

基于图嵌入和 GRU 的兴趣点推荐模型^①



王兴源

(南京邮电大学 计算机学院, 南京 210046)

通讯作者: 王兴源, E-mail: 1218043325@njupt.edu.cn

摘要: 下一个兴趣点推荐是基于位置的社交网络 (Location-Based Social Network, LBSN) 的重要服务之一, 其不仅可以帮助用户寻找其感兴趣的目的地, 还能帮助商家提高潜在的收入. 目前已有算法提出采用用户行为序列信息以及兴趣点信息进行推荐, 但其没有很好地利用兴趣点辅助信息, 因此无法缓解冷启动与数据稀疏问题. 本文提出了一种基于图嵌入与 GRU (Gated Recurrent Unit) 的兴趣点推荐模型 GE-GRU (Graph Embedding-Gated Recurrent Unit). GE-GRU 首先通过图嵌入的方法, 将兴趣点本身与其辅助信息相融合, 得到信息丰富的深层次兴趣点向量, 再将其输入到神经网络中, 利用 GRU 对用户近期兴趣偏好进行建模得到用户 Embedding 表示, 最后根据兴趣点排序列表进行下一个兴趣点推荐. 本文在一个真实的数据集 Foursquare 中超过 48 万条签到记录上进行了实验, 采用 $Accuracy@k$ 指标进行评估, 实验结果表明, GE-GRU 相比于 GRU、LSTM (Long Short-Term Memory) 在 $Accuracy@10$ 上分别有 3% 和 7% 的提升.

关键词: 图嵌入; GRU; 兴趣点推荐; LBSN

引用格式: 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. <http://www.c-s-a.org.cn/1003-3254/8161.html>

POI Recommendation Model Based on Graph Embedding and GRU

WANG Xing-Yuan

(School of Computer Science, Nanjing University of Posts and Telecommunications, Nanjing 210046, China)

Abstract: The next Point-Of-Interest (POI) recommendation is one of the most important services of the Location-Based Social Network (LBSN). It can not only help users find the destination which they are interested in, but also improve the potential income of business providers. Existing algorithms have employed user behavior sequences and the POI information for recommendation, but none of them fully utilize POI side information, thereby failing to ease the problems of cold start and sparse data. In light of the above analysis, this study proposed a POI recommendation system, Graph Embedding-Gated Recurrent Unit (GE-GRU). Firstly, GE-GRU relies on Graph Embedding (GE) to integrate the POI itself with its side information to get the POI embedding that contains deep information. Then, the POI embedding is input into the GRU-based neural network to model recent user preferences to acquire user embedding. Finally, according to the POI rank list, the next POI can be recommended. Experiments are conducted on a real dataset, Foursquare, which contains more than 480 000 check-ins, and $Accuracy@k$ is adopted for evaluation. The results show that, compared with GRU and Long Short-Term Memory (LSTM), GE-GRU has 3% and 7% improvement on $Accuracy@10$, respectively.

Key words: Graph Embedding (GE); Gated Recurrent Unit (GRU); Point-Of-Interest (POI) recommendation; Location-Based Social Network (LBSN)

^① 收稿时间: 2021-01-09; 修改时间: 2021-02-08; 采用时间: 2021-03-11

随着移动设备、全球定位系统 (Global Position System, GPS) 和 Web 2.0 技术的迅速发展, 基于位置的社交网络 (Location-Based Social Network, LBSN) 逐渐在人们的日常生活中普及. 与传统的社交网络相比, LBSN 不仅包括了人与人之间的联系, 还可以共享人们之间的位置信息, 使得线上社交和线下社交相结合, 用户可以随时分享自己或浏览他人的足迹. 目前主流的社交应用 (如 Twitter、Foursquare、Gowalla 等) 都满足 LBSN 的主要特性. 这样的应用每天都在产生 TB 级别的时空数据, 其通常以 GPS 数据或签到数据 (check-ins) 的形式记录. 这些信息既是个人行为与偏好的体现^[1], 也在一定程度上反映了一座城市里人们的生活方式和移动模式. 基于以上数据, 多种类型的推荐被提出^[2], 其中兴趣点推荐为其重要研究方向之一.

如图 1 所示, 兴趣点推荐模型的方法主要分为传统推荐方法和深度学习推荐方法. 其中传统推荐方法可分为以下 5 种: (1) 协同过滤, 其基本思想为相似的用户有相似的兴趣, 通过相似度计算进行推荐. Ference 等^[3]综合考虑用户偏好, 社交因素以及地理位置, 在协同过滤的基础上提出了 UPS-CF 算法, 将本地居民和外地居民分开推荐. (2) 概率模型, 其认为用户-POI 签到矩阵分布符合特定的概率分布模型. Cheng 等^[4]基于对用户签到数据的观测, 发现其有家、公司等多个分布中心, 基于此提出了一个多中心高斯分布模型来进行推荐. (3) 矩阵分解, 其将用户签到矩阵分解为用户矩阵 U 和兴趣点矩阵 V , 从 U 和 V 中可以分别得到所有用户和兴趣点的潜在表示向量, 通过两种表示向量内积计算推荐评分. Cheng 等^[5]提出的基于矩阵分解和马尔科夫链的 FPMC-LR 模型, 依据矩阵分解学习所有用户的整体偏好, 通过兴趣点转移矩阵的马尔科夫链来挖掘出人们在时间维度的移动模式. (4) 基于链接的模型, 此类模型考虑用户与用户, 兴趣点与兴趣点, 用户与兴趣点之间的联系, 据此构建对应图进行推荐. Ying 等^[6]通过构建一个 HITS (Hyperlink Induced Topic Search) 为基础的模型, 将兴趣点推荐问题转化为用户-兴趣点的相关度问题. (5) 混合模型, 即综合考虑各个模型的优缺点, 一般采用两个模型进行联合推荐. Ye 等^[7]的 USG 模型中, 一方面通过协同过滤处理用户偏好以及朋友关系, 另一方面又采用幂律分布概率模型对地理因素进行建模, 最后将推荐的结果线性相加进行混合推荐. 张岐山等^[8]提出的 SoGeoCat 模型将

协同过滤和矩阵分解算法相结合, 根据用户相似性与潜在兴趣点进行建模, 克服了单一模型的不足, 缓解了数据稀疏的问题.

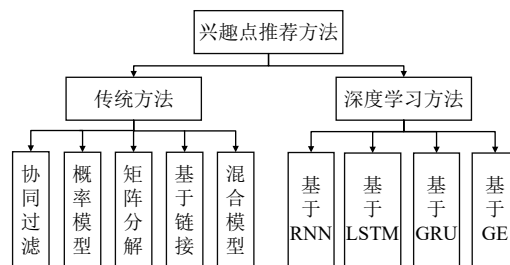


图 1 兴趣点推荐方法分类

深度学习的兴趣点推荐方法主要有以下 4 种: (1) 基于 RNN (Recurrent Neural Networks) 的方法. 由于近来 RNN 在自然语言处理领域表现优秀, 研究人员就尝试将其应用在任务相似的兴趣点推荐领域. Liu 等^[9]提出了 ST-RNN (Spatial-Temporal RNN) 时空循环神经网络模型, 此模型在普通的 RNN 基础上增加了时间转移矩阵和距离转移矩阵, 通过此方法, ST-RNN 能够捕捉时间因素和距离因素对人们移动轨迹的影响. (2) 基于 LSTM (Long Short-Term Memory) 的方法. LSTM 在其网络结构中引入了输入门, 遗忘门和输出门的概念, 解决了 RNN 在处理较长序列时产生的梯度消失问题. Zhao 等^[10]提出的 SLSTM 模型, 采用了堆叠 LSTM 和 Embedding 嵌入层来进行兴趣点推荐. 王立等^[11]提出的 POI-LSTM 推荐框架, 将用户信息、好友关系、POI 信息和评论信息进行 Embedding 化以后输入到 LSTM 神经网络中捕捉用户的兴趣变化趋势来进行推荐. Huang 等^[12]提出的 AT-LSTM 模型, 将时空信息融入模型中, 同时引入了注意力机制, 实现了高效的兴趣点推荐. Zhao 等^[13]提出的 STGN 模型, 基于 LSTM 与时空数据, 对 LSTM 每个 cell 的内部结构进行了修改优化, 使得推荐效果大幅度提高. (3) 基于 GRU (Gated Recurrent Unit) 的模型. 相比于 LSTM, GRU 因使用同一门控来控制需要遗忘和记忆的信息而大大减少了网络结构所需要的参数, 使得其计算代价变低了. (4) 基于图嵌入 (Graph Embedding, GE) 的模型. GE 通过对类似于用户-兴趣点这样的二分图进行学习, 得到低维的特征表示用作后续步骤的推荐. Xie 等^[14]通过对兴趣点-兴趣点图, 兴趣点-区域图, 兴趣点-时间图, 兴趣点-文字图进行学习, 分别研究了序列因素、地理因素、时间因素和语义因素对用户移动轨迹

的影响,通过计算用户移动轨迹之间的相似性来进行兴趣点推荐。

虽然上述的传统方法和深度学习方法在兴趣点推荐领域中取得了不错的成绩,但是他们没有对兴趣点本身附带的辅助信息进行很好的使用和融合,如兴趣点的种类,兴趣点的品牌等。本文提出了一种基于图嵌入的 GRU 兴趣点推荐方法 GE-GRU。该模型首先利用 GE 方法对 POI 本身及其辅助信息进行融合,得到了信息丰富的深层兴趣点 Embedding 表示信息,再将此 Embedding 信息输入到 GRU 网络中进行训练,最后利用用户 Embedding 和通过 GE 模型学习到的兴趣点 Embedding 进行推荐。相比于现有的模型,GE-GRU 一方面吸收了 GE 可以通过从图中学习出低维特征表示的优点,另一方面运用了 GRU 网络擅长捕捉序列依赖信息的特点,两者相结合,使得其在兴趣点推荐上表现良好。

本文的贡献点如下:

(1) 在数据预处理阶段,为了缓解数据稀疏问题,采用了扩充用户移动序列的数据增强方法。

(2) 对兴趣点及其辅助信息进行了融合处理,使得兴趣点表征信息更加丰富。

(3) 将 GE 图嵌入模型与 GRU 门控循环单元模型相结合,吸取了二者的优点,提高了兴趣点推荐效果。

后文组织如下:第1节介绍兴趣点推荐的问题定义以及 GE 和 GRU 的简介;第2节介绍 GE-GRU 兴趣点推荐模型的具体实现细节;第3节介绍数据集、数据预处理以及实验结果及分析;第4节总结概括全文。

1 相关背景

本节主要介绍模型的问题定义,和模型架构相关的基于图嵌入的模型和 GRU 网络结构。

1.1 问题定义

用 P 表示用户集合,用 Q 表示兴趣点集合。每个兴趣点 v 都有其相应的地理坐标 $\{x_v, y_v\}$, 辅助信息 $\{s_1, s_2, \dots, s_k\}$ 。对于用户 u , 其历史兴趣点访问序列为 $Q^u = \{q_{t_1}^u, q_{t_2}^u, \dots, q_{t_n}^u\}$, 其中, $q_{t_i}^u$ 表示用户 u 在时间 t_i 访问了兴趣点 q 。所有用户的兴趣点访问序列为 $Q^U = \{Q^{u_1}, Q^{u_2}, \dots, Q^{u_n}\}$ 。给定一个用户历史访问记录,模型的任务是预测在下一个特定的时间点 t 该用户最有可能去的兴趣点。

1.2 图嵌入简介

图广泛存在于真实世界的多种场景中,图即节点和边的集合,如社交网络中人与人之间的联系,兴趣点与兴趣点之间的关联。

图嵌入技术^[15]是一种将图数据,通常为高维稠密矩阵映射为低维稠密向量的过程,其习得的向量不仅能够保留图模型的结构信息和潜在的特征,还能够很好地解决图数据难以高效输入机器学习算法的问题。图嵌入将属性图转换为向量或者向量集,学习得到的嵌入数据捕捉了图的拓扑结构、顶点到顶点的关系以及关于图、子图和顶点的其他相关信息。

图嵌入技术的基础是 Word2Vec 算法^[16],其思想为:利用海量的文本序列,根据上下文单词预测目标单词共同出现的概率,构造出一个最优化的神经网络,此网络中的特定参数矩阵即单词的向量。Skip-gram 为 Word2Vec 的模型之一,如图 2 所示,其网络有输入层、隐层和输出层。网络的输入即每个单词的独热编码 (one-hot),独热编码是一个长度与单词字典相同的向量,除了其在字典的对应位置为 1 以外,其他都为 0,隐层没有激活函数,其输出为单词的嵌入表示,输出层为与预测单词邻域单词的 Softmax 分类器。由图 2 可以看出,Word2Vec 本质上是一种将单词从高维冗长的独热编码形式降维到含义丰富的低维表示向量。




图 2 Skip-gram 模型

图嵌入的方法主要分为 3 类^[15]: 1) 基于因子分解的方法; 2) 基于随机游走的方法; 3) 基于深度学习的方法。

法. DeepWalk^[17] 是典型的基于随机游走的方法, 其受 Word2Vec 启发, 首先选取某特定的点作为起点, 接着随机游走一定的步数, 得到序列, 将此序列视为句子输入到 Word2Vec 模型中进行训练, 得到图中每个点的表示向量, 该向量反映的是该点在途中的局部结构, 两个点在图中的共有近邻点越多, 其对应的两个向量之间的相似度就越高.

1.3 GRU 简介

GRU 是循环神经网络的一种, 其网络结构与 LSTM 类似, 都是为了解决长期记忆和反向传播中的梯度等问题而提出的, 而前者与后者不同之处在于, GRU 在使用了更少的门控单元的情况下能够达到与 LSTM 网络十分相当的效果, 因此 GRU 相比之下更加容易训练, 很大程度上提高了训练效率.

GRU 的每个 cell 结构如图 3 所示, 包括重置门 (reset gate), 更新门 (update gate) 和隐藏层. 重置门用来控制当前 cell 需要保留多少上个 cell 传递的记忆, 更新门在功能上实现了 LSTM 中遗忘门和输入门的功能, 其控制了需要从上个 cell 的隐藏层中遗忘多少信息, 和需要从当前 cell 的隐藏层中加入多少信息, 两者结合得到最后输出的隐藏层信息. GRU 的前向传播公式如下:

$$z_t = \sigma(W_z \cdot [h_{t-1}, x_t] + b_z) \quad (1)$$

$$r_t = \sigma(W_r \cdot [h_{t-1}, x_t] + b_r) \quad (2)$$

$$\tilde{h}_t = \tanh(W \cdot [r_t \times h_{t-1}, x_t] + b_{\tilde{h}}) \quad (3)$$

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

$$y_t = \sigma(W_o \cdot h_t + b_y) \quad (5)$$

其中, σ 表示 Sigmoid 函数, W 表示 GRU 网络结构中的各权重矩阵, h 表示隐藏层信息, b 表示偏置项, \tanh 表示输出的激活函数.

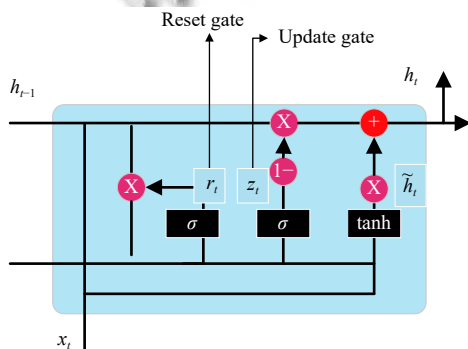


图 3 GRU 模块结构

2 模型介绍

现有的兴趣点推荐模型存在着数据稀疏与冷启动问题, 针对此问题, 本文提出了融合兴趣点与其辅助信息的思路. 兴趣点辅助信息指的是兴趣点名称, 兴趣点品牌以及兴趣点种类这些和兴趣点本身密切相关的信息. 现有的基于深度学习的兴趣点推荐模型只考虑对兴趣点本身进行学习, 而忽略了兴趣点辅助信息中所蕴含的信息. 通常, 有着相似辅助信息的兴趣点在 Embedding 空间中也会有着相似的 Embedding 表示. 基于这样的前提, 本文提出了采用 GE 方法学习出融合辅助信息的兴趣点 Embedding 表示, 再将融合了 Embedding 表示的用户序列信息输入到 GRU 神经网络中得到用户 Embedding 表示, 此用户 Embedding 和兴趣点 Embedding 进行内积运算, 得到该用户下一个可能去的兴趣点列表排序, 据此进行推荐.

本节将从兴趣点基础 Embedding 生成模型、改良 Embedding 生成模型, GE-GRU 模型网络结构 3 方面进行介绍.

2.1 基础 Embedding 生成模型

基于 GE 的 Embedding 生成模型主要采用了随机游走与 Word2Vec 的思想, 本小节将分 4 个步骤介绍该模型.

(1) 提取用户访问序列. 如图 4 所示, 对同一个用户来说, 如果其连续访问两个兴趣点的时间不超过 ΔT , 则这两次连续访问在同一个用户访问序列中.




图 4 提取用户序列

(2) 兴趣点-兴趣点有向图构造. 如图 5 所示, 根据步骤 (1) 已经提取完成的用户访问序列, 建立兴趣点-兴趣点有向图 G .

(3) 随机游走. 本步骤采用了 DeepWalk^[13] 的思想, 如图 6 所示, 根据步骤 (2) 已经建立好的有向图进行随机游走: 从一个节点出发, 按照一定的概率随机移动到其邻居节点, 并将该节点作为新的当前节点, 执行数次这样的步骤, 得到一条游走路径, 其中每次从当前节点 v_i 移动到其邻居节点 v_j 的概率如式 (6) 所示.

$$P(v_j|v_i) = \begin{cases} \frac{M_{ij}}{\sum_{j \in N_i} M_{ij}}, & v_j \in N_i \\ 0, & \text{other} \end{cases} \quad (6)$$

其中, M 为有向图 G 的邻接矩阵, M_{ij} 为从节点 v_i 指向节点 v_j 的边的权重, N_i 为节点 v_i 的所有外连邻居集合, 即如果有向图 G 中存在一条从 v_i 指向节点 v_k 的边, 那么 $v_k \in N_i$.




图5 构建有向图




图6 随机游走

(4) 生成兴趣点 Embedding. 此处采用了 Word2Vec 中 skip-gram 模型的思想, 将步骤 (3) 得到的游走序列看作文本数据输入到模型中, 其目的是最大化同一序列中两个节点之间共现的概率, 因此训练得出的这两个节点在 Embedding 空间中很接近. 如图 7 所示, 通常可以采用 output matrix 作为所有节点的 Embedding 集合.




图7 生成兴趣点 Embedding

2.2 改良 Embedding 生成模型

本小节主要介绍针对 2.1 节步骤 (4) 生成兴趣点 Embedding 的改良工作, 主要分为以下两点:

(1) 兴趣点与其辅助信息融合. 在 2.1 节步骤 (4) 中, 模型只利用了兴趣点本身的信息输入到网络中, 并没有利用到类似于兴趣点种类这样的辅助信息, 如此学习得出的兴趣点 Embedding 蕴含的信息比较单一, 不能够很好地缓解冷启动问题. 加入兴趣点辅助信息后, 神经网络能够挖掘出深层次的兴趣点信息, 让 Embedding 含义变得更加丰富.

此处采用 W_q^0 来表示兴趣点 q 本身的 Embedding 矩阵, 用 W_q^k 表示兴趣点 q 第 k 个辅助信息的 Embedding 矩阵. 此处融合采用平均池化的方式, 如式 (7) 所示.

$$E_q = \frac{1}{n+1} \sum_{k=0}^n W_q^k \quad (7)$$

E_q 为融合后的兴趣点 q 的 Embedding, 通过这样的方式, 在 Embedding 空间中, 辅助信息相似的兴趣点之间的距离就会比较相近, 缓解了兴趣点推荐中的冷启动问题.

(2) 在上述 (1) 中, 式 (2) 的融合方式是基于这样一个前提: 所有的辅助信息对于兴趣点 Embedding 的重要程度都是一致的. 这显然不符合实际, 例如某用户要前往健身房运动, 此时健身房的兴趣点种类 (运动) 要比健身房的品牌更加趋近于用户访问该兴趣点的原因. 因此, 不同的辅助信息对于兴趣点的重要程度是不一致的, 针对此, 本文提出了基于注意力机制的兴趣点辅助信息融合方法.

用 A 来表示权重矩阵, a_q^k 表示其第 q 个兴趣点的第 k 个辅助信息的权重, 其中 a_q^0 表示该兴趣点本身所占的权重. 根据不同辅助信息所占权重不同的基于注意力机制的融合方法如式 (8) 所示.

$$E_q = \frac{\sum_{k=0}^n e^{a_q^k} W_q^k}{\sum_{k=0}^n W_q^k} \quad (8)$$

2.3 GE-GRU 模型网络结构

如图 8 所示, GE-GRU 模型网络的整体架构分为 GE 和 GRU 所示, 首先通过 GE 训练出兴趣点的 Embedding 表示, 再将此 Embedding 表示当作基于 GRU 的网络中的 Embedding 层的初始化参数, 这一步

桥接了模型的两个部分,使得蕴含深层次信息的兴趣点 Embedding 能够顺利输入到 GRU 网络中进行训练,从而使得后续的神经网络能够拥有良好的输入,提高了训练的质量。




图8 GE-GRU 整体模型

具体的 GE 结构如图 9 所示, SI_0, SI_1, \dots, SI_n 表示兴趣点本身及其 n 个辅助信息,第 1 步对兴趣点及其辅助信息进行简单 Embedding 表示,第 2 步将各 Embedding 表示采用注意力机制,按式 (2) 的方式结合成新的兴趣点 Embedding。模型的最后一层是 sampled Softmax, Softmax 函数的一种变体。训练完成后,采用模型输出层的 output matrix 作为所有兴趣点 Embedding 的矩阵集合。

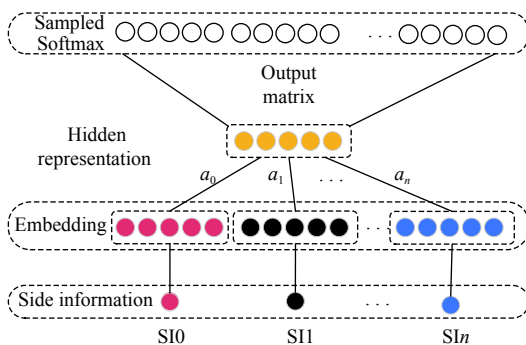


图9 GE 模块框架

2.4 损失函数

可将模型最终的任务看作一个多分类任务,即若该任务中共有 N 个兴趣点,每次推荐都是在进行一次 N 分类,挑选出评分排名最靠前的 k 个兴趣点进行推荐,而多分类的损失函数通常使用交叉熵损失函数来表示。

交叉熵能够衡量同一个随机变量中的两个不同概率分布的差异程度,在机器学习中就表示为真实的概率分布和预测的概率分布之间的差异,交叉熵的值越小,其模型预测效果就越好。在多分类问题中,交叉熵通常与 Softmax 函数一起出现,Softmax 函数将模型输

出的结果进行处理,使其所有分类的预测值和为 1,再通过交叉熵来计算损失。最终损失函数如式 (9) 所示。

$$L(p, q) = - \sum_{i=0}^n p_i \ln(q_i) \quad (9)$$

其中, q 为模型预测的概率分布,而 p 为真实的概率分布,模型的目的就是不断缩小预测的概率分布与真实的概率分布之间的差异,差异越小,实验效果就越好。

2.5 训练方法

经过数据预处理之后,整个数据集按时间顺序被分为了训练集和测试集。在本文实验的训练过程中,用户的单条序列为 $Q^u = \{q_{t_1}^u, q_{t_2}^u, \dots, q_{t_i}^u\}$,则模型输入为 $Q_{\text{input}} = \{q_{t_1}^u, q_{t_2}^u, \dots, q_{t_{i-1}}^u\}$,标签为 $q_{t_i}^u$ 用于验证模型的输出误差。

GE-GRU 每次单独处理一条分割好的序列,采用 mini-batch 梯度下降的方法对模型进行训练。batch_size 即每次训练的样本数量,当 batch_size 太小比如 1 时,每一个训练数据都要进行权值更新,这样就舍弃了向量化处理带来的加速;当 batch_size 太大如全部样本都算为一个 batch,全部数据训练完才进行一次权值更新,在数据量大时,单次迭代时间太长。综合考虑,本实验将 batch_size 定为 512,采用 Adam 优化器对损失函数进行优化。

Adam 优化器结合了 AdaGrad 和 RMSProp 两种优化器的优点,其实现简单,计算高效,对内存需求少;参数更新不受梯度伸缩变换的影响,并且非常适用于大规模的数据以及参数的场景,十分符合本文的需求。

3 实验

3.1 数据集介绍

本文使用的 Foursquare 数据集^[18]是一个典型的基于位置的社交网络数据集,时间跨度从 2010 年 4 月至 2011 年 9 月,地理范围集中在美国加利福尼亚州。具体数据如表 1 所示。

表1 Foursquare 数据集参数

| 参数 | 数值 |
|------------|---------|
| 用户数 | 4163 |
| 兴趣点数 | 121 142 |
| Check-ins数 | 483 813 |

3.2 数据预处理

本文采用了 Cheng 等^[5]的方法对用户访问序列做了分割处理,即将同一用户访问序列中,如果连续两次

访问之间的时间间隔不超过 6 h, 则将其编入同一序列之中, 若超过 6 h, 则编入不同序列中。同时, 为了防止不活跃用户与不活跃兴趣点对数据集的影响, 本文还过滤掉了总 check-ins 数少于 5 条的用户和兴趣点, 以及对用户序列分割后少于 5 条访问序列的用户。

为了缓解数据稀疏的问题, 本文采用了 Tan 等^[19]的方法, 具体为: 给定原始序列 $Q^u = \{q_{t_1}^u, q_{t_2}^u, \dots, q_{t_i}^u\}$, 那么其所有前缀序列如 $\{q_{t_1}^u, q_{t_2}^u\}, \{q_{t_1}^u, q_{t_2}^u, q_{t_3}^u\}, \dots, \{q_{t_1}^u, q_{t_2}^u, \dots, q_{t_{i-1}}^u\}$ 都视作该用户的一条新访问序列。先按时间顺序将每个用户所有访问序列排序, 将前 70% 的序列作为训练集 D_{train} , 后 30% 的序列作为测试集 D_{test} 。

如表 2 所示, 在数据增强前, 数据集提取出的有效用户移动序列数为 13 830 条, 数据增强后, 序列总数扩充到了 119 142 条。深度学习的特性是样本数量越多, 其效果越明显。在数据增强前, 总样本数量仅有 13 830 条, 用于训练的样本数量仅有 9681 条, 样本太少的情况下, 神经网络几乎无法学习出隐藏于序列中的知识, 所以实验效果很差。

表 2 样本数量对比

| 条件 | 样本数量 |
|-------|---------|
| 数据增强前 | 13 830 |
| 数据增强后 | 119 142 |

3.3 Baseline 方法介绍

(1) FPMC-LR^[5]: 基于矩阵分解和马尔科夫链的兴趣点推荐模型, 依据矩阵分解学习所有用户的整体偏好, 通过兴趣点转移矩阵的马尔科夫链来挖掘出人们在时间维度的移动模式。

(2) LSTM^[20]: 长短期记忆网络, 通过遗忘门来选择

性遗忘上个 cell 传入的信息, 通过输入门来选择需要记忆多少当前 cell 中新的信息, 通过输出门输出隐层信息。

(3) GRU^[21]: 门控循环单元, 整体结构与 LSTM 类似, 不同之处在于其将遗忘门和输入门合二为一成更新门。

3.4 评价指标

本文采用了兴趣点推荐中常用的 $Accuracy@k$ 指标来评价实验结果, 具体定义如下:

在某一次推荐中, 计算所有兴趣点的排序分数, 按照从高到底编入一个列表, 其中真实标签兴趣点所在的排序位置为 m , 如果 $m \leq k$, 则称该次推荐命中, 记为 $hit = 1$, 否则 $hit = 0$ 。最终结果如式 (10) 所示。

$$Accuracy@k = \frac{hit@k}{|D_{\text{test}}|} \quad (10)$$

3.5 实验结果分析

本文采用 $Accuracy@1$, $Accuracy@5$, $Accuracy@10$, $Accuracy@15$, $Accuracy@20$ 五种评价标准。实验结果如表 3 所示。

相较于传统推荐方法 FPMC-LR 与深度学习推荐方法 LSTM、GRU, GE-GRU 在 Foursquare 数据集上效果最优, 在 $Accuracy@10$ 这一指标上, GE-GRU 的效果为 0.467, 优于 GRU 3%, 优于 LSTM 7%。在其他 $Accuracy$ 指标上, 仅在 $Accuracy@20$ 上, GE-GRU 效果稍逊于 FPMC-LR, 且相差不多。在 k 越来越大时, 其同时推荐的兴趣点个数也增加了, 推荐成本也增加了。这说明在将序列数据输入到 GRU 网络之前, 通过 GE 学习得出的兴趣点 Embedding, 在很好地融合了其辅助信息后, 挖掘出了兴趣点深层次的信息, 使得兴趣点 Embedding 蕴含的内容更加丰富, 从而让用户访问序列表示更加准确。

表 3 对比实验

| 方法 | $Accuracy@1$ | $Accuracy@5$ | $Accuracy@10$ | $Accuracy@15$ | $Accuracy@20$ |
|---------|--------------|--------------|---------------|---------------|---------------|
| FPMC-LR | 0.112 | 0.296 | 0.394 | 0.519 | 0.575 |
| GRU | 0.139 | 0.360 | 0.452 | 0.482 | 0.510 |
| LSTM | 0.142 | 0.353 | 0.434 | 0.484 | 0.511 |
| GE-GRU | 0.142 | 0.368 | 0.467 | 0.521 | 0.556 |

4 结论

本文在基于位置的社交网络背景下, 采用了数据增强方法, 丰富了用户访问序列数量, 通过图嵌入技术对兴趣点及其辅助信息在注意力机制下融合, 得到的兴趣点 Embedding 挖掘出了深层次的信息, 将此 Embedding 输入到 GRU 中能够捕捉到用户近期偏好。实

验结果表明, 本文的 GE-GRU 方法能够有效地提升兴趣点推荐的准确率, 并且能够缓解数据稀疏与冷启动的问题。

参考文献

- Ye Y, Zheng Y, Chen YK, et al. Mining individual life

- pattern based on location history. Proceedings of 2009 Tenth International Conference on Mobile Data Management: Systems. Taipei: IEEE, 2009. 1–10.
- 2 Bao J, Zheng Y, Wilkie D, *et al.* Recommendations in location-based social networks: A survey. *Geoinformatica*, 2015, 19(3): 525–565. [doi: [10.1007/s10707-014-0220-8](https://doi.org/10.1007/s10707-014-0220-8)]
 - 3 Ferenc G, Ye M, Lee WC. Location recommendation for out-of-town users in location-based social networks. Proceedings of the 22nd ACM International Conference on Information & Knowledge Management. San Francisco: ACM, 2013. 721–726.
 - 4 Cheng C, Yang HQ, King I, *et al.* Fused matrix factorization with geographical and social influence in location-based social networks. Proceedings of the Twenty-Sixth AAAI Conference on Artificial Intelligence. Toronto: AAAI Press, 2012. 17–23.
 - 5 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 Press, 2013. 2605–2611.
 - 6 Ying JJC, Kuo WN, Tseng VS, *et al.* Mining user check-in behavior with a random walk for urban point-of-interest recommendations. *ACM Transactions on Intelligent Systems and Technology*, 2014, 5(3): 40.
 - 7 Ye M, Yin PF, Lee WC, *et al.* Exploiting geographical influence for collaborative point-of-interest recommendation. Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval. Beijing: ACM, 2011. 325–334.
 - 8 张岐山, 李可, 林小榕. LBSN 中融合类别信息的混合推荐模型. *计算机系统应用*, 2019, 28(1): 200–206. [doi: [10.15888/j.cnki.csa.006722](https://doi.org/10.15888/j.cnki.csa.006722)]
 - 9 Liu Q, Wu S, Wang L, *et al.* Predicting the next location: A recurrent model with spatial and temporal contexts. Proceedings of the Thirtieth AAAI Conference on Artificial Intelligence. Phoenix: AAAI Press, 2016. 194–200.
 - 10 Zhao SL, Chen XX, King I, *et al.* Personalized sequential check-in prediction: Beyond geographical and temporal contexts. Proceedings of 2018 IEEE International Conference on Multimedia and Expo. San Diego: IEEE, 2018. 1–6.
 - 11 王立, 张谧. 基于 LSTM 的 POI 个性化推荐框架. *计算机系统应用*, 2018, 27(12): 56–61. [doi: [10.15888/j.cnki.csa.006530](https://doi.org/10.15888/j.cnki.csa.006530)]
 - 12 Huang LW, Ma YT, Wang SB, *et al.* An attention-based spatiotemporal LSTM network for next POI recommendation. *IEEE Transactions on Services Computing*, 2019: 1–14.
 - 13 Zhao PP, Luo AJ, Liu YC, *et al.* Where to go next: A spatio-temporal gated network for next POI recommendation. *IEEE Transactions on Knowledge and Data Engineering*, 2020: 1–13.
 - 14 Xie M, Yin HZ, Wang H, *et al.* Learning graph-based POI embedding for location-based recommendation. Proceedings of the 25th ACM International on Conference on Information and Knowledge Management. Indianapolis: ACM, 2016. 15–24.
 - 15 Goyal P, Ferrara E. Graph embedding techniques, applications, and performance: A survey. *Knowledge-Based Systems*, 2018, 151: 78–94. [doi: [10.1016/j.knosys.2018.03.022](https://doi.org/10.1016/j.knosys.2018.03.022)]
 - 16 Mikolov T, Chen K, Corrado G, *et al.* Efficient estimation of word representations in vector space. arXiv: 1301.3781, 2013.
 - 17 Perozzi B, Al-Rfou R, Skiena S. DeepWalk: Online learning of social representations. Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2014. 701–710.
 - 18 Yin HZ, Zhou XF, Shao YX, *et al.* Joint modeling of user check-in behaviors for point-of-interest recommendation. Proceedings of the 24th ACM International on Conference on Information and Knowledge Management. Melbourne: ACM, 2015. 1631–1640.
 - 19 Tan YK, Xu XX, Liu Y. Improved recurrent neural networks for session-based recommendations. Proceedings of the 1st Workshop on Deep Learning for Recommender Systems. Boston: ACM, 2016. 17–22.
 - 20 Hochreiter S, Schmidhuber J. Long short-term memory. *Neural Computation*, 1997, 9(8): 1735–1780. [doi: [10.1162/neco.1997.9.8.1735](https://doi.org/10.1162/neco.1997.9.8.1735)]
 - 21 Chung J, Gulcehre C, Cho K, *et al.* Empirical evaluation of gated recurrent neural networks on sequence modeling. arXiv: 1412.3555, 2014.