij}}{\sum_{k=1}^n a_{kj}} S_i \quad (11)$$

其中: $P_{u,j}$ 为用户 u 对候选兴趣点 j 的聚合偏好表示, e^j 为候选兴趣点 j 的嵌入向量, S_i 为用户轨迹中第 i 次签到更新后的向量表示。在时空特征权重方面, w_{ij}^P 以及 w_{ij}^T 分别表示预测时间 t_j 与第 i 次访问的时间 t_i 的时间周期权重和时间间隔权重, 具体的计算过程为式(5)和(6)。 w_{ij}^D 则表示候选兴趣点 j 与第 i 次访问的兴趣点 i 之间的空间距离权重, 由式(7)计算得到。

最后, 计算用户 u 对于候选兴趣点 j 的交互得分 $Score_{u,j}$, 为

$$Score_{u,j}=P_{u,j} \cdot e^j \quad (12)$$

3.4 损失函数

二元交叉熵损失函数是模型训练时被广泛采用的基础方法, 但是这种方法存在着一定的局限性, 对于每一个正样本而言, 只是随机挑选一个用户未曾访问过的负样本进行计算。此处理方式并没有将兴趣点集合里大量潜在负样本所包含的信息价值充分利用起来。本文引入一种经过改进的负采样机制, 在损失函数计算的过程中, 针对每一个正样本从用户未访问的兴趣点集合里随机抽取 K 个负样本参与训练过程, 损失函数计算公式为

$$L=-\sum_{s \in S} \left(\log \sigma(Score_{u,l}) + \sum_{k=1}^K (\log(1-\sigma(Score_{u,n_k}))) \right) \quad (13)$$

其中: s 为用户签到数据集的训练集, l 为有待预测的目标兴趣点, n_k 为从用户未曾访问过的兴趣点集合里随机抽取出来作为负样本。运用 Adam 优化算法^[20]开展模型参数学习, 此算法可依据损失函数动态调整学习率, 有效提升模型训练的收敛效率。

4 实验

4.1 数据集

选取 Foursquare 数据集的 NYC 与 TKY 真实签到数据集作为实验数据, 它们分别记录了用户于纽约市

以及东京市的长期签到行为(表 1)。在实验中将数据集分为训练集和测试集, 用前 80% 数据作为训练集, 用后 20% 数据作为测试集, 剔除交互数量少于 10 次的位置和用户。

表 1 数据集统计信息

Tab. 1 Dataset statistical information

项目	NYC	TKY
用户数量	1064	2245
POI 数量	5136	7872
签到数量	147939	447571

4.2 评价指标

选用召回率(Recall@K)和归一化折损累积增益(NDCG@K)作为模型推荐性能的评估指标。

Recall@K 指的是推荐系统所生成的前 K 项推荐列表 $R_k(u)$ 里和用户真实偏好集合 $T(u)$ 的交集所占的比例, 与推荐效果呈正相关, 计算式为

$$Recall@k=\frac{|R_k(u) \cap T(u)|}{T(u)} \quad (14)$$

NDCG@K 则考虑推荐结果的相关性和排序位置两个因素, 对排名靠前的命中项赋予更高的权重, 排名越靠前的项对用户的影响越大, 计算式为

$$DCG@K=\sum_{i=1}^K \frac{r_i}{\log_2(i+1)} \quad (15)$$

$$NDCG@K=\frac{DCG@K}{IDCG@K} \quad (16)$$

其中: r_i 表示用户对第 i 个位置的偏好, $IDCG$ 表示理想状态下的 DCG 。

4.3 参数设置

运用 Adam 优化算法训练模型, 关键参数设置: 学习率为 0.003, 丢弃率为 0.5, 嵌入维度为 60, 用户历史签到到序列长度参数 (n) 为 20, 时间规律性系数 τ 为 0.2, 时间衰减因子 α 为 0.1, 空间衰减因子 β 为 1000, 负采样数量为 10。

4.4 对比实验

为验证 ISTARN 模型的有效性, 选择多种主流推荐算法作为对比进行实验。

STRNN^[3]: 将连续访问的时空特征融入循环神经网络架构, 凭借捕捉时间序列数据中的时空关联性, 一定程度提升序列建模性能。

STGN^[5]: 在 LSTM 架构中整合时间间隔门控单

元与距离门控机制,借助双重门控结构实现对时序特征的动态调控。

LSTPM^[21]: 集成长期和短期偏好建模机制,采用双通道特征融合策略,提高推荐系统预测准确性。

DeepMove^[22]: 融合循环神经网络和注意力机制,依靠双模块协同作用,捕捉移动轨迹的周期性特征。

GeoSAN^[23]: 运用分层网格化方式处理 GPS 位置数据,实现空间离散化,采用自注意力层进行轨迹匹配。

DyHGN^[24]: 构建分时段的动态异构图序列,捕捉用户意图随时间和场景的动态演变,结合全局图结构与局部序列模式共同进行推荐。

MVHGAT^[25]: 构建交互、轨迹及地理 3 个维度的多视图超图,显式建模用户与 POI 之间的高阶依赖关系。

STAN^[18]: 使用双向注意力机制架构,聚合沿途轨迹中所有签到的相关时空信息。

ROTAN^[7]: 将连续的时间戳映射到复数向量空间,利用复数域中的旋转操作显示建模时间周期性与非对称转移关系。

与基线模型推荐性能比较结果见表 2。经过实验对比分析可发现,STGN 模型在 NYC 和 TKY 数据集上的指标除 Recall@10 之外都要比 STRNN 模型更好,这说明 STGN 引入的时空门控机制可以有效提高 LSTM 结构的时空信息融合能力。LSTPM 模型凭借

联合建模长短期时间偏好取得了比 STGN 更好的表现,然而其基于 RNN 的强假设特性可能会导致错误依赖关系的出现。DeepMove 模型运用注意力机制捕获长期时空依赖关系,相比于 LSTPM 模型呈现出更为优越的性能。GeoSAN 和 STAN 对时空信息的利用更充分,因此效果好于 DeepMove。DyHGN 利用动态图结构能更好地适应不同密度的数据分布,进一步提升了模型性能。MVHGAT 利用超图卷积网络,用于聚集和传播,学习每个视图中的潜在因素,使模型性能进一步提升。ROTAN 则通过复数空间中的旋转机制精准建模时间周期性,展现出了更强的预测性能。由此可见,采用更精细的方式挖掘时空信息对提升模型准确性具有积极作用。本文 ISTARN 模型构建了签到序列的时空关系矩阵,采用多模态嵌入技术学习用户、位置、时间及时空效应的密集表示,借助时间间隔自注意力机制,通过引入高斯核函数显式建模时间相关性的平滑衰减,使模型能够有效容忍用户行为的时间偏移,从而精准捕获非连续访问间的潜在周期性关联,并且通过时空融合注意力网络对历史签到信息进行注意力聚合,提升了兴趣点推荐的准确性。

在 NYC 和 TKY 数据集上对比分析 Recall@K 和 NDCG@K 性能,ISTARN 模型在所有性能指标上均优于其他对比模型,这些实验结果验证本文模型体系结构的优越性与有效性。

表 2 与基线模型推荐性能比较

Tab. 2 Recommendation performance comparison with baselines

模型	NYC				TKY			
	Recall@5	Recall@10	NDCG@5	NDCG@10	Recall@5	Recall@10	NDCG@5	NDCG@10
STRNN	0.2365	0.2802	0.2045	0.2223	0.1836	0.2791	0.1675	0.2012
STGN	0.2439	0.3015	0.2171	0.2367	0.1904	0.2710	0.1747	0.2160
LSTPM	0.2791	0.3564	0.2316	0.2575	0.2568	0.3310	0.2114	0.2487
DeepMove	0.3268	0.4014	0.2834	0.3159	0.2684	0.3509	0.2286	0.2631
GeoSAN	0.4006	0.5267	0.3412	0.3955	0.2957	0.3740	0.2574	0.2815
DyHGN	0.4135	0.5172	0.3476	0.4063	0.3178	0.3824	0.2682	0.2883
STAN	0.4669	0.5962	0.3953	0.4471	0.3461	0.4264	0.2924	0.3268
MVHGAT	0.4733	0.6046	0.4102	0.4572	0.3513	0.4381	0.3018	0.3296
ROTAN	0.4825	0.6104	0.4085	0.4628	0.3552	0.4406	0.3076	0.3343
ISTARN	0.5156	0.6471	0.4362	0.4923	0.3723	0.4637	0.3253	0.3564

4.5 消融实验

为验证本文模型中各组成模块在用户时空偏好

建模过程中的作用,围绕时间间隔自注意力机制中的时空相关性建模方式及时空融合策略,设计了 3 种

模型变体,并在 NYC 和 TKY 两个数据集上进行了对比实验。通过分析不同变体模型在多个评价指标上的性能变化,对各模块的有效性进行评估,相关实验结果如图 2 所示。

为分析时空相关性建模方式对用户轨迹表示学习的影响,构建变体模型 ISTARN-1,移除由时间周期权重、时间间隔权重和空间距离权重共同构成的综合权重矩阵,使自注意力机制仅基于签到嵌入之间的相似性进行建模。实验结果显示,在两个数据集上,ISTARN-1 的模型性能在各评价指标上均出现下降。这表明仅依赖签到表示的内容相似性难以充分刻画用户历史签到行为之间的时空关联关系。引入时间周期性、时间间隔衰减以及空间距离约束后,模型能够更有效地建模不同行为之间的关联强度,从而提升整体推荐性能。

为评估显式时间间隔建模对用户轨迹表示学习的影响,构建变体模型 ISTARN-2,使用标准自注意力机制替代原有的时间间隔自注意力网络。实验结果表明,ISTARN-2 在两个数据集上均表现出一致的性能下降趋势。这说明标准自注意力机制在建模序列依赖关系方面具有一定能力,但由于未考虑签到行为之间不规则的时间间隔信息,其在刻画用户行为时间动态特征方面存在局限。相比之下,时间间隔自注意力机制通过连续时间衰减建模,使用户轨迹表示能够更准确地反映行为发生的时间特性。




图 2 在 NYC 和 TKY 上的消融实验结果

Fig. 2 Results of ablation experiments on NYC and TKY

为验证时空融合策略的有效性,构建变体模型 ISTARN-3,将基于候选兴趣点的时空融合注意力机制替换为对历史签到表示的简单平均操作。实验结果显示,该变体模型在两个评价指标上均出现性能下降。这表明不同历史签到行为对用户访问候选兴趣点的影响程度存在差异,采用等权重聚合方式难以充分反映这种差异性。通过引入时空融合注意力机制,模型


能够根据候选兴趣点动态聚合相关历史行为,从而构建更具判别性的用户偏好表示。

综合上述实验结果可以看出,本文模型各模块在模型性能提升中均发挥了积极作用。其中,基于时空相关性建模的时间间隔自注意力机制增强了用户轨迹的时空依赖建模能力,时空融合策略则进一步提升了模型对不同候选兴趣点的区分能力。

4.6 超参数分析

为了探究关键超参数对模型性能的影响,在不同参数设置下进行了分析实验。嵌入维度对模型表现的影响如图 3 所示。随着维度的增加,Recall@10 和 NDCG@10 呈现快速上升趋势,表明增加维度有效地缓解了欠拟合问题,增强了模型对稀疏签到数据的表征能力。当维度达到 60 时,模型在 NYC 和 TKY 两个数据集上均达到性能峰值,此时特征空间的表达能力与模型复杂度达到了最佳平衡。当维度进一步增加至 70 时,性能出现轻微下滑,表明模型出现轻微的过拟合现象。因此,将嵌入维度设定为 60。

参数 τ 在高斯核函数中起着调节时间窗口宽度的关键作用,它直接决定着模型对于用户签到时间偏移的容忍程度。参数 τ 对模型的影响如图 4 所示。模型性能随 τ 的增大呈现出先上升后下降的趋势。当 τ 取值较小时,高斯分布形态过于尖锐,模型对时间匹配的要求过于严格,这导致了具有自然波动特性的周期性行为被错误地过滤掉,限制了模型性能。 τ 增加至 0.2 时,模型在捕获严格周期性与容忍日常时间偏差之间找到了最佳平衡点,性能在两个数据集上都达到了峰值。但是当 τ 继续增大时,过宽的时间窗口导致权重衰减过于平缓,这使非周期性的噪声数据被赋予了不合理的高权重,削弱了模型对有效时空模式的判别能力。因此,将 τ 固定为 0.2 以确保最优性能。



(a) NYC 数据集






图 3 嵌入维度对模型的影响

Fig. 3 Effect of embedding dimension



(a) NYC 数据集



(b) TKY 数据集

图 4 参数 τ 对模型的影响Fig. 4 Effect of hyperparameter τ

5 结论

针对 POI 推荐任务中用户签到行为的复杂连续时空依赖关系,提出一种融合时空注意力关系的推荐模型 ISTARN。该模型通过构建基于自适应分位数划分的时空关系矩阵,实现了对连续时间间隔与空间距离信息的有效建模,并在时间间隔自注意力框架中引入高斯核平滑衰减机制,提升了模型对用户行为时间偏移的鲁棒性。同时,运用时空融合注意力加权预测策略能够针对不同候选兴趣点自适应聚合历史签到

信息,从而构建更具判别力的用户偏好表示。实验结果表明,本文方法在多个评价指标上均优于现有主流模型,验证了其在兴趣点推荐任务中的有效性。首先,模型对用户签到行为中时间周期性与空间邻近性的有效刻画,表明用户出行决策具有明显的时空规律性,这为城市管理者在公共设施布局、商业选址及服务资源配置等方面提供了数据支持。其次,通过精准建模用户在不同时间和空间条件下的偏好变化,位置服务平台和商业运营方可以更加高效地进行个性化推荐与精准营销,从而提升用户体验与平台运营效率。最后,本文模型的时空注意力建模框架具有较好的扩展性,可为智慧城市、智慧商业等应用场景中的决策支持系统提供参考。

在未来的工作中,可以尝试引用自适应特征融合机制,以求能更好地衡量不同模态特征对于用户决策的差异化贡献度,进一步挖掘多源数据的潜在价值引入;同时,尝试引入实时动态上下文信息,如即时天气、交通状况、临时性社交活动等,探索将这些异构信息与现有的时空嵌入进行有效对齐与联合建模。

参考文献:

- [1] Islam M A, Mohammad M M, Das S S S, et al. A survey on deep learning based point-of-interest (POI) recommendations [J]. Neurocomputing, 2022, 472: 306-325.
- [2] Werneck H, Silva N, Viana M C, et al. A survey on point-of-interest recommendation in location-based social networks[C]//Proceedings of the Brazilian Symposium on Multimedia and the Web. Brazil: Association of Computing Machinery, 2020: 185-192.
- [3] Liu Qiang, Wu Shu, Wang Liang, et al. Predicting the next location: a recurrent model with spatial and temporal contexts[C]//Proceedings of the 30th AAAI Conference on Artificial Intelligence. Phoenix: AAAI Press, 2016: 194-200.
- [4] Huang Liwei, Ma Yutao, Wang Shibo, et al. An attention-based spatiotemporal LSTM network for next poi recommendation[J]. IEEE Transactions on Services Computing, 2019, 14(6): 1585-1597.
- [5] Zhao Pengpeng, Luo Anjing, Liu Yanchi, et al. Where to go next: a spatio-temporal gated network for next POI recommendation[J]. IEEE Transactions on Knowledge and

- Data Engineering, 2020, 34(5): 2512-2524.
- [6] Wang Xiaolin, Sun Guohao, Fang Xiu, et al. Modeling spatio-temporal neighbourhood for personalized point-of-interest recommendation[C]//Proceedings of the 31st International Joint Conference on Artificial Intelligence. Vienna: IJCAI, 2022: 3530-3536.
- [7] Feng Shanshan, Meng Feiyu, Chen Lisi, et al. ROTAN: a rotation-based temporal attention network for time-specific next POI recommendation[C]//Proceedings of the 30th ACM SIGKDD conference on knowledge discovery and data mining. Barcelona: ACM, 2024: 759-770.
- [8] Ye Jihang, Zhu Zhe, Cheng Hong. What's your next move: user activity prediction in location-based social networks[C]//Proceedings of the 2013 SIAM International Conference on Data Mining. Austin: Society for Industrial and Applied Mathematics, 2013: 171-179.
- [9] Yin Hongzhi, Wang Weiqing, Wang Hao, et al. Spatial-aware hierarchical collaborative deep learning for POI recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2017, 29 (11) :2537-2551.
- [10] Jiang Shuhui, Qian Xueming, Shen Jialie, et al. Author topic model-based collaborative filtering for personalized POI recommendations[J]. IEEE Transactions on Multimedia, 2015, 17 (6) :907-918.
- [11] Luan Wenjing, Liu Guanjuan, Jiang Changjun, et al. Partition-based collaborative tensor factorization for POI recommendation[J]. IEEE/CAA Journal of Automatica Sinica, 2017, 4 (3) :437-446.
- [12] Rendle S, Freudenthaler C, Schmidt-Thieme L. Factorizing personalized Markov chains for next-basket recommendation[C]// Proceedings of the 19th International Conference on World Wide Web. Raleigh: Association for Computing Machinery, 2010: 811-820.
- [13] Lai Yiqiang, Zeng Xianfeng. A POI recommendation model for intelligent systems using AT-LSTM in location-based social network big data[J]. International Journal on Semantic Web and Information Systems, 2023, 19(1): 1-15.
- [14] Wang Ziwei, Zeng Jun, Zhong Lin, et al. DSDRec: next POI recommendation using deep semantic extraction and diffusion model[J]. Information Sciences, 2024, 678: 121004.
- [15] Qin Yifang, Xie Jiaxuan, Xiao Zhiping, et al. GeoMamba: towards multi-granular POI recommendation with geographical state space model[C]//Proceedings of the AAAI Conference on Artificial Intelligence. Philadelphia: AAAI Press, 2025: 12479-12487.
- [16] Xia Qingxin, Hara T, Maekawa T, et al. An effective and efficient self-attention based model for next POI recommendation [C]// 2023 IEEE International Conference on Pervasive Computing and Communications Workshops and other Affiliated Events. Piscataway: IEEE, 2023: 478-483.
- [17] 沈学利, 杜志伟. 融合自注意力机制与长短期偏好的序列推荐模型[J]. 计算机应用研究, 2021, 38(5): 1371-1375.
- [18] Luo Yingtao, Liu Qiang, Liu Zhaocheng. STAN: spatio-temporal attention network for next location recommendation[C]// Proceedings of the 2021 World Wide Web Conference. Ljubljana: International World Wide Web Conferences Steering Committee Association for Computing Machinery, 2021: 2177-2185.
- [19] Zhou Shiyang, Zhu Jinghua, Xi Heran, et al. Heterogeneous graph based long- and short-term preference learning model for next POI recommendation[C]//Proceedings of the 22nd International Conference on Algorithms and Architectures for Parallel Processing. Copenhagen: Springer-Verlag, 2022: 455-470.
- [20] Kingma D P, Ba J. Adam: A method for stochastic optimization[PP/OL]. (2014-12-22)[2025-12-30]. V1. arXiv. <https://doi.org/10.48550/arXiv.1412.6980>.
- [21] Sun Ke, Qian Tieyun, Chen Tong, et al. Where to go next: modeling long-and short-term user preferences for point-of-interest recommendation[J]. Proceedings of the AAAI Conference on Artificial Intelligence, 2020, 34(1): 214-221.
- [22] Feng Jie, Li Yong, Zhang Chao, et al. DeepMove: predicting human mobility with attentional recurrent networks[C]//Proceedings of the 2018 World Wide Web Conference. Lyon: Association for Computing Machinery, 2018: 1459-1468.
- [23] Lian Defu, Wu Yongji, Ge Yong, et al. Geography-aware sequential location recommendation[C]// Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining. New York: Association for Computing Machinery, 2020: 2009-2019.

- [24] Wang Tianci, Lai Yantong, Chen Gaode, et al. A dynamic-aware heterogeneous graph neural network for next POI recommendation[C]//Pacific Rim International Conference on Artificial Intelligence. Singapore: Springer Nature Singapore, 2023: 313-326.
- [25] Hu Luyao, Han Guangpu, Liu Shichang, et al. Multi-view contrastive fusion POI recommendation based on hypergraph neural network[J]. Mathematics, 2025, 13(6): 998.