

基于双粒度序列融合的下一个兴趣点推荐^①

彭 瑾, 史艳翠, 刘凌云

(天津科技大学 人工智能学院, 天津 300457)

通信作者: 史艳翠, E-mail: syc@tust.edu.cn



摘要: 针对现有方法无法有效利用签到信息为用户提供更精准的位置推荐服务的问题, 提出一种基于双粒度序列融合的下一个兴趣点推荐模型。首先, 该模型综合考虑了细粒度的时空序列信息和现实生活中天然存在的粗粒度类别序列信息, 并通过门控循环单元有效捕捉长期依赖关系, 从而丰富签到上下文信息。然后, 利用提取到的信息将固定划分签到长序列的“硬”划分方式转变为能有效提取完整局部子序列语义信息的“软”划分方式。最后, 通过对各局部子序列的显著信息进行聚合来构建推荐模型。提出的模型在 Foursquare 数据集上召回率、归一化折损累计增益分别平均提升 9.07%、9.72%, 在 Gowalla 数据集上分别平均提升 9.37%、10.24%, 实验结果表明该模型具有更优的推荐性能。

关键词: 兴趣点推荐; 双粒度序列; 签到上下文; 序列划分; 门控循环单元

引用格式: 彭瑾, 史艳翠, 刘凌云. 基于双粒度序列融合的下一个兴趣点推荐. 计算机系统应用. <http://www.c-s-a.org.cn/1003-3254/9724.html>

Next Point-of-interest Recommendation Based on Dual-granularity Sequence Fusion

PENG Jin, SHI Yan-Cui, LIU Ling-Yun

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

Abstract: Existing methods fail to effectively leverage check-in information to provide precise location recommendation services. To address this problem, this study introduces a novel model for the next point-of-interest (POI) recommendation based on dual-granularity sequence fusion. Firstly, the model integrates fine-grained spatio-temporal sequence information with naturally occurring coarse-grained categorical sequence information in real life. It effectively captures long-term dependency relationships using gated recurrent units to enrich the context of check-ins. Subsequently, the model uses the extracted information to transform the “hard” segmentation of long sequences into a “soft” segmentation, enabling the extraction of complete semantic information from local sub-sequences. Finally, the recommendation model aggregates salient information from each local sub-sequence. Experimental results on the Foursquare and Gowalla datasets show that the proposed model improves the recall by 9.07% and 9.37%, respectively, and enhances the normalized discounted cumulative gain by 9.72% and 10.24%, respectively. These results indicate that the proposed model exhibits superior recommendation performance.

Key words: point-of-interest (POI) recommendation; bi-granular sequence; check-in context; sequence partitioning; gated recurrent unit (GRU)

随着可定位电子移动设备的大量普及, 基于位置的社交网络 (location based social network, LBSN) 应用

逐渐走进人们的生活^[1], 典型的如 Foursquare、Twitter 等。用户不仅可以使用智能移动设备签到自己感兴趣

① 基金项目: 国家自然科学基金 (62377036)

收稿时间: 2024-06-06; 修改时间: 2024-06-28; 采用时间: 2024-07-11; csa 在线出版时间: 2024-11-28

的地点,还能与家人或好友分享自己的签到信息.因而产生了大量极具个人特色的签到数据,并引起了学者们对兴趣点(point-of-interest, POI)研究领域的关注.

在传统的兴趣点推荐中,典型的方法是融合用户的自身偏好、地理位置、社交关系、时间信息等因素以实现精准的兴趣点推荐.现有研究考虑的因素越来越多,但大多数模型把用户的签到信息按照静态特征处理.在实际的生活场景中,用户的签到行为通常具有移动性、复杂性、周期性等特征.此外,用户的移动行为很大程度上受其之前签到序列的影响.因此,众多学者开始探索下一个兴趣点推荐领域,并研究用户访问不同地点之间的顺序关系对推荐下一个兴趣点所产生的影响.

下一个兴趣点推荐更多地利用签到序列、时间、地理位置等信息来辅助预测用户下一个可能移动的地点.在早期的研究中,它采用序列推荐任务中的常用方法进行预测,如马尔可夫链^[2,3]、矩阵分解^[3]、度量嵌入^[4]等.如今,鉴于注意力机制在序列推荐领域的成功应用,双层注意力模型、改进的Transformer、循环神经网络(recurrent neural network, RNN)及其变体长短时记忆网络(long short-term memory, LSTM)等方法被引入到下一个兴趣点推荐领域中.尽管这些方法相较于早期模型能够更有效地提升推荐的准确性,但仍存在一些局限:一方面,研究者们仅依靠签到长序列本身的信息对用户移动行为建模,不注重结合用户轨迹序列的全局上下文信息.另一方面,虽然从签到长序列中推断出用户的潜在移动模式,并提取其中丰富的语义信息十分关键,但大多数模型忽略了局部子序列完整信息的重要性.

综上,本文将签到的全局上下文信息引入下一个兴趣点推荐研究中,提出了一种基于双粒度序列融合的下一个兴趣点推荐模型DGSF(next point-of-interest recommendation based on dual-granularity sequence fusion),主要贡献如下.

(1) 在细粒度时空序列的基础上,结合天然存在的粗粒度类别序列,对现有用户签到行为建模,提取序列全局上下文信息,获取更丰富的特征表示.

(2) 引入序列“软划分”的概念,利用全局上下文信息把需要划分子序列的相关量转变为可预测的参数,从而实现自适应序列划分,最终可以获得局部子序列的完整语义信息.

(3) 提出一种基于双粒度序列融合的算法模型,学习序列中更突出、更全面的嵌入表示,提升推荐的准确性.

1 相关工作

1.1 传统兴趣点推荐

近年来,由于兴趣点推荐具有广阔的应用前景而引起了学者们的关注.Ding等人^[5]提出了一种时空距离度量嵌入模型,它利用签入时间和地理序列属性有效捕获用户的特定时间偏好,进而提升推荐性能.申晋祥等人^[6]深度提取评论文本中的信息,同时结合用户偏好及位置偏好建模,以此获得更准确的兴趣点推荐.安敬民等人^[7]通过建模用户社会关系和POI地理特征重构上下文信息模型,并将其与用户自身偏好模型进行有效融合,提升个性化兴趣点推荐的准确性.王兴源^[8]基于图嵌入的方法提取更深层次的兴趣点及辅助信息,再利用神经网络建模用户近期偏好建模,以应对数据稀疏性和冷启动问题.

1.2 下一个兴趣点推荐

随着兴趣点研究领域的扩展,下一个兴趣点推荐正逐渐成为新的研究热点.Liu等人^[9]结合不同时间间隔和地理间隔的特异性过渡矩阵捕获时空背景信息,并利用循环结构捕获周期性的时间上下文,最终提出一种新的时空递归神经网络模型ST-RNN.Luo等人^[10]设计了一种时空双注意力模型STAN,该模型充分考虑位置聚合的时空效应,并结合时空相关性来学习非相邻位置和非连续访问之间的规律.Yang等人^[11]提出了一种基于Transformer的框架,利用签到顺序转换信息生成一个全局轨迹流图,接着将用户短期轨迹、用户一般偏好、时空上下文融合为最终签到表示以辅助预测下一个兴趣点.石美惠等人^[12]将全局静态特征和用户签到之间的顺序依赖相结合来预测用户下一个可能移动的地点.

2 问题定义及GRU模型描述

2.1 问题定义及相关描述

$U = \{u_1, \dots, u_i, \dots, u_{|U|}\}$ 和 $P = \{p_1, \dots, p_j, \dots, p_{|P|}\}$ 分别表示用户和兴趣点集合,其中 $|U|$ 表示用户的数量, $|P|$ 表示兴趣点的数量.

用户的签到序列: $Q = \{S^{u_1}, S^{u_2}, \dots, S^{u_{|U|}}\}$ 表示所有用户的历史签到序列.那么,用户 u 的签到序列表示为

$S^u = (cs_{t_1}^u, \dots, cs_{t_k}^u, \dots, cs_{t_l}^u)$, $cs_{t_i}^u$ 为签到相关因素组成的多元组, 表示为用户 u 在时间 t_i 的一次签到活动.

DGSF 模型的推荐任务是为用户在下一时刻推荐其最有可能访问的地点, 即给定用户 u 和其签到序列 S^u , 预测用户在 t_{i+1} 访问的 POI ($p_{t+1} \in p$).

2.2 GRU 模型

门控循环单元 (gated recurrent unit, GRU) 通过门机制选择性遗忘之前不重要的信息, 最终达到控制信息流动的目的. 这种特点决定它既可以处理序列中的长期依赖关系, 也可以及时忽略掉可能对当前输出产生误导的信息, 进而提高对下一个兴趣点推荐的准确性及可解释性^[13]. 因此, 本文采用 GRU 作为细粒度时空序列与粗粒度类别序列融合后提取信息的深度学习模型.

GRU 模型的基本计算公式如下:

$$z_t = \sigma(W_{zx}x_t + W_{zh}h_{t-1} + b_z) \quad (1)$$

$$r_t = \sigma(W_{rx}x_t + W_{rh}h_{t-1} + b_r) \quad (2)$$

$$\tilde{h} = \tanh(W_{hx}x_t + W_{hr}(r_t \odot h_{t-1}) + b_h) \quad (3)$$

$$h_t = z_t \odot \tilde{h}_t + (1 - z_t) \odot h_{t-1} \quad (4)$$

其中, \odot 是哈达玛积运算; σ 是 Sigmoid 激活函数; 更新门 z_t 、重置门 r_t 控制每个隐层的信息更新; W_{zx} 、 W_{zh} 、 W_{rx} 、 W_{rh} 、 W_{hx} 、 W_{hr} 均表示权重系数矩阵; b_z 、 b_r 、 b_h 均是偏置参数; x_t 和 h_{t-1} 分别表示当前时间 t 的输入向量和上一时间 $t-1$ 的输入向量; \tilde{h}_t 中的 $r_t \odot h_{t-1}$ 表示通过重置门 r_t 控制上一时间的输入需保留信息量; h_t 的前半部分通过更新门 z_t 控制当前时间输入的信息量, 后半部分通过 $1 - z_t$ 控制上一时间输入的信息量.

3 算法描述

3.1 模型框架描述

针对现有模型无法精准为用户进行下一个兴趣点推荐的问题, 因此本文采取双粒度序列融合的方式进行推荐. DGSF 模型主要包括嵌入层、全局上下文信息融合层、序列自适应划分层、子序列聚合层及预测层. 其中, 嵌入层将天然存在的粗粒度类别序列及与用户签到序列密切相关的细粒度时空序列分别转换为对应嵌入向量; 全局上下文信息融合层将二者的对应向量输入 GRU 中得到融合后的全局上下文信息; 序列自适应划分层利用前一层得到的信息动态地调整预测变化

中心的偏移距离与子序列偏移长度, 最终降低固定划分方式所带来的信息损失, 提高对完整语义信息的提取能力; 子序列聚合层为了突出完整语义信息对用户行为建模的影响, 采用子序列最大聚合增强相关特征表示; 预测层最后对下一个签到的兴趣点进行预测. DGSF 的总体框架图如图 1 所示.

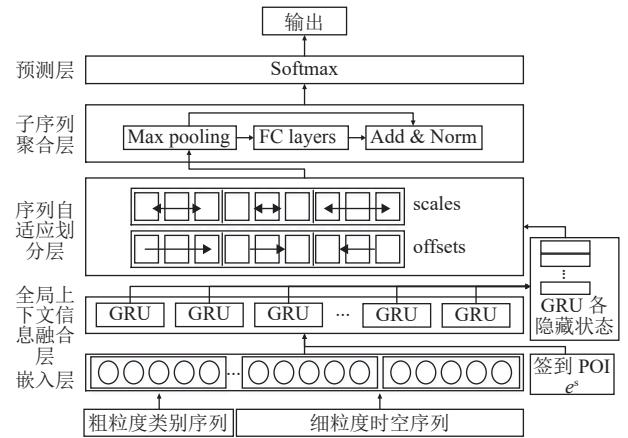


图 1 总体框架图

3.2 嵌入层

3.2.1 粗粒度类别序列嵌入

用户类别序列是在语义层面对其历史签到序列的表示, 它能够揭示用户的移动趋势和行为模式偏好^[14]. 同时, 类别序列内部的语义相关性程度越高, 则代表用户做出类似选择的可能性越大. 但是, 需要注意的是这种相关性具有高度的顺序依赖性、随时空变化性. 例如, 用户更倾向于从“餐饮”类别转向“运动”类别, 但这种模式会受到之前访问过的 POI 类别的影响, 从而导致访问顺序出现变化. 由此可见, 类别信息对于预测用户下一个要访问的地点具有重要意义.

现有的大多数研究常建立在用户签到地点的细粒度类别序列上, 例如, 用户 A 的类别序列为“家→公司→披萨店→羽毛球馆→家”. 然而, 忽略了其中天然存在的粗粒度类别序列. 因为在本文所使用的数据集中, 众多用户所访问的地点涉及上百个细粒度类别, 这种情况使得信息提取较为困难, 不利于提高预测的准确性. 所以, 本文在此基础上将细粒度类别序列归纳成更高级别且语义涵盖范围更大的粗粒度类别序列. 此时, 用户 A 的类别序列将转变为“住宅→办公地→餐饮→运动→住宅”, 如图 2 所示.

因此, 本文将用户 u 的类别序列表示为 $C^u =$

$(c_{t_1}^u, \dots, c_{t_k}^u, \dots, c_{t_i}^u)$, 序列长度为 i , 其为经过处理过后所确定的固定值. 最终, 定义在 t_k 时刻输入的类别嵌入向量为 $e_{t_k}^c$.

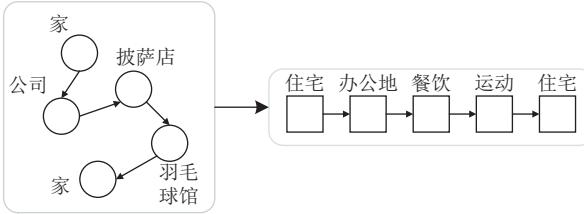


图 2 粗粒度类别序列

3.2.2 细粒度时空序列嵌入

对于下一个兴趣点推荐的特点而言, 与 POI 最直接相关的信息即为时间、地理位置信息. 然而, 过去的推荐研究方法通常将用户访问 POI 的时间看作是固定不变的时间点, 地理位置信息则直接采用 POI 的经度、纬度来表示. 然而, 固定时间点无法表现用户访问 POI 与 POI 之间的时间连续性, 这与真实情况相悖. 经纬度信息虽能精确定位一个 POI, 但忽略了 POI 之间的关联性, 即距离近的 POI 比距离远的 POI 更相关, 表现出较强的地理影响^[15].

因此, 本文为了利用用户签到序列的时间背景信息, 计算用户访问过的每两个兴趣点之间的时间间隔, 用以构建相应的时间间隔嵌入向量. 其中, 用户签到序列 S^u 对应的时间戳序列为 $T_s = (t_{t_1}, \dots, t_{t_k}, \dots, t_{t_i})$. S^u 内两地 $cs_{t_i}^u$ 和 $cs_{t_j}^u$ 的时间间隔为 $t_{A_{i,j}} = |t_i - t_j|$. 最终, 定义在 t_k 时刻输入的空间间隔嵌入向量为 $e_{t_k}^t$.

为了利用用户签到序列的空间背景信息, 计算用户访问过的每两个兴趣点之间的空间间隔, 用以构建相应的空间间隔嵌入向量. 其中, 两个地点之间距离间隔 d_i 可以通过两个地点经纬度坐标的 Haversine 公式计算得到. 签到序列 S^u 对应的地理位置序列为 $D_s = (d_{t_1}, \dots, d_{t_k}, \dots, d_{t_i})$, S^u 内两地 $cs_{t_i}^u$ 和 $cs_{t_j}^u$ 的距离间隔为 $d_{A_{i,j}} = \text{Haversine}(d_i, d_j)$. 最终, 定义在 t_k 时刻输入的空间间隔嵌入向量为 $e_{t_k}^d$.

3.3 全局上下文信息融合层

用户的访问行为往往具有时空依赖性, 但值得注意的是, 探索单个 POI 上的时空模式远不如研究融合类别因素的时空-类别模式清晰和稳定. 因此, 本文将细粒度时空序列信息与粗粒度类别序列信息进行有效融合. 鉴于签到序列本身对挖掘移动模式信息的重要

影响, 本文还将用户在 t_k 时刻输入的签到序列信息的嵌入向量 $e_{t_k}^s$ 也加入其中. 最终经过 GRU 基础模型形成基于双粒度序列融合的全局上下文信息.

计算公式如下:

$$e_{t_k} = W_c e_{t_k}^c + W_t e_{t_k}^t + W_d e_{t_k}^d + W_s e_{t_k}^s + b_G \quad (5)$$

$$h_{t_k}^u = \text{GRU}(e_{t_k}, h_{t_{k-1}}^u) \quad (6)$$

其中, W_c 、 W_t 、 W_d 、 W_s 分别为对应向量的可学习的权重, b_G 为相应偏置, GRU(·)是 GRU 基础模型的公式的集合, 如式 (1)–式 (4) 所示. $h_{t_{k-1}}^u$ ($1 \leq k \leq i$) 表示第 t_{k-1} 时刻的隐藏状态.

最终可得到所有时刻 $(t_{t_1}, \dots, t_{t_k}, \dots, t_{t_i})$ 的所有隐藏状态 $E_{\text{GAL}}(u) = (h_{t_1}^u, \dots, h_{t_k}^u, \dots, h_{t_i}^u)$.

3.4 序列自适应划分层

从局部子序列中提取完整的语义信息为推荐下一个兴趣点提供了巨大的帮助^[16], 然而现有的方法通常把一段长序列划分为固定大小的子序列, 这种“硬”划分方式可能会带来两个问题, 从而影响推荐的准确性. 第 1, 可能会捕获到同一用户偏好的不一致信息, 降低推荐的准确性. 第 2, 序列中不容易捕捉到完整的与用户常见移动模式相关的局部信息. 例如在工作日, 用户的签到长序列中可能多次出现家、公司以及公司附近的餐厅这 3 个签到地点形成的局部子序列, 但序列的“硬”划分方式可能割裂这 3 个地点的连贯模式, 导致完整语义信息的丢失. 考虑到这类子序列蕴含的完整语义信息对用户决策的影响, 从而在工作日用餐时间为用户推荐公司附近更符合其喜好的餐厅, 而不是更远处的其他类型的地点.

为了清晰、规范地描述“软”划分方法的实现过程, 首先按照传统方法将一段长序列划分成 $\lceil \frac{L}{len} \rceil$ 段不重叠的子序列^[17,18]. 其次, 将长序列 L 中第 i 个子序列的中点设为 c_i , 且划分后每一段子序列的范围可表示为 $(c_i - len/2, c_i + len/2)$. 其次, 根据上一层输出的全局上下文信息, 本文将围绕变化中心的偏移距离与重新确定的子序列偏移长度转变为可预测的参数, 并将变化后每段子序列的范围确定为 $(c_i + \Delta c_i - \Delta len_i/2, c_i + \Delta c_i + \Delta len_i/2)$, 最终降低“硬”划分方式所带来的信息损失.

基于输入序列的全局上下文信息, 第 i 个子序列中 c_i 与 len_i 的变化如式 (7) 和式 (8) 所示:

$$\Delta c_i = \tanh(W_{\text{off}} \cdot f(E_{\text{GAL}}(u)_i)) \quad (7)$$

$$\Delta len_i = \text{ReLU}(\tanh(W_{\text{scale}} \cdot f(E_{\text{GAL}}(u)_i) + b_{\text{scale}})) \quad (8)$$

其中, W_{off} 、 W_{scale} 、 b_{scale} 分别为控制中心坐标偏移权重、有效移动距离的权重和移动偏置, 它们可以用来更新子序列的位置. $E_{\text{GAL}}(u)_i$ 是经过上下文层得到的第 i 个子序列的矩阵表示. $f(\cdot)$ 表示从子序列表示中学习偏移量和长度的特征提取器.

综上, 理论上得到了符合预期的变长子序列. 但在实现过程中仍然存在两个必须要解决的问题: (1) 多个变长序列的编码难以实现且预测的活动中心坐标表示大概率不是整数. (2) 如何把得到的序列合理表示出来. 为了解决问题 (1), 本文采取均匀采样策略, 利用大量的采样数据推断出最接近划分长度的定长序列, 并选择线性插值以及最邻近采样的方法来调整坐标表示. 为了解决问题 (2), 本文将调整后的采样点表示为 $\{\hat{a}^{[x_j]}, j = 1, 2, \dots, n\}$, 最终得到的序列表示如下所示:

$$E_{\text{LP}}(u)_i = \text{Concat}([\hat{a}^{[x_1]}; \hat{a}^{[x_2]}; \dots; \hat{a}^{[x_n]}]) \quad (9)$$

3.5 子序列聚合层

为了加强每一段子序列中的每个签到地点所表示的语义信息对用户移动行为建模的影响, 同时精确构建用户偏好表示, 本文对子序列进行最大池化聚合, 计算公式如式 (10) 所示:

$$E(S)_i = \text{Aggregate}(E_{\text{LP}}(u)_i) \quad (10)$$

最后, 为了解决训练过程不稳定与模型过拟合等问题, 本文在计算后加入前馈神经网络, 以及 dropout 正则化等技术, 得到聚合后的最终输出序列的整体表示 $E(S)$.

3.6 预测层

为了预测下一个签到的兴趣点, 本文需要获得用户个性化移动的特征表示, 即第 3.5 节中得到的 $E(S)$, 在预测层中表示为 U_u . 本文直接使用 Softmax 函数将输出转换为可预测的概率, 其公式表达如下:

$$\hat{y}_u = \text{Softmax}(U_u W^{\text{Pre}}) \quad (11)$$

其中, W^{Pre} 是可学习的权重矩阵, \hat{y}_u 是用户 u 访问下一个兴趣点的预测分数的集合.

最后, 本文使用交叉熵损失函数来量化模型的 POI 预测任务的误差:

$$\text{Loss} = - \sum_{S_u \in S_{\text{Train}}} \left(\sum_{j \in P} \log(1 - \hat{y}_{u,j}) + \log \hat{y}_{u,i} \right) \quad (12)$$

其中, S_{Train} 代表用户签到轨迹序列的训练集, 而 P 则表示所有 POI 签到地点的集合.

4 实验与分析

4.1 数据集

为了验证基于双粒度序列融合的下一个兴趣点推荐模型的有效性, 本文在 Foursquare 和 Gowalla 两个公开数据集上进行实验. Foursquare 数据集中包含了用户在纽约的移动签到数据. Gowalla 数据集收集了用户在加州和内华达州进行签到的移动数据. 经过处理后的两个数据集均包含用户 ID、POI ID、POI 粗粒度类别、签到地点的经纬度以及时间戳等信息.

本文在实验开始前对数据集进行预处理, 首先是在每个数据集中剔除掉签到次数小于 10 次的用户及其 POI 相关信息; 接着本文考虑到编码不等长序列的复杂程度, 对不同长度的签到序列统一进行处理. 最后为了模拟真实世界的下一个 POI 推荐场景, 按时间顺序对每个用户的签到进行排序, 并将数据集分为训练集 (80%)、验证集 (10%) 和测试集 (10%).

4.2 评价指标

为了评估推荐 DGSF 模型的性能优劣, 本文使用召回率 Recall 和归一化折损累计增益 NDCG 作为评价指标. 这两个评价指标被广泛应用于下一个兴趣点推荐的研究领域中.

(1) 召回率 ($\text{Recall}@K$), 衡量模型推荐结果中正确识别用户访问占将访问兴趣点的比例, $K \in \{5, 10\}$.

(2) 归一化折损累计增益 ($\text{NDCG}@K$), 通过给排名靠前的命中分配更高的权重来进一步强调命中的位置, $K \in \{5, 10\}$. 计算公式如下所示:

$$\text{DCG}@K = r_{\text{rel},1} + \sum_{y=2}^n \frac{r_{\text{rel},y}}{\log_2 y} \quad (13)$$

$$\text{NDCG}@K = \frac{\text{DCG}@K}{\text{IDCG}@K} \quad (14)$$

其中, $\text{IDCG}@K$ 是当推荐的 POI 被排在理想位置时的 $\text{DCG}@K$ 值. $r_{\text{rel},y}$ 是指排名在第 y 位的结果的相关性. $\text{NDCG}@K$ 的范围是 0–1, 数值越大意味着推荐结果越好.

4.3 实验环境及参数设置

本文实验是在 Intel Xeon E5-2667 v4 CPU 以及 NVIDIA RTX 3070 GPU 的硬件基础上, 使用 Python 3.9.16 及 PyTorch 1.10.0 学习框架实现. 同时,

将模型的丢弃率 dropout 设为 0.2, 学习率采取与文献[19]中相同的动态调整方法, 隐藏维度 hidden size 设为 128, 并且使用 Adam 优化器优化模型的相关参数.

4.4 对比模型

本文将提出的基于双粒度序列融合的下一个兴趣点推荐模型与以下 7 个典型模型进行对比, 对比结果如图 3、图 4 所示.

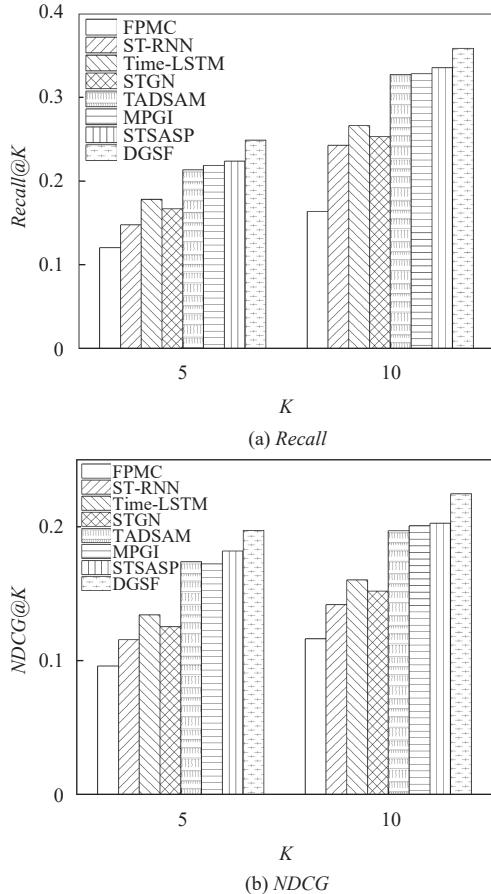


图 3 在 Foursquare 数据集上的性能比较

(1) FPMC^[3]: 扩展 BPR 框架, 将用户偏好与马尔可夫链结合起来.

(2) ST-RNN^[9]: 该方法考虑每一层 RNN 中的时空背景, 利用时间特异性转移矩阵和距离特异性转移矩阵分别表征连续时间间隔的动态性和距离地理特性.

(3) Time-LSTM^[20]: 提出 LSTM 的一种新变体, 设计时间门和距离门来捕获签到之间的时空间隔信息.

(4) STGN^[21]: 利用时空门控网络扩展了 LSTM 的门控机制, 通过 4 个时空门来捕捉用户的长期和短期的空间、时间偏好.

(5) TADSAM^[22]: 使用扩展的自关注机制来处理复

杂的用户签到记录, 并在考虑时间影响的基础上采用个性化的权重计算方法挖掘用户签到行为中蕴含的时间模式信息.

(6) MPG1^[23]: 针对用户的长短期偏好建模, 设计了一种 POI 关联建模层, 并将高度相关的 POI 与目标 POI 相融合, 以动态选择签到轨迹中最有价值的信息.

(7) STSASP^[24]: 该模型将时空网络与自注意力机制结合, 通过签到地点与候选地点的时空信息为用户推荐感兴趣的地点序列.

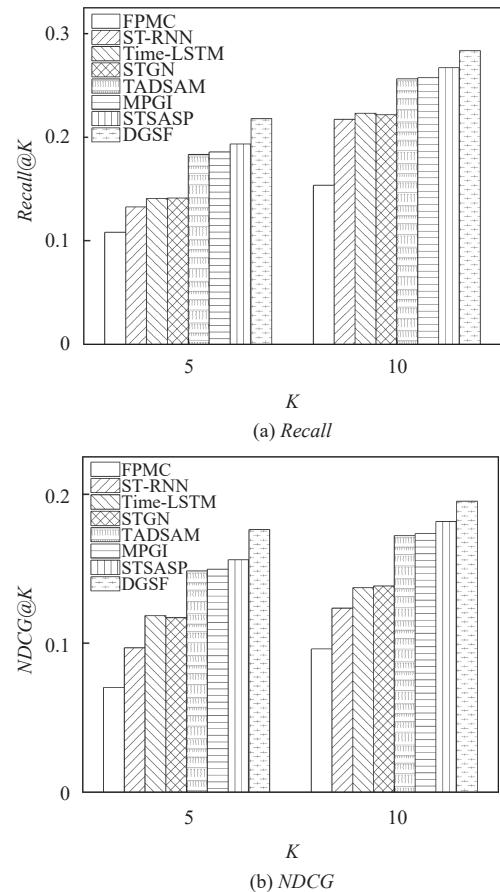


图 4 在 Gowalla 数据集上的性能比较

从图 3、图 4 中的对比数据可见, 本文提出的 DGSF 模型在两个数据集的相关指标均高于所对比基线模型. 在 Foursquare 数据集上, 与最佳基线 STSASP 相比, $Recall@5$ 、 $Recall@10$ 分别提升了 11.26%、6.88%, $NDCG@5$ 、 $NDCG@10$ 分别提升了 8.53%、10.91%. 同时, 在另一个数据集 Gowalla 上, $Recall@5$ 、 $Recall@10$ 分别提升了 12.61%、6.14%, $NDCG@5$ 、 $NDCG@10$ 分别提升了 12.95%、7.54%. 此外, 基于非神经网络的模型 FPMC 的各项指标均低于基于神经网

络的模型。由此可见，神经网络模型对序列建模能力有显著提升。而基于 RNN 变体的模型 (Time-LSTM、STGN、STSASP) 指标表现比基于 RNN 模型的更好。因此，RNN 的变体普遍在长序列建模方面优于 RNN，并且对整个签到序列的建模能力更优秀。其中，嵌入至少一种时空信息模型 (ST-RNN、Time-LSTM、STGN、TADSAM、MPGI、STSASP) 的指标表现低于本文提

出的模型，这原因可能是本模型在考虑时空信息的基础上还引入了粗粒度类别信息，证明丰富的签到上下文信息能对用户的移动行为进行更全面、更准确的建模。

4.5 消融实验

为了验证本文提出的模型的各个组件的有效性，因此主要将 3 种变体与整体模型的结果进行对比，结果如表 1 所示。

表 1 变体与整体模型对比结果

变体	Foursquare				Gowalla			
	Recall@5	Recall@10	NDCG@5	NDCG@10	Recall@5	Recall@10	NDCG@5	NDCG@10
DGSF-c	0.2215	0.3371	0.1723	0.1977	0.1828	0.2689	0.1354	0.1561
DGSF-st	0.1236	0.2145	0.0873	0.1132	0.0975	0.1738	0.0821	0.1056
DGSF-ss	0.1721	0.2712	0.1375	0.1641	0.1317	0.2103	0.1132	0.1379
DGSF	0.2489	0.3587	0.1972	0.2246	0.2178	0.2835	0.1761	0.1953

(1) DGSF-c: 在模型构建时，忽略粗粒度类别序列，故不涉及双粒度序列信息的融合。

(2) DGSF-st: 在模型构建时，忽略细粒度时空序列，故不涉及双粒度序列信息的融合。

(3) DGSF-ss: 在模型构建时，忽略序列的自适应划分和子序列聚合，采取固定划分方式提取序列信息。

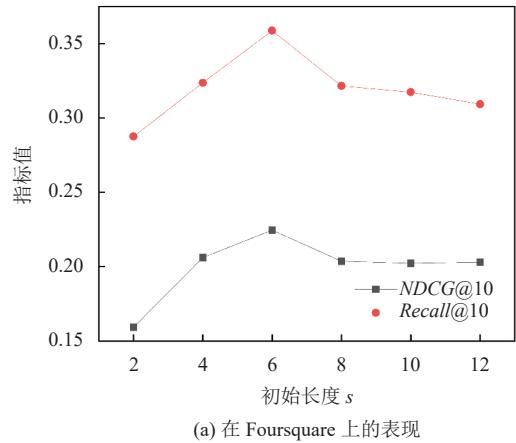
表 1 展示了本文提出的模型 DGSF 以及几种变体的性能差异，同样采用 Recall 与 NDCG 作为评价指标进行评估。从实验数据中可以观察到：在两个数据集上，本文所提出模型的推荐性能均高于所提出的 3 种变体。其中，DGSF-c 忽略粗粒度类别信息后，性能指标虽不如 DGSF，但相对接近。这是因为粗粒度类别序列是作为辅助信息融入全局上下文签到信息中的，粗粒度类别序列本身可挖掘的信息量与细粒度时空序列的相比也存在差距，因此模型性能最接近 DGSF。DGSF-st 忽略用户签到的细粒度时空序列信息，导致性能急剧下降，从而导致之后所设计的模块最大限度地发挥作用，这充分表明时空上下文信息与下一个兴趣点推荐任务息息相关，利用时空信息能提升模型的推荐性能。而 DGSF-ss 忽略序列的自适应划分和相关子序列的聚合，性能也出现一定程度的下降，这表明这部分组件能充分学习用户签到长序列中所蕴含的更丰富的语义信息。

4.6 不同超参数对性能的影响及分析

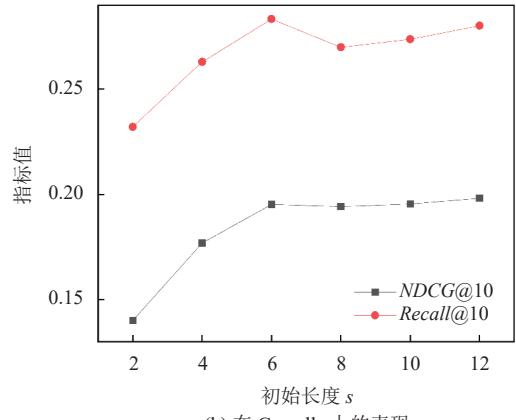
子序列初始长度、嵌入维度是本模型中两个至关重要的参数，能够明显影响模型的性能表现。本文将在两个数据集上对这两个参数进行实验，以此探究对模型性能产生的影响。

4.6.1 子序列初始长度

本文为探究初始设置的不同子序列长度对模型产生的影响，故将子序列的初始长度 s 在 {2, 4, 6, 8, 10, 12} 中进行取值，实验结果如图 5 所示。



(a) 在 Foursquare 上的表现



(b) 在 Gowalla 上的表现

图 5 DGSF 在不同初始长度 s 下的性能变化

图 5 显示了模型性能会随着 s 的增大, 先上升后下降。可见, 子序列初始长度过短将无法提取子序列中蕴含的完整语义信息; 子序列初始长度过长则可能导致模型处理数据的成本上升且引入不必要的噪声, 从而带来性能上的下降。实验结果显示, 在达到最优值之前, 增加 s 的值, 可以使模型取得更好的效果。其中, 在 s 的值取 6 时, 效果最好。所以, 本文默认将子序列的初始长度设为 6。

4.6.2 嵌入维度

本文将全局上下文信息融合层中的粗粒度类别序列模块与细粒度时空序列模块中的嵌入维度 d 的大小进行统一, 并在 {16, 32, 64, 96, 128} 中取值进行实验, 实验结果如图 6 所示。

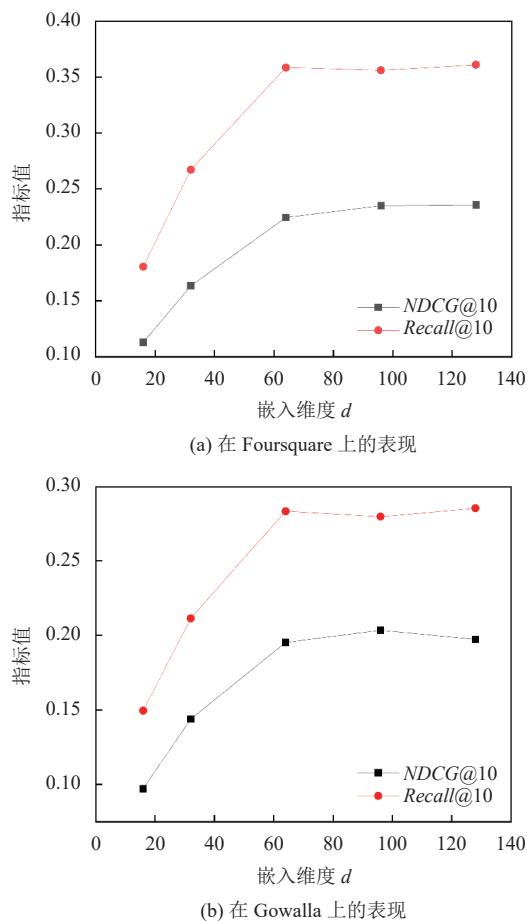


图 6 DGSF 在不同嵌入维度 d 下的性能变化

图 6 显示了嵌入维度 d 较小时, 模型性能表现较差。随着 d 的逐步增加, 模型的推荐性能急剧上升, 之后逐渐趋于稳定。出现此现象的原因, 可能是初始设置的嵌入维度 d 过小, 提取信息特征的能力较弱, 从而导

致推荐效果不佳。随着嵌入维度 d 变大, 模型表达能力加强, 拥有更优的学习能力, 从而效果更好。但随着 d 的增大, 综合考虑模型性能增益多少与时间成本、计算资源消耗之间的冲突问题, 最终, 本文默认嵌入维度 d 的大小取 64。

5 结论与展望

本文提出一种基于双粒度序列融合的下一个兴趣点推荐方法 DGSF。首先, 该方法通过结合粗、细两种粒度序列信息对用户签到行为进行建模, 有效提取全局上下文信息。接着, 根据此信息对签到长序列进行“软划分”, 获得序列中蕴含的更加丰富的语义信息, 在一定程度上提升了“硬划分”方式带来的信息损失。最后, 对划分后的子序列信息进行有效聚合, 进一步突出有效信息, 实现下一个兴趣点的推荐。在两个真实数据集上进行实验的结果显示, 该模型在 Recall 与 NDCG 两个指标上均取得了较好的推荐效果。

在下一步的研究工作中, 本文将考虑加入与兴趣点签到相关的其他辅助信息, 例如用户社交关系、兴趣点实时热点和个性化评论信息等。基于更加丰富的签到全局上下文信息有助于进一步对用户签到行为建模, 从而可以最大限度准确预测用户下一步访问的兴趣点。

参考文献

- 胡琪, 朱定局, 吴惠彝, 等. 智能推荐系统研究综述. 计算机系统应用, 2022, 31(4): 47–58. [doi: 10.15888/j.cnki.csas.008403]
- Cheng C, Yang HQ, Lyu MR, et al. Where you like to go next: Successive point-of-interest recommendation. Proceedings of the 23rd International Joint Conference on Artificial Intelligence. Beijing: AAAI, 2013. 2605–2611.
- Rendle S, Freudenthaler C, Schmidt-Thieme L. Factorizing personalized Markov chains for next-basket recommendation. Proceedings of the 19th International Conference on World Wide Web. Raleigh: ACM, 2010. 811–820.
- Feng SS, Li XT, Zeng YF, et al. Personalized ranking metric embedding for next new POI recommendation. Proceedings of the 24th International Conference on Artificial Intelligence. Buenos: AAAI Press, 2015. 2069–2075.
- Ding RF, Chen ZZ, Li XL. Spatial-temporal distance metric embedding for time-specific POI recommendation. IEEE

- Access, 2018, 6: 67035–67045. [doi: [10.1109/ACCESS.2018.2869994](https://doi.org/10.1109/ACCESS.2018.2869994)]
- 6 申晋祥, 鲍美英. 基于卷积神经网络的评论文本兴趣点推荐算法. 计算机系统应用, 2022, 31(8): 314–318. [doi: [10.15888/j.cnki.csa.008614](https://doi.org/10.15888/j.cnki.csa.008614)]
- 7 安敬民, 李冠宇, 蒋伟, 等. 基于用户活动轨迹和个性化区域划分的兴趣点推荐. 计算机学报, 2022, 45(6): 1176–1194.
- 8 王兴源. 基于图嵌入和GRU的兴趣点推荐模型. 计算机系统应用, 2021, 30(10): 40–47. [doi: [10.15888/j.cnki.csa.008161](https://doi.org/10.15888/j.cnki.csa.008161)]
- 9 Liu Q, Wu S, Wang L, et al. Predicting the next location: A recurrent model with spatial and temporal contexts. Proceedings of the 30th AAAI Conference on Artificial Intelligence. Phoenix: AAAI, 2016. 194–200.
- 10 Luo YT, Liu Q, Liu ZC. STAN: Spatio-temporal attention network for next location recommendation. Proceedings of the 2021 Web Conference. Ljubljana: ACM, 2021. 2177–2185. [doi: [10.1145/3442381.3449998](https://doi.org/10.1145/3442381.3449998)]
- 11 Yang S, Liu JM, Zhao KQ. GETNext: Trajectory flow map enhanced Transformer for next POI recommendation. Proceedings of the 45th International ACM SIGIR Conference on Research and Development in Information Retrieval. Madrid: ACM, 2022. 1144–1153.
- 12 石美惠, 申德荣, 寇月, 等. 融合全局和局部特征的下一个兴趣点推荐方法. 软件学报, 2023, 34(2): 786–801. [doi: [10.13328/j.cnki.jos.006712](https://doi.org/10.13328/j.cnki.jos.006712)]
- 13 李全, 许新华, 刘兴红, 等. 融合时空感知GRU和注意力的下一个地点推荐. 计算机应用, 2020, 40(3): 677–682.
- 14 Liu YW, Pei AX, Wang F, et al. An attention-based category-aware GRU model for the next POI recommendation. International Journal of Intelligent Systems, 2021, 36(7): 3174–3189. [doi: [10.1002/int.22412](https://doi.org/10.1002/int.22412)]
- 15 Tobler WR. A computer movie simulating urban growth in the Detroit region. Economic Geography, 1970, 46: 234–240. [doi: [10.2307/143141](https://doi.org/10.2307/143141)]
- 16 Zhao KZ, Zhang Y, Yin HZ, et al. Discovering subsequence patterns for next POI recommendation. Proceedings of the 29th International Conference on International Joint Conferences on Artificial Intelligence. Yokohama: IJCAI, 2020. 445.
- 17 Chen ZY, Zhu YS, Zhao CY, et al. DPT: Deformable patch-based Transformer for visual recognition. Proceedings of the 29th ACM International Conference on Multimedia. New York: ACM, 2021. 2899–2907.
- 18 Xie JY, Chen ZZ. Hierarchical Transformer with spatio-temporal context aggregation for next point-of-interest recommendation. ACM Transactions on Information Systems, 2023, 42(2): 37.
- 19 Vaswani A, Shazeer N, Parmar N, et al. Attention is all you need. Proceedings of the 31st International Conference on Neural Information Processing Systems. Long Beach: Curran Associates Inc., 2017. 6000–6010.
- 20 Zhu Y, Li H, Liao YK, et al. What to do next: Modeling user behaviors by time-LSTM. Proceedings of the 26th International Joint Conference on Artificial Intelligence. Melbourne: AAAI Press, 2017. 3602–3608.
- 21 Zhao PP, Zhu HF, Liu YC, et al. Where to go next: A spatio-temporal gated network for next POI recommendation. Proceedings of the 33rd AAAI Conference on Artificial Intelligence. Honolulu: AAAI, 2019. 5877–5884.
- 22 Liu P, Guo YG, Li XX, et al. TADSAM: A time-aware dynamic self-attention model for next point-of-interest recommendation. Proceedings of the 1st International Workshop on Practical Deep Learning in the Wild. 2022.
- 23 Ren JY, Gan MX. Mining dynamic preferences from geographical and interactive correlations for next POI recommendation. Knowledge and Information Systems, 2023, 65(1): 183–206. [doi: [10.1007/s10115-022-01749-7](https://doi.org/10.1007/s10115-022-01749-7)]
- 24 朱建豪, 马文明, 王冰, 等. 融合时空网络和自注意力的兴趣点序列推荐. 计算机工程与设计, 2023, 44(2): 590–597.

(校对责编: 张重毅)