

欧阳锦涛, 陈俊, 杨硕, 等. 基于神经网络的位置感知兴趣点推荐算法研究[J]. 智能计算机与应用, 2025, 15(12): 94-99.
DOI: 10.20169/j.issn.2095-2163.24052301

基于神经网络的位置感知兴趣点推荐算法研究

欧阳锦涛¹, 陈俊¹, 杨硕¹, 张祯²

(1 沈阳化工大学 计算机科学与技术学院 沈阳 110142; 2 营口理工学院 电气工程学院, 辽宁 营口 115014)

摘要: 随着位置服务技术的飞速发展, 基于位置的社交网络(Location-Based Social Networks, LBSN)的兴趣点(Points Of Interest, POI)推荐逐渐成为研究热点。尽管传统的机器学习方法在POI推荐上取得了一定成效, 但如何充分考虑地理位置、用户行为模式和上下文信息, 并有效解决签到数据稀疏性问题, 仍是当前面临的重要挑战。本文针对此问题, 提出一种融合深度学习策略的位置感知推荐算法, 运用了长短期记忆网络(Long Short-Term Memory Networks, LSTM)这一递归神经网络变体, 将其与地理信息紧密结合, 构建出Geo-LSTM模型。该模型能够捕捉用户的时空行为模式, 并利用地理位置信息增强推荐效果。实验证明, 将Geo-LSTM应用在Foursquare和 Gowalla等公开大规模数据集上时, 不仅能够在好友推荐中体现用户的社交关联性和空间邻近性, 在兴趣点推荐方面也表现出了显著优势, 体现在显著提升的召回率和精确率指标上, 从而证实了Geo-LSTM在位置感知推荐系统中的有效性和优越性。

关键词: 基于位置社交网络; 兴趣点推荐; 位置感知; 长短期记忆网络; 时空行为模式

中图分类号: TP391.1 **文献标志码:** A **文章编号:** 2095-2163(2025)12-0094-06

Research on location aware interest point recommendation algorithm based on neural networks

OUYANG Jintao¹, CHEN Jun¹, YANG Shuo¹, ZHANG Zhen²

(1 School of Computer Science and Technology, Shenyang University of Chemical Technology, Shenyang, 110142, China;
2 School of Electrical Engineering, Yingkou Institute of Technology, Yingkou 115014, Liaoning, China)

Abstract: The rapid development of location services, points of interest (POI) recommendation in location-based social networks (LBSN) has gradually become a research hotspot. Traditional machine learning methods have achieved some success in POI recommendation, but how to fully consider geographical location, user behavior patterns, and contextual information, and effectively solve the problem of sparse check-in data, remains an important challenge. This paper proposes a location-aware recommendation algorithm that integrates deep learning strategies. It uses a variant of recurrent neural networks, long short-term memory networks (LSTM), and closely integrates it with geographic information to construct a Geo-LSTM model. This model can capture the temporal and spatial behavior patterns of users and use geographic location information to enhance the recommendation effect. Experiments have shown that when applied to publicly available large-scale datasets such as Foursquare and Gowalla, Geo-LSTM not only reflects users' social relevance and spatial proximity in friend recommendations, but also demonstrates significant advantages in POI recommendations, as reflected in significantly improved recall and precision metrics, thus confirming the effectiveness and superiority of Geo-LSTM in location-aware recommendation systems.

Key words: location-based social networks; point of interest recommendation; location-aware; LSTM; Spatio-temporal behavior patterns

0 引言

随着LBSN的广泛应用, 兴趣点(POI)推荐也

逐渐被广泛关注^[1-2]。人类在线上与线下行为间的地理关联性为兴趣点推荐带来了丰富的信息维度, 如何有效利用这种地理位置动态变化对POI推荐

基金项目: 辽宁省教育厅青年基金(LJKQZ2021184); 辽宁省自然科学基金(2022-YKLH-18, 2023-MSLH-311); 营口理工学院重点研究项目基金(ZDIL202305)。

作者简介: 欧阳锦涛(1998—), 男, 硕士研究生, 主要研究方向: 兴趣点推荐; 陈俊(1999—), 男, 硕士研究生, 主要研究方向: 数据挖掘; 杨硕(1983—), 男, 博士, 讲师, 主要研究方向: 计算机视觉。

通信作者: 张祯(1991—), 女, 博士, 副教授, 主要研究方向: 基于位置社交网络分析与挖掘。Email: zhangzhen@yku.edu.cn。

收稿日期: 2024-05-23

效果进行优化,成为当前研究的关键桥梁。传统推荐策略大多依赖于用户-项目或用户-用户间的静态相似度分析,仅基于历史兴趣偏好构建模型。然而,用户的兴趣偏好具有显著的时间和空间维度变化特性,如季节、天气等因素会引发用户对不同类型地点的兴趣转变。例如,在寒冷季节中用户可能倾向于火锅店等暖食场所,而气温升高时,这些选择可能会发生改变^[3]。因此,时序性和地理位置因素在 POI 推荐中的作用不容忽视。

影响兴趣点推荐的特征信息主要包括时空、语义、类别、兴趣偏好、社会互动、地理定位等,大多数研究都是依据上述特征进行推荐。Ye 等^[4]融入了社会影响力和地理因素到协同过滤框架内,利用幂律分布刻画 POI 间距离效应,与用户偏好相结合,构建了一个朴素贝叶斯推荐模型,但该模型仍面临数据稀疏性挑战,影响了协同过滤的效果。Cheng 等^[5]则通过整合多中心高斯模型与矩阵分解,同时考虑地理位置和社会关系,以解决先前模型忽视地理因素导致推荐效果欠佳的问题。任星怡等^[6]通过建立一个综合多因素的联合概率生成模型,有效解析了签到行为背后的复杂动因,有效缓解了数据稀疏性问题。Zhao 等^[7]创新性地引入了评分进度表概念及人际关系评分因子,将用户个人偏好、社交圈兴趣相似度等维度集成于矩阵分解框架中。Ren 等^[8]综合考虑用户历史签到、好友签到频次的幂律分布、地理位置影响及时序特性,提升了签到预测的准确性。彭宏伟等^[9]采用矩阵分解处理签到数据,综合考虑用户行为、POI 位置、社交网络信息及类别标签,有效减轻了数据稀疏问题。Li 等^[10]为了解决数据稀疏和冷启动问题,借助用户社交圈信息,细分好友类型,提出了一种混合多种签到信息的矩阵分解方法。Xiong 等^[11]则针对 LBSN 数据稀疏、信息不完整及用户偏好的多样性,综合分析地理位置、社会互动、用户行为等多种信息,设计了基于异构信息的潜在概率生成模型以提升推荐精准度。这些研究共同展示了在兴趣点推荐中综合考虑社会与地理位置信息的重要性,并通过创新算法设计努力克服数据稀疏性和提高推荐系统性能。Sun 等^[12]考虑了用户兴趣偏好对下一个兴趣点的影响,将用户的偏好分成稳定偏好和不稳定偏好,利用 LSTM 对用户的偏好进行建模,用户的历史数据可以用来对长期偏好建模而近期数据用来对短期偏好建模。Fang 等^[13]基于多图融合实现兴趣点推荐,基于用户的评分数据构建用户 POI 交互图,考虑用户的一阶好友

和高阶好友,利用图神经网络进行推荐。Liu 等^[14]通过 LDA 从评论中生成用户主题分布和项目主题分布,利用深度学习和矩阵分解进行深度语义分析,提升推荐性能。Li 等^[15]考虑人们签到的时间、空间以及类别特性建立 3 个模型综合推荐。

近年来,递归神经网络 (Recurrent Neural Network, RNN) 在推荐系统领域的应用逐渐兴起,人们意识到用户的行为序列中蕴含着潜在模式。尽管 RNN 在诸如语言建模等序列数据处理任务上表现出色,但其通常未充分考虑时间序列中兴趣偏好的动态演变及地理情境的影响。在 RS 领域,用户之间的地理位置关系是揭示互动规律的重要线索,而常规 RNN 架构对此类信息的建模能力有限^[16]。

本文创新性地提出了一种融合地理位置信息的 LSTM 变体——Geo-LSTM 模型。该模型通过引入专门设计的地理信息门控机制,以模拟并捕捉用户随时间和地理环境变迁的行为序列特征。相较于传统的 RNN 方案,Geo-LSTM 不仅充分利用了 RNN 对于有序序列数据的强大建模能力,还成功整合了地理信息这一关键要素,从而更准确地预测和捕捉用户的动态兴趣偏好。

1 任务定义

在本研究中,将用户集合记为 $U = \{u_1, u_2, u_3, \dots\}$, 而兴趣点集合表示为 $P = \{p_1, p_2, p_3, \dots\}$ 。针对任意单个用户 $u \in U$, 其历史签到记录集 H_u 可被定义如下:

$$H^u = [(p_1^u, g_1^u), (p_2^u, g_2^u), \dots, (p_{n_u}^u, g_{n_u}^u)] \quad (1)$$

其中,对于每一个 $m \in \{1, 2, \dots, n_u\}$, p_m^u 代表用户 u 在兴趣点 p 的第 m 次签到记录, (p_m^u, g_m^u) 则意味着用户 u 在其第 m 次签到时的位置信息是 g 。

本文的核心任务是在给定一组特定用户子集 u_a 及一系列地理位置信息 g_b , 并基于这些信息,通过构建和应用推荐模型,从而生成一个从总体兴趣点集合 P 中提取出的、具有针对性的兴趣点推荐列表 $P_l \subseteq P$ 。

2 相关理论

2.1 RNN

在与传统模型的对比中,RNN 的独特之处在于其对序列数据的内在考量。典型的 RNN 结构包含 3 层:底层为输入部分主要负责处理序列数据,其中的核心隐藏部分位于中间层,而最高的部分则是输出部分生成预测结果。这一架构直观地体现了

RNN 的关键特征,即输出层的计算结果会循环反馈至隐藏层作为下一轮迭代的输入信号^[17]。

2.2 LSTM

LSTM 是一种 RNN 的创新变体,其在隐藏层结构上做出了显著改进。不同于常规 RNN, LSTM 的隐藏层被设计为多个存储单元(Memory Block)的集合,这些单元通常简称为 block。每一个 block 内部又嵌套了一个关键组件——记忆细胞(Memory Cell),简称 cell^[18]。值得注意的是,每个 cell 采用了独特的三重门控机制。图 1 展示了 LSTM 的基础构造,从该图中可以清楚地辨识出,每个记忆细胞内含有的 3 个功能性门分别是:输入门(Input Gate),负责控制新信息的写入;遗忘门(Forget Gate),用于决定哪些历史信息应当舍弃;以及输出门(Output Gate),其管控着传递至后续层或者作为当前时间步输出的有效信息内容。

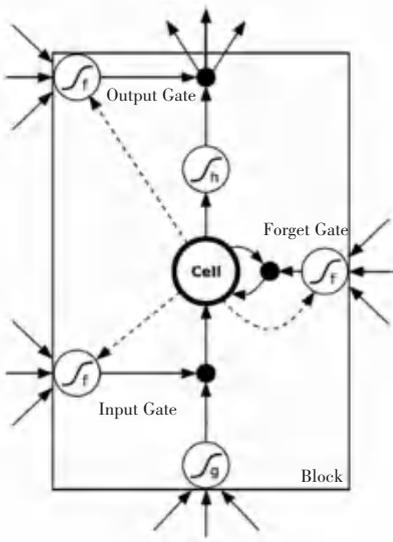


图 1 LSTM 基础结构示意图

Fig. 1 Schematic diagram of LSTM structure

2.3 Geo-LSTM 模型

在 LSTM 模型的原有框架上,本文创新性地提出了 Geo-LSTM 模型,其独特之处在于增设了一个地理信息门(Geographical Factor Gate, Geo Gate),记为 G_m ,从而使模型拥有了总计 4 个门控机制。Geo-LSTM 模型的整体架构如图 2 所示,新增加的地理因子门与其他 3 个经典的门结构并列存在;输入门(Input Gate)、输出门(Output Gate)以及遗忘门(Forget Gate)。

模型的核心计算组件包括这 4 个门控单元的计算、记忆细胞的状态更新过程,以及最终的输出生成。接下来将逐一详解各个门的计算方式以及记忆

细胞状态更新的具体算法。

首先,通过下式可以得到输入门的计算表达式:

$$i_m = \sigma_i(\mathbf{x}_m \mathbf{W}_{xi} + \mathbf{h}_{m-1} \mathbf{W}_{hi} + w_{ci} \odot c_{m-1} + b_i) \quad (2)$$

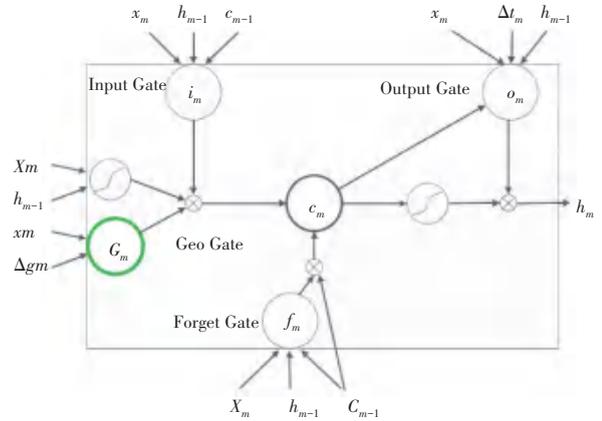


图 2 Geo-LSTM 结构图

Fig. 2 Geo LSTM structural diagram

在 LSTM 模型中, i_m 代表的是当前对象的输入门变量,通过计算上一时刻输出向量 \mathbf{h}_{m-1} 与当前输入特征向量 \mathbf{x}_m 的加权和来确定。其中, \mathbf{W}_{xi} 表示与输入特征向量相关的权重矩阵,而 \mathbf{W}_{hi} 则是对应于前一时刻输出向量的权重矩阵。另外, \mathbf{h}_{m-1} 反映了前一个时间步长的隐藏层输出状态; w_{ci} 是用于连接到上一次 cell 状态 c_{m-1} 的特定权重参数, c_{m-1} 存储了前一时刻细胞的状态信息;同时, b_i 代表了应用于输入门计算的偏置项。整个输入门的激活函数采用 Sigmoid 函数 (σ_i),其数学表达形式如下式:

$$S = \frac{1}{1 + e^{-x}} \quad (3)$$

该函数以其特有的 S 型曲线对加权和进行非线性转换,以确保结果映射到 0~1 之间,实现对输入信号的有效控制。

遗忘门的计算是通过应用下式来实现:

$$f_m = \sigma_f(\mathbf{x}_m \mathbf{W}_{xf} + \mathbf{h}_{m-1} \mathbf{W}_{hf} + w_{cf} \odot c_{m-1} + b_f) \quad (4)$$

其中, f_m 代表当前对象所对应的遗忘门变量,其通过对前一时刻输出向量 \mathbf{h}_{m-1} 和当前输入特征向量 \mathbf{x}_m 分别乘以各自的权重矩阵 \mathbf{W}_{xf} 和 \mathbf{W}_{hf} ,再进行加权和运算后得出的结果; \odot 表示逐元素乘积运算; \mathbf{h}_{m-1} 表示上一步骤的隐藏层输出状态; w_{cf} 是连接到上一次 cell 内部存储信息 c_{m-1} 的特定权重参数; c_{m-1} 记录了前一个时间步长细胞的状态记忆; b_f 则是与遗忘门计算相关的偏置项。遗忘门的激活函数同样采用了 Sigmoid 函数 (σ_f),该函数以其 S 型曲线特性对上述加权和结果进行非线性变换,使得最终得到的遗忘门值范围限制在 0~1 之间,从而有

效地控制哪些先前存储的信息应当被保留或遗忘。

在 Geo-LSTM 模型中, 第 m 个对象的内存细胞内容 c_m 的更新过程是通过整合多个门控机制以及地理信息来实现的, 具体计算公式如下式:

$$c_m = f_m \odot c_{m-1} + i_m \odot G_m \odot \sigma_c(x_m W_{xc} + h_{m-1} W_{hc} + b_c) \quad (5)$$

其中, c_m 代表当前时间步 m 的内存细胞状态; f_m 为遗忘门在时间步 m 的输出值, 决定了上一时间步存储的信息 c_{m-1} 保留多少; i_m 则是输入门在时间步 m 的输出值, 控制新输入信息如何影响当前细胞状态; 而 G_m 即为地理因子门, 其计算细节可在公式 (5) 中查阅, 其利用了地理位置信息以进一步调整细胞状态更新。tanh 函数 (记为 σ_c) 的定义见公式 (6), 用于非线性转换。 x_m 是输入特征向量, W_{xc} 和 W_{hc} 分别代表与输入特征和前一时刻隐藏层输出相关的权重矩阵; h_{m-1} 则为前一次循环的输出向量, b_c 则是对应的偏置项。

至于地理信息门 G_m , 在公式 (6) 中的表达, 采用了 Sigmoid 函数 (记作 σ_g) 进行运算, 并将地理位置间的距离 Δg 作为重要考量因素, 同时结合权重 W_{xg} 、偏置项 b_g 对地理信息进行编码处理。

$$G_m = \sigma_g(x_m W_{xg} + \sigma_{\Delta g}(\Delta g_m W_{xg}) + b_g) \quad (6)$$

$$\tanh = \frac{\sinh x}{\cosh x} = \frac{e^x - e^{-x}}{e^x + e^{-x}} \quad (7)$$

输出门计算公式:

$$o_m = \sigma_o(x_m W_{xo} + \Delta g_m W_{go} + h_{m-1} W_{ho} + w_{co} \odot c_m + b_o) \quad (8)$$

在 Geo-LSTM 模型中, 第 m 个对象的最终输出向量 h_m 是通过其输出门 o_m 控制细胞内容 c_m 线性投影后的结果。 o_m 是在时间步 m 时计算出的输出门值, 由 Sigmoid 函数 σ_o 进行激活, Sigmoid 函数用于生成 0~1 之间的输出, 决定有多少细胞状态信息将被传递至当前时间步的输出。

下式详细描述了输出 h_m 的计算方法:

$$h_m = o_m \odot \sigma_h(c_m) \quad (9)$$

在 Geo-LSTM 模型中, h_m 代表当前时间步 m 的输出向量; o_m 则特指该时间步对象所对应的输出门; σ_h 是 tanh 函数; x_m 是当前输入特征向量。

在分析 Geo-LSTM 与经典 LSTM 之间的关系时, 可以注意到公式 (2)、(4) 和 (9) 沿用了标准 LSTM 结构中的核心更新规则。然而, Geo-LSTM 的独特之处在于其对地理信息的整合, 具体体现为引入了地理因子门 G_m 这一概念。首先, 细胞状态 c_m 的更新不仅受到输入门 i_m 的影响, 还结合了地理

因子门 G_m 的信息过滤, 使得特征整合更为全面; 其次, 通过将地理距离变化 Δg_m 存储于 G_m 中, 并逐步传递到后续时间步的细胞状态 c_{m+1} 、 c_{m+2} 等, 有效地模拟了用户基于地理位置的长期行为偏好, 从而提升了推荐系统的性能和准确性。

3 实验与分析

3.1 数据集

本文的研究实验在两个公开且广泛使用的位置签到数据集上进行, 表 1 统计了两个数据集预处理后的用户数、PDI 数、签到记录数, 数据清晰准确。

Foursquare 数据集: 该数据集涵盖了从 2012 年 4 月至 2013 年 9 月期间纽约和东京市用户的签到记录。为了保证实验的有效性和可靠性, 在实验准备阶段, 对原始数据进行了预处理步骤, 排除了签到次数低于 10 次的用户和未达 10 次访问频次的 POI。

Gowalla 数据集: 此数据集记录了自 2009 年 2 月至 2010 年 10 月全球 Gowalla 用户的签到行为。同样地, 在实验前, 对该数据集进行了预处理操作, 将签到次数低于 10 次的用户及被访问次数少于 15 次的 POI 从数据集中移除。经筛选后, 获得数据, 见表 1。

表 1 预处理后数据集

Table 1 Preprocessed Dataset

数据集	用户数	POI 数	签到记录数
Foursquare	24,941	28,593	1,196,248
Gowalla	18,737	32,510	1,278,274

3.2 对比方法

在本研究实验中, 选取了当前广泛应用且具有代表性的 4 种算法——LRT^[18]、GeoMF^[19]、GeoPFM^[20] 以及 RankGeoFM^[21] 作为对比的基准模型, 以评估本文新型模型的性能表现。对于 Geo-LSTM 模型, 学习率设定为 0.001, 批次大小为 128, 迭代次数为 500 次, 平衡学习效率与模型收敛性。而对于对比基准模型, 则依据原始论文的参数设置, 以确保实验结果的可复现性和公平性。

3.3 实验结果与分析

在 Gowalla、Foursquare 公开数据集上运用本模型进行实验, 设定推荐给用户的 POI 数量分别为 5、10、20 和 50。同时, 对比模型 LRT、GFM、GeoPFM 以及 RankGeoFM 采用相同的推荐个数阈值进行了相似的实验。实验结果, 推荐精确度如图 3、图 4 所示, 召回率如图 5、图 6 所示。

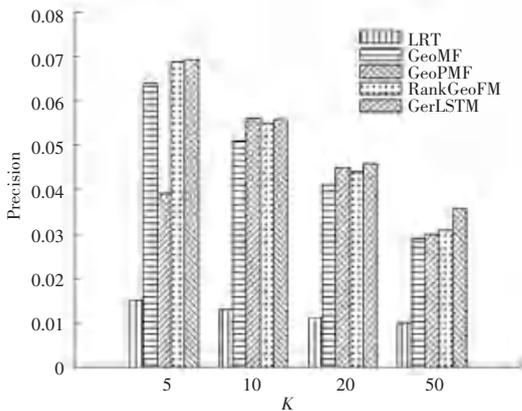


图 3 Gowalla 数据集上的精确度

Fig. 3 Accuracy rates on the Gowalla dataset

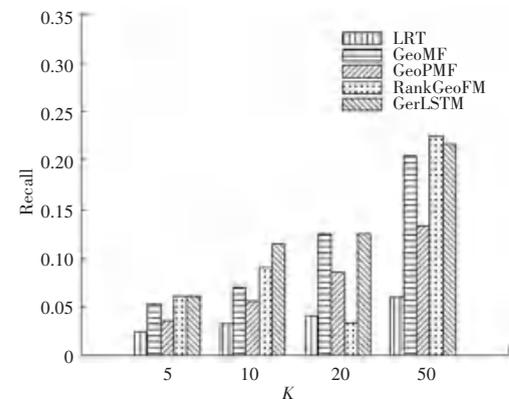


图 5 Gowalla 数据集上的召回率

Fig. 5 Recall rates on the Gowalla dataset

从实验结果可以看出,无论是在 Gowalla 还是在 Foursquare 数据集上,本文提出的模型均表现出优于其他基础模型的精确度和召回率。其中,LRT 模型的表现最为逊色。通过对 LRT 模型输入特性的深入分析,认为其推荐效果较差的原因在于未考虑地理信息这一关键因素;而其他对比模型成功地结合了地理位置信息,在推荐性能上取得了更好的效果。

此外,在分析实验结果时,发现 RankGeoFM 模型相较于其他对比模型表现出了整体优势。这一现象的原因在于 RankGeoFM 采用了不同于常规损失函数的设计思路,其引入了排序关系,并将序列中的不兼容性以和的形式构建损失函数。比较 RankGeoFM 与本文提出的 Geo-LSTM 模型,发现前者在较小规模的数据集上能够展现出优异的推荐性能。然而,基于传统机器学习方法的 RankGeoFM 往往受限于数据量的增长,随着数据规模扩大,其预测能力和泛化能力相较于深度学习方法,特别是神经网络结构(如 Geo-LSTM)而言,则会显示出明显的局限性。这也从侧面印证了深度学习技术之所以受到广泛青睐的原因之一,即其在大规模数据处理上

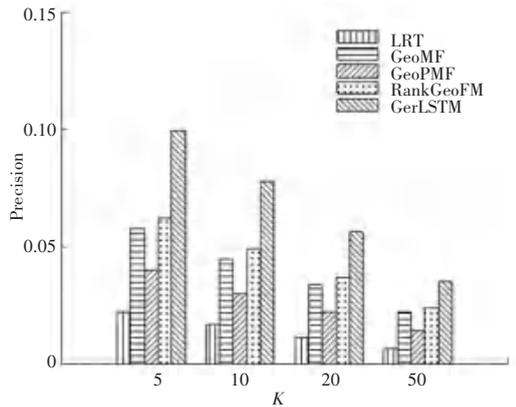


图 4 Foursquare 数据集上的精确率

Fig. 4 Accuracy rates on the Foursquare dataset

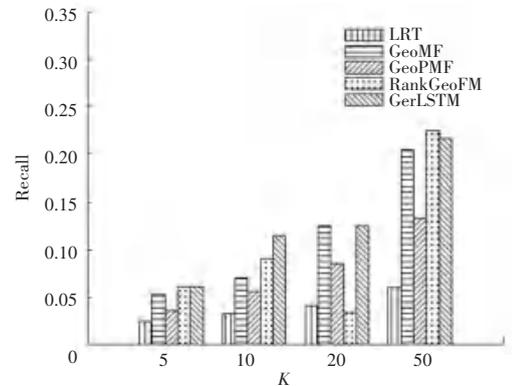


图 6 Foursquare 数据集上的召回率

Fig. 6 Recall rates on the Foursquare dataset

的优越适应性和性能提升潜力。

4 结束语

随着移动互联网和全球定位系统的普及,基于位置的社交服务迅速发展,催生了如 Gowalla、Foursquare 等国际平台以及美团、饿了么等国内应用。这些服务为用户提供实时位置分享、商家发现及评价等功能,极大地便利了日常生活。然而,在海量用户数据增长背景下,如何有效挖掘并推荐用户可能感兴趣的地点成为挑战。本文针对此问题,在分析前人研究成果基础上设计了一种创新模型——Geo-LSTM,该模型结合循环神经网络中的 LSTM 结构,并引入地理因子门机制,以捕捉用户地理位置信息对兴趣偏好长期的影响。实验证明,相较于传统的推荐方法,本文所提出的 Geo-LSTM 模型表现出优异的推荐准确率。该模型虽取得了显著效果,但其在处理用户行为时间间隔以及 cell 结构专业化方面仍存在改进空间,未来针对此方面研究有望对模型的性能进一步提升。

参考文献

- [1] 李勇, 韩志媛, 安敬民. 基于循环神经网络的实时偏好感知兴趣点推荐 [J]. 计算机工程与设计, 2023, 44(12): 3772-3777.
- [2] FENG S, CONG G, AN B, et al. Poi2vec: Geographical latent representation for predicting future visitors [C]//Proceedings of the AAAI Conference on Artificial Intelligence. AAAI, 2017: 756.
- [3] 曲昭伟, 杨凯翔, 王晓茹, 等. 基于语义行为和社交关联的好友推荐模型 [J]. 南京大学学报: 自然科学版, 2018, 54(6): 1124-1131.
- [4] YE M, YIN P, LEE W C, et al. Exploiting geographical influence for collaborative point-of-interest recommendation [C]//Proceedings of the 34th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2011: 325-334.
- [5] CHENG C, YANG H, KING I, et al. Fused matrix factorization with geographical and social influence in location-based social networks [C]//Proceedings of the 26th AAAI Conference on Artificial Intelligence. AAAI, 2012: 17-23.
- [6] 任星怡, 宋美娜, 宋俊德. 基于用户签到行为的兴趣点推荐 [J]. 计算机学报, 2017, 40(1): 28-50.
- [7] ZHAO G, QIAN X, XIE X. User-service rating prediction by exploring social users' rating behaviors [J]. IEEE Transactions on Multimedia, 2016, 18(3): 496-506.
- [8] REN Yueqiang, WANG Ze, SUN Xiaona, et al. A multi-element hybrid location recommendation algorithm for location based social networks [J]. IEEE Access, 2019, 7: 100416-100427.
- [9] 彭宏伟, 靳远远, 吕晓强, 等. 一种基于矩阵分解的上下文感知 POI 推荐算法 [J]. 计算机学报, 2019, 8(42): 1797-1811.
- [10] LI Huayu, GE Yong, HONG Ruichang, 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. New York: ACM, 2016: 975-984.
- [11] XIONG X, QIAO S, HAN N, et al. Where to go: An effective point-of-interest recommendation framework for heterogeneous social networks [J]. Neurocomputing, 2020, 373: 56-69.
- [12] SUN K, QIAN T, CHEN T, et al. Where to go next: Modeling long- and short-term user preferences for point-of-interest recommendation [C]//Proceedings of the 34th AAAI Conference on Artificial Intelligence. AAAI, 2020: 214-221.
- [13] FANG J, MENG X, QI X. A top-k POI recommendation approach based on LBSN and multi-graph fusion [J]. Neurocomputing, 2023, 518: 219-230.
- [14] LIU N, ZHAO J. Recommendation system based on deep sentiment analysis and matrix factorization [J]. IEEE Access, 2023, 11: 16994-17001.
- [15] LI M, ZHENG W, XIAO Y, et al. Exploring temporal and spatial features for next POI recommendation in LBSNs [J]. IEEE Access, 2021, 9: 35997-36007.
- [16] 夏彬. 基于位置信息社交网络的推荐系统研究 [D]. 南京: 南京理工大学, 2018.
- [17] 李英华. 基于神经网络的兴趣地点推荐研究与应用 [D]. 重庆: 重庆大学, 2019.
- [18] 韩旭, 孙文本, 周智楠, 等. 基于 LSTM 神经网络的舰船航行位置预测 [J]. 舰船电子工程, 2023, 43(9): 58-61.
- [19] GAO H, TANG J, HU X, et al. Exploring temporal effects for location recommendation on location-based social networks [C]//Proceedings of the 7th ACM Conference on Recommender Systems. New York: ACM, 2013: 93-100.
- [20] LIAN D, ZHAO C, XIE X, et al. GeoMF: Joint geographical modeling and matrix factorization for point-of-interest recommendation [C]//Proceedings of the 20th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York: ACM, 2014: 831-840.
- [21] LI X, CONG G, LI X L, et al. Rank-geofm: A ranking based geographical factorization method for point of interest recommendation [C]//Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval. New York: ACM, 2015: 433-442.