



## 深度学习方法在兴趣点推荐中的应用研究综述

汤佳欣<sup>1,2</sup>, 陈阳<sup>1,2</sup>, 周孟莹<sup>1,2</sup>, 王新<sup>1,2</sup>

(1. 复旦大学, 计算机科学技术学院, 上海 201203; 2. 上海市智能信息处理重点实验室 (复旦大学), 上海 201203)

**摘要:** 近年来, 基于位置的社交网络被广泛使用, 用户通过在兴趣点签到以记录他们的行程, 并与其他用户分享他们的感受和评价。兴趣点推荐是基于位置的社交网络提供的一项重要服务, 一方面它可以帮助用户快速发现感兴趣的兴趣点, 另一方面也有利于兴趣点提供商更全面深入地了解用户偏好, 并有针对性地提高服务质量。兴趣点推荐主要基于对用户历史签到数据以及内容、社交关系等信息的分析。这篇论文系统归纳了兴趣点推荐中需要解决的四个挑战, 即时空序列特征提取、内容社交特征提取、多特征整合以及对数据稀疏性问题的处理, 总结了使用深度学习方法解决这四个挑战的相关工作, 并指出了它们的不足。最后论文提出了三类在兴趣点推荐上还没有得到充分利用的深度学习方法, 即使用增量学习加速推荐模型更新、使用迁移学习缓解冷启动问题以及使用强化学习建模用户动态偏好。这篇论文聚焦在深度学习方法在兴趣点推荐上的应用, 希望通过分析总结最新的研究进展, 为进一步提升推荐效果提供研究思路。

**关键词:** 兴趣点推荐; 深度学习; 特征提取; 特征整合; 数据稀疏性



## Deep Learning for POI Recommendation: A Survey

Tang Jiaxin<sup>1,2</sup>, Chen Yang<sup>1,2</sup>, Zhou Mengying<sup>1,2</sup>, Wang Xin<sup>1,2</sup>

(1. School of Computer Science, Fudan University, Shanghai 201203, China;

2. Shanghai Key Laboratory of Intelligent Information Processing, Fudan University, Shanghai 201203, China)

**[Abstract]** Location-based social networks (LBSNs) are popular recently. Users conduct check-ins at selected POIs to record their trajectories and share feelings with their friends. POI recommendation is an important service of LBSN which can facilitate users to find interesting POIs and help service providers understand user interests and improve the user experience. The quality of POI recommendation depends on the performance of unknown user preference prediction. Historical check-in data and other information in LBSN such as social networks and user reviews can be explored to speculate the user preference. In this paper, we give a brief introduction to the deep learning methods for POI recommendation. We point out four challenges of POI recommendation, i.e., spatial-temporal sequential feature extraction, content and social feature extraction, multi-feature incorporation, and solutions to data sparsity. We review the existing work which leveraged deep learning methods to solve these challenges respectively. The limitations of them are analyzed. Finally, we point out three potential research directions in the future to use deep learning methods for POI recommendation based on existing work, i.e., incremental learning to accelerate the model update process, transfer learning to solve cold start problem, and reinforcement learning to capture dynamic user preference. In conclusion, we focus on the application of deep learning methods for POI recommendation in this survey and we attempt to analyze the future trend to improve the performance of POI recommendation by analyzing the latest research outcomes.

**基金项目:** 上海市自然科学基金项目(16ZR1402200)

**作者简介:** 汤佳欣, 1995年、女、硕士在读、数据挖掘和计算机网络; 陈阳, 副教授; 周孟莹, 博士在读; 王新, 教授。

**E-mail:** jxtang18@fudan.edu.cn

## 0 概述

智能手机的普及和全球定位系统的支持促进了基于位置的社交网络 (Location-based Social Network, LBSN), 如 Foursquare、Yelp、Instagram、大众点评等, 的广泛使用。兴趣点 (Point of Interest, POI) 推荐是 LBSN 提供的一项重要服务, 一方面可以方便用户规划行程、快速发现感兴趣的兴趣点; 另一方面, 也可以帮助兴趣点服务提供商和广告商更全面深入地了解用户偏好, 发掘更准确的市场目标群体, 并引入更有针对性的广告策略吸引用户。

LBSN 中包含了大量用户和兴趣点的信息, 为挖掘用户偏好提供了基础。在一个典型的 LBSN 中, 用户可以通过在兴趣点签到以记录行程, 一次签到 (Check-in) 可以用一个 “<用户, 兴趣点, 时间戳>” 三元组表示。每个用户的多次签到记录可以根据时间戳排序构成其签到序列, 即用户轨迹。签到记录直接反映了用户对兴趣点的偏好。此外, 用户还可以在 LBSN 中发表对兴趣点的评价或上传照片; 可以关注其他用户并分享他们对于兴趣点的感受, 与其他用户之间形成社交好友关系, 上述内容信息和社交关系信息也隐含了用户的偏好。因此, 兴趣点推荐服务的实现可以依托于从 LBSN 的丰富信息中挖掘出的用户偏好。

传统推荐系统中的一些经典方法可以被运用到兴趣点推荐中, 其中使用最广泛的方法之一是基于矩阵分解的方法<sup>[1-2]</sup>, 其原理是通过分解 “用户-兴趣点” 签到矩阵 (user-POI check-in matrix) 获取表征用户和兴趣点关联的低维隐特征, 但这种方法没有考虑用户签到序列的序列特征。另一类方法将签到序列抽象为 Markov 链<sup>[3-5]</sup>, 仅根据上一次签到决定下一次签到的推荐, 没有考虑更早期的历史签到中体现的用户偏好信息对下一次签到的影响。此外, 这两类方法都只使用了用户签到数据, LBSN 中的其他信息没有得到充分有效地利用。随着人工智能技术的快速发展, 深度学习已被证实可以有效地从大量数据中学习隐藏信息并预测未来状态。相比于传统的机器学习算法, 它可以通过模型自动化从数据中提取并处理特征。将深度学习应用于兴趣点推荐系统有助于充分利用系统中丰富的特征并挖掘特征之间的复杂关联。

近年来, 兴趣点推荐问题已得到了广泛的研究。现有的一些有代表性的综述<sup>[6-8]</sup>根据推荐目标将兴趣点推荐分为用户通用兴趣点推荐和用户下一个兴趣点推荐; 根据用户偏好的主要影响因素将其分为地理因素、时间因素、社交因素和内容因素主导的兴趣点推荐系统; 根据使用的数据种类将其分为基于用户位置、轨迹、活动

以及以上多种数据的兴趣点推荐系统。不同于这些综述对兴趣点推荐问题中涉及的要素进行分类, 我们聚焦于该问题本身的挑战以及深度学习方法在解决这些挑战的应用上, 试图从方法的角度对兴趣点推荐的研究进行总结并提供未来研究思路。

## 1 兴趣点推荐问题的挑战

兴趣点推荐需要根据 LBSN 中的大量相关信息对用户偏好进行总结和刻画, 给出个性化的兴趣点推荐, 针对兴趣点推荐系统的特性, 我们将其中的挑战总结为以下四个方面:

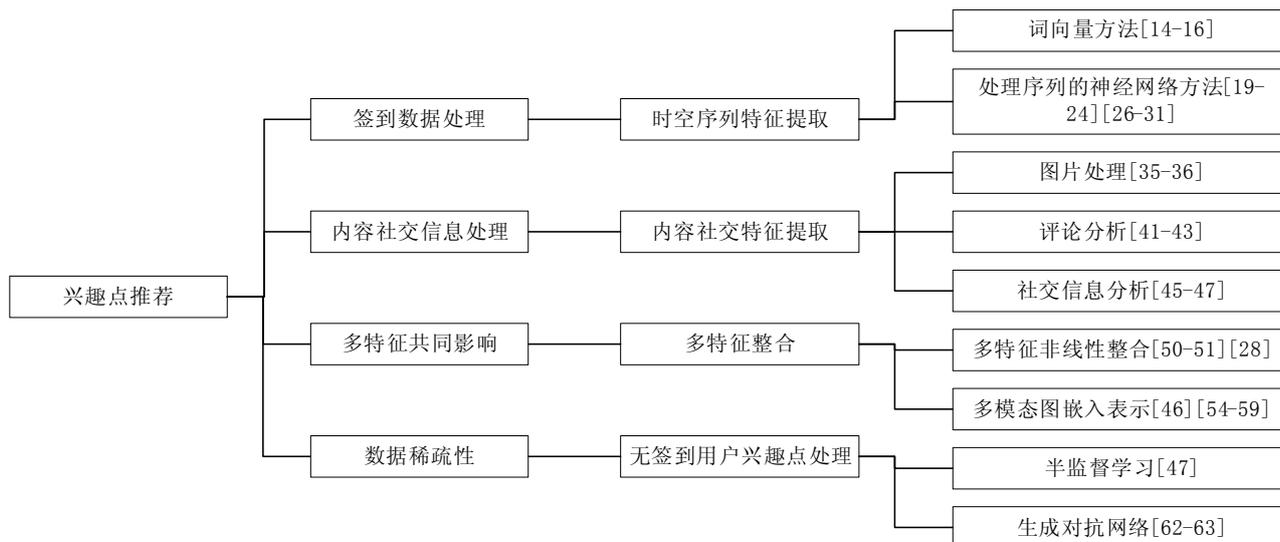
1) 如何从签到数据中提取时空序列特征? 用户的历史签到序列是 LBSN 中用户对兴趣点偏好最直观的体现。与传统的 “用户-商品” 矩阵相比, 签到序列包含了上下文时空信息, 充分挖掘其时空序列特征可以有效改善对用户偏好的建模效果。

2) 如何充分利用 LBSN 中的信息? 除了用户签到序列, LBSN 中还包含大量用户生成内容 (User-Generated Content, UGC) 和社交关系信息, 如用户发布的关于某个兴趣点的照片评论、用户之间的关注关系等。这些信息能够反映出用户的关注点和兴趣偏好, 同时也隐含了兴趣点的特征, 因此可以被用来进一步改善兴趣点推荐的效果。

3) 如何综合多特征的影响实现兴趣点推荐? 如上所述, 兴趣点推荐系统中包含大量体现用户偏好的特征。从特征对象的角度可以分为用户特征、兴趣点特征和外部环境特征; 从用户偏好主要影响因素的角度可以分为时空因素、内容因素和社交关系因素等。一个有效且有拓展性的模型需要综合考虑这些特征的共同影响以实现个性化的兴趣点推荐。

4) 如何处理 “用户-兴趣点” 签到矩阵的稀疏性问题? 虽然 LBSN 被广泛使用, 但单个用户访问过的兴趣点数量相比于全部兴趣点而言是极少的。此外, 对于新用户和新注册的兴趣点, LBSN 中关于它们的历史签到信息较少。鉴于以上原因, “用户-兴趣点” 签到矩阵具有较强的稀疏性。怎样挖掘有限的历史签到数据、利用没有历史签到的用户兴趣点其本身的特性以在一定程度上缓解数据稀疏性问题是许多相关工作研究的焦点。

基于以上对兴趣点推荐问题挑战的总结, 本文将从时空序列特征提取、内容社交特征提取、多特征整合和无签到用户兴趣点处理四方面对使用深度学习解决这些挑战的背景和优势进行分析, 对相关工作中用于解决四个问题的具体深度学习方法进行回顾, 具体内容如图 1 所示。通过对兴趣点推荐中深度学习方法的总结和分类,



我们希望可以帮助读者对该问题有更加全面的理解和系统的思考。

Fig.1 Category of deep learning methods for POI recommendation

图 1 兴趣点推荐中应用的深度学习方法分类

## 2 时空序列特征提取

用户的历史签到数据是 LBSN 中反映用户对兴趣点偏好的最直观的信息。用户签到包括其访问的兴趣点和时间戳，用户偏好受到时空特征的限制和影响，例如由于营业时间限制，一些兴趣点只会在特定的时间段被访问；根据地理学第一定律<sup>[9]</sup>，兴趣点之间的距离远近在一定程度上决定了它们之间关联的紧密程度。此外，签到序列往往具有一些序列特征，如某些兴趣点之间访问的连续性、用户偏好的一致性、用户行为的周期性等。

推荐系统传统的矩阵分解方法没有考虑到签到数据的时空序列特征，一些相关工作<sup>[11-13]</sup>试图使用传统统计和概率学的方法对矩阵分解方法进行改进，如最小化连续两次访问的用户向量差<sup>[11]</sup>、最小化候选兴趣点向量与用户历史访问过的兴趣点向量之间的差<sup>[12]</sup>等。但是这些改进只能启发式地描述签到序列一些显式的宏观特征，用户签到数据中隐含的特征和联系依然很难被充分挖掘和利用。

近年来随着自然语言处理技术的快速发展以及处理序列的神经网络模型的广泛使用，深度学习方法被证实处理序列数据上具有很大优势，通过对循环神经元结构的改造、“门”的设计以及注意力机制的运用，这类方法可以有效地在序列数据中刻画复杂的上下文特征并捕捉用户的长短期偏好，因此可以被应用于 LBSN 中包含时空信息的签到序列的特征提取。在本章中，我们主要总结归纳了两类提取时空序列特征的方法，第一类是

使用自然语言处理中获取词向量的方法来处理兴趣点序列，这类方法更加关注局部的序列特性，即某些兴趣点常在短期内被同一用户访问的模式，使这些兴趣点拥有相近的隐特征向量，在推荐时根据隐特征向量给出符合用户历史偏好的兴趣点；第二类方法是使用一些常用的处理序列的神经网络模块，如循环神经网络和注意力机制等，这类方法相比于第一类方法可以获取历史兴趣点序列的长期特征即用户的长期偏好以及兴趣点被访问的前后关系特征，并可充分挖掘利用兴趣点签到相关的上下文信息，如兴趣点地理位置、签到时间等，因此在相关工作中被应用得更加广泛。

### 2.1 词向量获取方法

为获取签到序列的序列特征，兴趣点推荐系统需要挖掘兴趣点之间的潜在关联，一类常见的方法是借鉴自然语言处理中获取词向量的方法，将每个兴趣点类比为单词，将用户历史签到的兴趣点序列看作句子，最终刻画用户的兴趣点访问模式可以被转化为提取句子的语义特征。常用的词向量获取方法 Word2vec 模型<sup>[10]</sup>分为两种实现，即 Skip-gram 和 Continuous Bag-of-Words (CBOW)。Skip-gram 是根据当前的词来预测其周围的词，而 CBOW 则是根据周围的词预测当前的词，这两种模型均可被应用于兴趣点推荐。

文献[14]利用 Skip-gram 实现以建模用户的签到兴趣点序列以获取每个兴趣点的隐特征，Skip-gram 在兴趣点推荐中其目标方程是最大化兴趣点上下文（历史数据中曾经在某个兴趣点前后被访问的兴趣点）和该兴趣点

同时出现的概率,该方法在推荐前十个兴趣点时比利用非一致性和连续性的特征改进的矩阵分解算法<sup>[11]</sup>准确率提高了约 0.03。文献[15]对上述方法进行了进一步优化,将用户每一天的签到序列看作一个单独的句子,并对兴趣点在工作日和周末的签到进行了区分。文献[16]则使用了 CBOW 实现,根据兴趣点序列获取兴趣点特征表示。

## 2.2 处理序列的神经网络方法

使用类比后获取词向量的方法从用户签到序列中

Table 1 Neural Network methods to deal with POI sequences

表 1 处理兴趣点序列的神经网络方法及相关工作

方法	局限性	优势	相关工作
循环神经网络	1. 无法获取历史序列中不同兴趣点的重要性大小 2. 模型可解释性较差	1. 可捕捉兴趣点访问的前后关系特征 2. 可获取序列的长短期特征 3. 可改进以处理上下文信息	LSTM [19] 改进 RNN [20-21] 改进 LSTM [23-24]
注意力机制	1. 无法刻画序列中兴趣点访问的前后关系 2. 对短期局部特征的刻画能力不足	1. 便于刻画用户偏好的整体特征 2. 增强了模型的可解释性	时间 [19][27-30] 空间 [26]
编码器	1. 模型可解释性较差 2. 只能提取时空特征,若不和其他模块结合使用,则无法获取序列特征	1. 可获取兴趣点之间深层次的非线性特征 2. 可结合地理特征和时间特征	编码器-解码器 [28] 自编码器 [31]

循环神经网络 (Recurrent Neural Network, RNN)<sup>[17]</sup>是处理带丰富上下文信息的序列数据的有效方法,将基于循环神经网络的方法引入兴趣点推荐可以有效地从签到序列中提取时空序列特征。由于传统的循环神经网络在刻画用户长期偏好时存在梯度消失的问题,基于长短期记忆网络 (Long Short-Term Memory, LSTM)<sup>[18]</sup>的方法在相关工作被使用得更加广泛,它可以有效地刻画用户的长短期偏好。文献[19]引入了兴趣点类别的概念并利用两个长短期记忆网络编码器分别提取用户签到的兴趣点类别序列和具体兴趣点序列的时间特征,根据兴趣点类别特征进行初步筛选后再根据每个兴趣点的特征和用户特征实现推荐,通过刻画不同层次的序列特征减小了推荐的搜索空间,提高了兴趣点推荐的准确性。

传统循环神经网络和长短期记忆网络仅考虑了兴趣点之间的顺序关系而没有考虑复杂上下文信息,如时间信息和地理信息。以最简单的循环神经网络为例,时间  $t_k$  时神经元输出的隐向量为

$$h_{t_k} = f(Mx_{t_k} + Ch_{t_{k-1}})$$

其中  $x_{t_k}$  为  $t_k$  时的输入,即  $t_k$  时签到的兴趣点特征,  $h_{t_{k-1}}$  为  $t_{k-1}$  时神经元的输出,  $M$  表示转移矩阵,这种神经网络结构具有较强的可拓展性,可以通过对循环的神经元即  $Mx_{t_k} + Ch_{t_{k-1}}$  部分进行改进以融入时空特征,因此,相关工作<sup>[20-21]</sup>改进了上述传统的循环神经网络模型以挖掘签到序列时空上下文之间的序列特征。ST-RNN<sup>[20]</sup>是一种典型的结合了时空上下文特征的循环神经网络模型,它将循环神经网络中的转移矩阵  $M$  替换为与时间、地理

提取兴趣点特征表示仅仅考虑到了兴趣点短期被同用户访问的关系,而没有考虑到兴趣点之间更复杂的关联,签到数据的具体地理位置信息和时间戳信息没有得到充分利用。为了更加深入地挖掘带时空上下文的序列特征,一些处理序列的神经网络模块可被应用于兴趣点推荐。我们将方法的优劣势和相关工作总结于表 1。

距离有关的转移矩阵的乘积,与时间相关的矩阵可以描述近期历史的影响同时考虑了时间间隔,与距离相关的矩阵可以获取用户签到到行为的地理特征。相比于原始的循环神经网络模型,ST-RNN 在 Gowalla 数据集上性能 (AUC<sup>[25]</sup>) 提高了约 0.03。另一些相关工作<sup>[22-24]</sup>对长短期记忆网络进行了改进,如文献[22]中作者认为连续签到之间的关联性大小会随着时间间隔和地理距离的增大而减小,而这种关联性对于用户短期偏好的影响较大,因此他们将长短期记忆网络中的细胞 (cell) 状态拆分为短期状态和长期状态,利用关于时间间隔和距离的衰减函数对每次签到的短期状态进行修正,和 ST-RNN 相比,模型在 Gowalla 数据集上的推荐准确率又提升了约 0.02。

上述工作通过改进循环神经网络的循环神经元使其更加适应于兴趣点推荐系统中时空序列特征的处理。但这类方法的缺点在于循环神经元无法有区别地处理签到序列中不同的签到,而事实上历史签到对未来签到的影响并不完全是随着时间间隔的增大而衰减。注意力机制是另一类处理序列的神经网络方法,可用于提取兴趣点序列的时空特征。从地理位置来看,每一对兴趣点之间的影响力大小不同。文献[26]提出了地理注意力网络来刻画兴趣点之间基于位置的关系,考虑了两个兴趣点之间的距离以及他们各自的地理属性——地理影响力 (即该兴趣点引导用户去其他兴趣点的能力) 和地理被影响力 (即该兴趣点吸引其他兴趣点的访客的能力),使用候选兴趣点的地理被影响力作为注意力机制中的查询 (Query)、该用户历史访问过的兴趣点的地理影响力作为键 (Key),影响力系数根据两个兴趣点之间的距离使

用 RBF 核获得, 最终计算出注意力权重, 模型输出的对于候选兴趣点的用户偏好为历史兴趣点地理影响的加权求和。地理注意力网络使得模型的性能在 Foursquare 和 Gowalla 数据集上均获得了较大提升。

在处理时序特征时, 注意力机制一般与循环神经网络或长短期记忆网络一起使用, 一类方法是使用后者获取每次签到的隐特征, 再利用注意力机制加权聚合签到序列中多次签到的隐特征; 另一类方法则是并行使用这两种方法从多维度提取签到序列的特征。文献[27]为推荐下一次签到的兴趣点, 先将用户签到序列(候选兴趣点和推荐时间作为序列的最后一个节点)中每一次签到的兴趣点特征和时空上下文特征输入长短期记忆网络以获取其隐特征, 由于每个历史签到对未来签到兴趣点预测的贡献程度不同, 他们再利用注意力机制根据历史签到的隐特征和候选兴趣点的隐特征计算注意力权重加权的决策向量, 基于此向量可预测该候选兴趣点被访问的概率, 访问概率最高的候选兴趣点被作为推荐的结果。文献[28]提出了一种基于长短期记忆网络模块的编码器-解码器模型来预测下一个被访问的兴趣点, 其中编码器中的长短期记忆网络被用来获取签到序列中每个签到兴趣点的隐特征, 解码器同样利用长短期记忆网络根据编码器的结果进一步挖掘签到兴趣点特征, 时间注意力机制根据编码器输出的历史签到的隐特征和解码器计算的候选兴趣点特征计算注意力权重, 考虑历史签到与候选兴趣点之间不同大小的相关性获取更准确的候选兴趣点特征进行推荐预测。不同于上述两个工作, 文献[29]并行地使用注意力机制和长短期记忆网络来共同刻画用户偏好的整体特征。他们认为用户签到行为从短期来看往往呈现出一定的连续性和一致性, 长短期记忆网络适用于建模用户签到的序列行为以获取用户的短期偏好; 而从长期来看, 用户的偏好在不同的情景和位置下往往具有非一致性, 注意力机制可以更有效地刻画用户的整体长期偏好。为了刻画出用户偏好在一天的具体时间段特征, 文献[19]区分了工作日和周末, 并将 1 天根据签到的分布密度分为 12 个时间窗口, 他们将长短期记忆网络输出的兴趣点隐特征划分到不同时间窗口中, 并利用用户和窗口中兴趣点的隐特征的相关性计算了每个时间窗口的注意力权重, 这项机制的设计大幅提升了兴趣点推荐的准确性。

上述相关工作的思路都是针对用户的单个签到序列进行分析并预测下一个签到兴趣点, 文献[30]提出对多条用户签到轨迹进行分析并利用签到轨迹之间的相关性预测当前轨迹下一个兴趣点的思路。他们设计了基于历史的注意力机制模块通过计算历史轨迹和当前轨迹之间的

相关性即注意力权重以获取最相关的上下文向量进行兴趣点推荐, 这种模型相比之前的单序列模型可以更有效地挖掘用户签到轨迹的多层次周期性和复杂连续性特征, 也是未来可研究的重要方向。

为综合考虑签到序列的时空特征, 文献[31]提出了一种基于自编码器(Autoencoder, AE)的模型使用基于自注意力机制的编码器来从签到兴趣点中提取时间特征, 再利用将地理距离因素与序列连续性相结合的解码器来处理地理位置影响。

### 2.3 相关工作的不足

时空特征是兴趣点推荐系统中最重要的特征之一, 目前大多数关于兴趣点推荐和位置预测的研究都聚焦于时空特征的提取和分析。大部分的现有工作侧重于利用深度学习模型提取时间序列特征, 尽管一些工作引入了时间影响力和时间间隔的概念, 但具体的时间点特征目前还没有能够被充分挖掘。例如, 用户更倾向于在某些特定日期访问某些兴趣点, 或某些兴趣点只在某些特定的时间段可被访问, 粗粒度的时间窗口无法描述这些特征。与时间相关的用户访问模式如多层次的周期性和一致性特征有待进一步挖掘。

此外, 相关工作多是对单个用户签到序列进行建模, 尽管每个单序列中都包含了丰富的时空序列特征, 但序列之间关系的挖掘和利用可以进一步提升用户偏好预测的效果, 目前该方面的研究工作较少。不同序列中由于存在某些相同或相近的兴趣点可以联合进行时空特征提取, 通过多序列特征提取可以获得更加全面的时空序列特征。

## 3 内容社交特征提取

除了用户签到数据, LBSN 中还包含了大量用户生成内容和社交关系信息, 如用户评论、照片以及用户之间的社交关系等, 这些信息也能够反映出用户的偏好和兴趣点的特征, 在数据集中包含这些类型的辅助信息时, 充分利用这些信息可以有效提升兴趣点推荐的效果。

根据用户评论可以分析出用户访问某个兴趣点时的感受和情绪, 用户上传的照片不仅可以反映出其关注点和偏好, 还可以提供更多关于兴趣点的信息。此外由于这些数据都是公开可见的, 它们也会影响其他用户对该兴趣点的预期, 进而影响用户选择是否会访问该兴趣点, 因此兴趣点推荐时需要考虑评论、照片等用户生成内容中包含的语义特征。

此外, 根据社交网络中的同质性(Homogeneity)<sup>[32]</sup>, 用户的社交关系往往也可以反映出用户的偏好, 好友之间的偏好存在一定的相似性, 好友的评论和信息反馈相

比其他陌生用户更能影响用户的偏好,因此社交关系特征也是兴趣点推荐中需要考虑的重要因素。

我们将 LBSN 中除了签到序列以外的其他信息以及利用这些信息进行兴趣点推荐的工作分为三类,如表 2。

Table 2 Methods and Related works about Content and Social Feature Extraction in LBSNs

表 2 LBSN 中的内容社交信息提取及相关工作

特征类型	方法	常用数据集	相关工作
图片	VGG16、CNN	Instagram、Yelp、Breadtrip	[35-36]
评论	Text-CNN	Foursquare	[41-43]
社交关系	社交图相关算法	Gowalla、Foursquare 等	[42-44]

### 3.1 图片处理

卷积神经网络 (Convolutional Neural Networks, CNN) [33] 近年来被广泛运用在计算机视觉和自然语言处理领域以进行图片和文本分析处理。文献[35]通过 Instagram API 获取了 Instagram 中大量用户发布的图片数据,为了提升兴趣点推荐的准确性,文中提出了 VPOI 模型,利用这些视觉内容即照片信息辅助推荐,作者认为用户发布的照片的视觉特征符合该用户的偏好,关于某个兴趣点的照片也反映了该兴趣点的特征,因此可以利用照片的视觉特征指导用户、兴趣点的隐特征学习。他们使用经典的图片分类模型 VGG16 [34] 获取每张照片的图嵌入 (embedding),并将上述思想与概率矩阵分解的目标方程相结合,模型准确性相比于原始的概率矩阵分解有较大提升。文献[36]同样使用了卷积神经网络来提取 LBSN 中的图片内容。

图片是某些 LBSN 中用户分享内容的重要媒介,但目前针对图片信息在兴趣点推荐中应用计算机视觉技术的相关工作较少,一方面由于大多数 LBSN 数据集中图片数据较少,另一方面用户的偏好基本体现在用户的签到行为中,图片包含的额外信息可能较少。

### 3.2 评论分析

用户的评论体现了其对某个兴趣点的偏好程度,也是对推荐效果的直接反馈。传统的兴趣点推荐系统中用户历史偏好主要通过签到矩阵体现,签到行为是一种对兴趣点的二元选择 (访问或不访问),不能反映出用户对兴趣点的具体偏好程度,此外,用户对兴趣点发表的负面评论可能比未访问过该兴趣点所反映的偏好程度更低。LBSN 中 Foursquare 包含丰富的评论信息,以下利用评论内容辅助进行兴趣点推荐的相关工作均基于 Foursquare 的数据进行。相关工作中对于用户评论的挖掘大多集中在情感分析和主题分析上,最简单的情感倾向估计方法是根据评论中的形容词计算情感分数 [37] 或计算评论中的词汇与强烈情感词 (如 excellent、cool、bad

等)的相似性 [38],但这种方法在处理否定句式时存在无法准确判断出情感倾向的可能,并且无法处理描述性的评论。另一部分工作使用了主题模型即 LDA (Latent Dirichlet Allocation) 模型 [39] 来估计评论的隐含主题 [40],这类方法更适用于描述性的评论,但没有考虑情感因素。为了综合分析评论的内容,相关工作 [41-43] 等引入了深度学习卷积神经网络模型挖掘用户评论辅助兴趣点推荐,文献[41]利用 Text-CNN [44] 模型对评论进行内容情感信息提取,计算用户对兴趣点的情感嵌入,使用该嵌入来调整用户兴趣点偏好分数,并根据该分数排序给出推荐结果,有效地提高了兴趣点推荐的准确性。

### 3.3 社交关系信息利用

LBSN 是一种特殊的社交网络,用户之间可以建立关注等社交关系,也可以由于地理位置的相关性形成地理邻居社交关系,最终构成用户社交关系图,有社交关系的用户之间的偏好可能会互相影响。文献[45]利用社交关系信息来提高兴趣点推荐性能,作者为每个用户构建了社交签到图,图中的节点表示该用户和其好友用户以及他们签到过的兴趣点,利用图上的随机游走可以获取该用户历史未访问过但好友访问过的潜在兴趣点集合,转移矩阵中的概率取决于两个用户之间的相似度和两个兴趣点之间的关联度 (即兴趣点之间的距离),最终稳态时可获得用户的潜在兴趣点。作者认为相比于没有被注意到的兴趣点,用户更倾向于访问这些潜在兴趣点。

不同于图片和评论数据受限于数据源,即只有某些特定的 LBSN 提供这些特殊类型的数据,大多数 LBSN 数据集中都包含丰富的社交信息,而对于社交信息的利用主要受限于社交关系本身对于用户签到行为偏好影响的重要性程度。由于用户的兴趣点访问模式受时空等物理因素的限制,社交关系对其的影响比传统社交网络小,社交关系信息更多时候作为兴趣点推荐系统实体关系异构图 (如 4.1 中图 2 所示) 中用户节点之间的边或应用于半监督学习中的无监督部分,更多的相关工作 [46-47] 具体见 4.2 和 5.1。

### 3.4 相关工作的不足

在兴趣点推荐中对于内容社交信息的利用和特征提取一方面受限于研究可获取的公开数据源较少,常用的公开数据集均没有同时包含这些类型的信息;另一方面目前在兴趣点推荐这种特定场景下的计算机视觉和自然语言处理应用研究相比于时空类型的数据分析和特征提取较少。从研究内容的角度,现有的对 LBSN 中用户评论的分析多数局限于情感和主题分析,而写作风格和语义信息没有得到充分地利用,这些信息不仅隐含了用户性格等特征,往往还直接反映出兴趣点的优点和劣势,

充分挖掘这些信息可以促进兴趣点推荐系统更全面地刻画用户和兴趣点的特点,获得更准确的用户、兴趣点隐特征,进而提升推荐的效果;从模型方法的角度,目前已有的研究只利用了一些经典的图片和文本分类模型方法,更多的深度学习方法如双向长短记忆网络与多层注意力网络的结合<sup>[48]</sup>、双向长短记忆网络与条件随机场(Conditional Random Field, CRF)的结合<sup>[49]</sup>等尚未被用于LBSN中的内容特征提取。

## 4 多特征整合

如上所述,从LBSN中的历史签到、用户生成内容和用户社交关系信息等数据中可以提取出丰富的特征,用户对于兴趣点的偏好受这些特征共同影响。从对象的角度分类,这些特征可以分为用户特征、兴趣点特征和外部环境特征;从影响因素的角度来看,可以分为时空特征、序列特征、内容语义特征、社交关系特征等。传统的协同过滤方法使用矩阵分解来获取用户和兴趣点的隐特征向量,这种方法将用户和兴趣点之间的关系刻画为隐特征之间的内积关系,其缺陷在于其要求用户和兴趣点的隐特征具有相同的维度,限制了用户兴趣点特征提取的效果;此外,线性运算无法全面地刻画用户和兴趣点之间的复杂关联,难以建模多特征的共同影响。

神经元中非线性激活函数的设计以及神经元之间的网络结构使得神经网络模型可以刻画输入和输出之间的复杂非线性关联,因此可以被用于兴趣点推荐中多特征整合的过程。此外,LBSN中各个实体(如用户、兴趣点等)之间存在不同类型的关系,构建多实体关系图并使用图嵌入的方法可以在特征整合的过程中有效地保留不同实体之间不同关系的结构特征。本章将归纳总结兴趣点推荐相关工作中进行特征整合时使用的这两类深度学习方法。

### 4.1 多特征的非线性整合

整合不同特征时需要挖掘不同特征之间的线性及非线性关联,其中线性关联可通过简单的内积方法获取,而非线性关联在相关工作中常利用不同的神经网络模块提取,最终通过设计构建神经网络模型来结合线性与非线性关联并获取不同特征共同作用的结果。文献[50]提出了基于神经网络的协同过滤模型,根据用户和兴趣点的特征计算兴趣点推荐分数。模型将用户特征和兴趣点特征连结,利用多层感知机(Multi-layer Perceptron, MLP)<sup>[52]</sup>提取它们之间的非线性关系,同时并行地使用一个广义的矩阵分解模块获取其线性关联,将两者的结果相联结计算得到最终的分數。类似地,文献[51]使用深度信念网络(Deep Belief Networks, DBN)<sup>[53]</sup>作为一个确定性函数来提取多特征连结的深层表示。

尽管多层感知机和深度信念网络可以有效提取特征之间的非线性关联,但它们的可解释性较差,无法获取不同特征对用户偏好的贡献大小的不同。为了实现可解释的特征整合,文献[28]使用了基于注意力机制的方法,通过分配不同的注意力权重,使得更重要的特征可以对用户偏好预测做出更大贡献。模型包括两级注意力模块,其中宏观上下文注意力度量了不同特征的重要程度,微观上下文注意力分配权重给隐向量中的每个值。

无论是多层感知机、深度信念网络还是注意力机制,它们共同的优势在于神经网络结构和非线性激活函数的使用对于特征之间非线性关联的充分挖掘,在应用时可根据具体的场景要求选择具体方法,在对可解释性要求较高时使用注意力机制。

### 4.2 多模态的图嵌入表示

图结构是表示兴趣点推荐系统中不同实体之间复杂关系的有效方式,利用图结构对不同类型的特征进行整合也是一种兴趣点推荐中常使用的方法。表3是对兴趣点推荐系统中使用图嵌入表示以整合特征的方法总结。

Table 3 Graph Embedding methods used for POI Recommendation

表3 兴趣点推荐图嵌入方法应用

图类型	方法	优势	局限性	相关工作
LBSN 实体异构图	图注意力机制	加权聚合不同节点的特征;可解释性强	无法直接处理多层次的异构图	[46]
	图自编码器	多层图神经网络获取节点间高阶非线性关联	无法直接处理多层次的异构图	[54-55]
	图卷积网络	可以直接处理多实体多层次的异构图;可获取节点之间的深层隐含关联	可解释性较弱	[56]
	其他随机游走采样方法	可以直接处理多实体多层次的异构图	难以挖掘节点之间的深层隐含关联	[57-58]
知识图	知识图嵌入	可处理较稀疏的数据	三元组表示的关系较简单 无法提取较复杂的序列特征	[59]

如图2所示的异构图是LBSN的一种典型的图表示,图中包括四种类型的节点,即用户节点、兴趣点节点、时间戳节点和活动节点,节点之间的边有不同的含义,

用户节点之间的边表示社交关系,兴趣点之间的边表示地理邻居关系或连续访问的关系,签到信息也使用边表示,即一条连接一个用户、兴趣点、时间戳和活动的超

边表示一次签到。根据图的整体结构特征和图中每个点自身的特征计算不同类型节点的嵌入是另一种整合不同特征的方法。

由于图 2 的结构较复杂,一些相关工作从图 2 中提取出不同的子图,如用户社交关系图、兴趣点邻居关系图等,分别计算这些相对较简单的图中节点的嵌入再进行加总得到不同类型节点最终嵌入。文献[46]提出了一种图注意力机制结合用户社交关系图、兴趣点邻居图(一个兴趣点与其地理位置最近的  $k$  个兴趣点之间有边相连)和“用户-兴趣点”签到关系图中的上下文信息。作者认为用户的朋友对该用户的影响力大小与用户自身的特征以及朋友关系特征相关,同时,针对不同的兴趣点,朋友对用户的影响力也不同,因此模型根据用户自身的特征、候选兴趣点的特征以及用户社交关系图中其朋友关系特征计算不同朋友节点的注意力权重并获得该用户的社交特征嵌入。在兴趣点邻居关系图中,对于每个兴趣点,模型根据该兴趣点与邻居兴趣点之间的距离、目标用户的特征和邻居关系特征计算注意力权重并获得该兴趣点的邻居特征嵌入。模型中还包括一种双重注意力网络模块在“用户-兴趣点”签到关系图中综合考虑用户和兴趣点的访问模式,计算不同兴趣点对用户访问特征的注意力权重和不同用户对兴趣点访问特征的注意力权重,分别获得用户和兴趣点的访问特征嵌入。最终的用户嵌入为用户自身特征嵌入、用户社交特征嵌入和用户访问特征嵌入之和,兴趣点嵌入为兴趣点本身特征嵌入、兴趣点邻居特征嵌入和兴趣点访问特征嵌入之和。这种图注意力机制的提出使得模型推荐命中率在多个数据集上均提升了约 10%。文献[54]设计了一种基于图神经网络(Graph Neural Network, GNN)的图自编码器以挖掘兴趣点访问和地理关系图,结合邻居兴趣点的特征获得每个兴趣点的最终出特征和入特征,多层图神经网络的使用可以捕捉到兴趣点之间的高阶非线性关联。进一步,利用图神经网络从用户-兴趣点访问图中根据兴趣点出特征计算出用户的最终隐特征表示,最终根据用户隐特征和候选兴趣点入特征给出推荐。

上述工作在多个子图中对特征进行多步图嵌入计算在一定程度上可以实现多实体特征整合,但无法充分挖掘 LBSN 实体异构图的整体特征。另一类工作直接在整体异构图中计算图嵌入,克服了这一缺陷。文献[56]基于图卷积网络(Graph Convolutional Network, GCN)<sup>[60]</sup>设计了一种时空感知的多层次图嵌入方法,对于不同类型的边使用不同的转移矩阵进行信息传播,并使用多层网络进行信息聚合。此外,还可以通过改进随机游走的采样方法以处理多实体异构图,文献[57]为用户-兴趣点、

兴趣点之间和用户之间的三种边设计了三种转移概率;文献[58]针对图 2 设计了一种带停留的随机游走机制,除了根据社交关系在用户之间游走采样,还会在某个用户节点停留以采样该用户的签到信息,通过不断迭代最终可以获得每个点的嵌入用作兴趣点推荐。

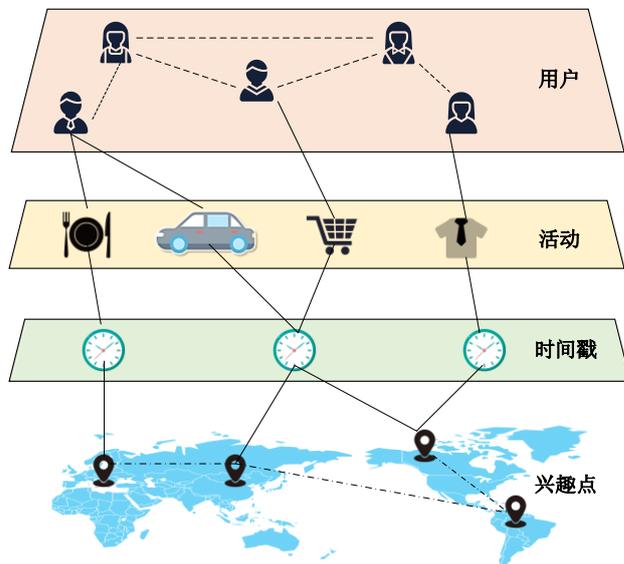


Fig.2 A heterogeneous graph representation of LBSN

图 2 基于位置的社交网络的异构图表示

近年来,知识图嵌入(knowledge graph embedding)方法<sup>[61]</sup>逐渐成熟,文献[59]使用知识图的结构来刻画兴趣点推荐系统中的复杂关系,模型认为下一个签到兴趣点是由用户和其所处的时间、地点共同决定的,因此将一个时间戳和一个地点组合成一个时空上下文“ $\langle t, l \rangle$ ”,并设计了一种基于翻译的推荐框架来建模用户、兴趣点和时空上下文之间的三元关系,签到序列中的一次签录用“ $(u, \langle t, l \rangle, v)$ ”表示,其中  $u$  和  $v$  分别表示用户和兴趣点。根据这些三元关系,利用知识图嵌入方法可以获取用户和兴趣点在同一个变换空间中的隐向量,并根据用户和候选兴趣点的隐向量进行推荐。

#### 4.3 相关工作的不足

现有工作对多个特征进行整合后可以较准确地刻画出用户的偏好并进行推荐,但特征对于推荐结果作用的可解释性目前还未得到充分重视,只有明确每个特征对于推荐结果的贡献,兴趣点提供商才能更有针对性地改进服务以吸引用户。部分现有工作引入注意力机制,通过注意力权重在一定程度上反映出各种特征的重要性,但各种特征之间的相互影响以及各个特征的变化对最终用户偏好的影响依然不够明确,相关工作缺乏对各特征作用机制的深入探讨。

此外,由于 LBSN 中的实体类型较多,如用户、兴

趣点、时间戳等,不同实体之间的关系较复杂,如社交关系、邻居关系、访问签到关系等,使用包含多种实体、多种关系的异构图的表示形式可以更有效地描述特征之间的关系,现有用于兴趣点推荐的图嵌入方法在解决规模性和异构性的问题上还存在一些不足。由于LBSN中用户和兴趣点数量的快速增长,除了硬件的提升,还需要在模型设计时考虑到空间和时间资源的占用情况。在针对异构性的分析处理中,一些工作为了规避对异构图中不同关系的处理,通过提取子图的方法分别处理每种关系,但一些节点是由不同类型的边经过多跳连接的,这类方法没有充分利用节点之间的间接关联,难以全面地刻画兴趣点推荐系统中实体间关系的结构特征。另一些工作使用基于随机游走的采样方法,未考虑多个不同类型相邻节点之间影响程度不同的问题。为解决异构性问题,不同类型的边之间的相似性和关联性还有待进一步挖掘。图卷积网络在刻画每个节点特征的同时挖掘整张图的结构特征,此外也可通过设计转移矩阵处理不同类型的节点,目前它在兴趣点推荐系统中的运用还较少,在兴趣点推荐中使用更高效的图神经网络模型可以使LBSN多实体异构图中的特征得到更深入地挖掘和全面地刻画,进而提升兴趣点推荐的效果。

## 5 无签到用户兴趣点处理

兴趣点推荐系统一个值得关注的特征就是其兴趣点数量规模巨大,由于时间和地理位置的限制单个用户只能访问其中很少一部分,因此兴趣点推荐系统存在严重的数据稀疏性问题。能否有效处理正样本(历史访问过的兴趣点)和负样本(历史未访问过的兴趣点)之间的数量不平衡对于用户偏好建模的效果至关重要,一方面如何根据少量历史访问数据从大量未访问过的候选兴趣点中推荐用户可能感兴趣的兴趣点是一项巨大挑战;另一方面用户历史未访问过的兴趣点也可以借助其自身的地理位置信息以及LBSN中的社交信息等辅助推荐。

近几年,在深度学习领域,介于监督学习和无监督学习之间的半监督学习受到了广泛关注。利用少量有标签数据和大量无标签数据,结合数据分布上的特征来构建模型,可以有效提升模型的准确性,同时降低训练的成本,因此被广泛运用在有标签数据不足的场景中。在兴趣点推荐系统中,历史签到数据可以被看作是有标签的数据,而历史未被访问的兴趣点是无标签数据,虽然有标签的数据量较少,但兴趣点的时空特征、用户的社交特征等分布具有一定的规律性,因此半监督学习的思想可以被应用在兴趣点推荐任务中以缓解数据稀疏的问题。

除了直接利用用户未访问过的兴趣点的分布特征,另一种解决方案是利用生成模型从未访问的兴趣点中筛选出一些与用户历史访问的兴趣点特征更相似、用户可能更感兴趣的兴趣点,即有条件的负采样(negative sampling)。传统的负采样往往是从大量负样本中随机选择一部分,选出的负样本和正样本在数量上属于同一数量级,从而在一定程度上减轻数据不平衡带来的负面影响,但它无法获得更重要更有价值的负样本;随着生成对抗网络(Generative Adversarial Networks, GAN)<sup>[64]</sup>的出现和普及,该问题得到了有效地解决,使用生成器获取更可能被访问的兴趣点可以提升兴趣点推荐的性能。

### 5.1 半监督学习

为了充分利用兴趣点的地理位置信息和用户之间的社交关系来缓解数据稀疏性问题,文献[47]在模型有监督的损失函数之外又引入了无监督损失部分来保存上下文图中的上下文信息,上下文图包括基于地理位置的兴趣点邻居图和基于好友信息的用户社交图,模型借鉴了Skip-gram算法的思想,对于图中任意一个节点,最小化根据其嵌入预测上下文节点(图中与该点距离较近的节点)嵌入的对数损失,该思想满足了拥有相同上下文两个节点拥有相近的嵌入。模型的每一轮训练,先采样历史签到数据中的用户和兴趣点即有标签数据来训练模型的监督部分,再利用随机游走在两个上下文图中按一定比例分别采样出的一定数量的正样本和负样本,即节点和其上下文节点对、节点和其非上下文节点对,训练模型的无监督部分。最终模型在 Gowalla 数据集上推荐10个兴趣点时的命中率相比于没有无监督部分的模型提高了约15%。

半监督学习的核心思想是通过引入无监督损失以利用无标签数据本身的特征辅助预测用户感兴趣的兴趣点,无监督损失一般基于用户和兴趣点之间的关联所隐含的相似性和一致性特征,因此通常需要利用4.2节中的LBSN图表示,LBSN本身作为一种特殊社交网络的属性为半监督学习在其中的应用提供了基础。

### 5.2 生成对抗网络

除了使用半监督学习引入无监督损失,直接利用无标签数据本身的分布特征辅助兴趣点推荐之外,文献[62]提出了另一种思路即利用对抗学习模型缓解数据稀疏导致的模型欠拟合或过拟合问题并增强模型的鲁棒性,文中针对兴趣点推荐设计了一种结合地理特征和生成对抗网络的对抗学习模型 Geo-ALM,模型包括一个生成器(Generator)和一个鉴别器(Discriminator):其中生成器的目标是从未访问过的兴趣点中筛选出与访问过的兴趣点最相似的集合,即采样出更重要的负样本;鉴别器

的目标是对兴趣点进行排序,使得访问过的兴趣点排在未访问过的兴趣点之前,并使用了地理特征辅助排序。训练时,鉴别器根据排序正确的概率进行监督式训练。生成器的训练使用强化学习中的策略梯度方法,鉴别器排序正确的概率越小,奖励越大。生成器的使用提高了鉴别器的训练速度,训练完成后的鉴别器可以根据候选兴趣点的排序结果给用户提供兴趣点推荐。该模型在 Foursquare 数据集上对比基准方法推荐 3 个兴趣点时准确率提高了约 7%。文献[63]也利用生成对抗网络的架构提出了 APOIR 模型,不同于上述工作,模型直接以一种生成模型的方式学习用户的偏好,即最终的推荐结果由生成器产生,而不是由鉴别器的排序结果决定。这里的生成器可以看作是推荐器,用来刻画用户偏好并推荐用户可能感兴趣的兴趣点;而鉴别器则用来区分推荐的兴趣点和真实被访问过的兴趣点,其输出也可看作是用户对于一个输入的兴趣点的偏好程度,为生成器推荐的准确性提供判断。训练完成后,生成器可以基于用户偏好的分布推荐更可能被访问的兴趣点。模型训练的目标方程由两个最优化问题组成,其一针对鉴别器最大化辨别出历史真实访问过的兴趣点和生成器生成的兴趣点之间的概率;另一个针对生成器最大化生成的未访问过的兴趣点被预测为用户感兴趣的兴趣点的概率,即最小化鉴别器能分辨出生成器生成的兴趣点和真实被访问的兴趣点的概率。对于 Yelp 数据集上的兴趣点推荐,APOIR 模型相比于不使用对抗学习的基准方法推荐 5 个兴趣点的准确率至少提升了 10.0%。

在候选兴趣点数量较大的情况下,使用生成对抗网络通过生成器和鉴别器对抗的方式可以使得生成器从大量未访问过的兴趣点中筛选出与历史访问过的兴趣点更相似的兴趣点提供推荐,鉴别器也能更精确地分辨出用户感兴趣的兴趣点。相较于传统的随机负采样,生成对抗网络不仅可以在每一轮训练时使用数量尽可能平衡的正负样本,还可以使得训练样本更具有针对性,提高训练速度。

### 5.3 相关工作的不足

上述现有工作对兴趣点推荐准确率的提升证实了半监督学习和生成对抗模型可以有效缓解兴趣点推荐系统中的数据稀疏性问题,但这些相关工作只是将这两种思想引入了兴趣点推荐,未对 LBSN 中的其他特征进行充分利用,无监督损失和生成器是整个预测模型中相对独立的模块,可以针对各个 LBSN 的特点与其他相关工作中的兴趣点推荐的方法相结合以提高模型的推荐效果。例如,基于社交和地理特征相似性的无监督损失可以与相关工作中的其他性能更优的监督学习模型目标方程相

结合,生成对抗网络中的鉴别器也可以替换为更高效的基于排序的兴趣点推荐模型。

## 6 未来工作

根据上述分析可以发现,深度学习方法的应用可以有效解决兴趣点推荐系统中存在的挑战,但目前兴趣点推荐的相关工作依然存在不足,未来可以针对上述四方面相关工作的不足进行进一步地研究。此外除了本文总结的兴趣点推荐的四方面挑战,深度学习相关技术还可用于解决目前兴趣点推荐中一些尚未得到足够重视的问题。

首先,目前大多数的兴趣点推荐相关工作都着力于提高推荐的准确率,而推荐方法的时空复杂度没有得到足够的重视。目前大多数的研究都是离线推荐,它们在已有的数据集上进行分析和预测,但实际运用这些推荐算法时,在线推荐是不可避免的。由于每秒钟都会有大量的用户签到数据产生,历史可用作训练的数据集的规模较大且增长较快,其中体现出的用户偏好也会不断变化,因此需要不断更新模型以适应这种偏好变化。在效率和有效性之间做权衡,一种折中方案是将训练和推断模型拆分为离线和在线两部分,离线部分根据最近收集的数据定期重训练模型,其效率问题是可容忍的;在线部分基于最新的模型实时产生每个用户的兴趣点推荐结果,对效率敏感,但这种方案推荐的准确率一定程度上取决于模型更新的频率。未来工作可以考虑利用增量学习(incremental learning)<sup>[65]</sup>来持续对兴趣点推荐的模型进行更新<sup>[66]</sup>,增量学习不断利用新收集的数据来扩展模型知识,训练过程是高效且节省资源的,同时模型可以快速捕捉到用户偏好的变化。

其次,冷启动是兴趣点推荐的一个经典问题,预测新用户或新到访一个地区的用户的偏好是一项挑战。目前已有的兴趣点推荐方法往往需要挖掘用户的历史数据,但在一个 LBSN 中关于新用户的相关信息较少,不足以反映出他们的偏好。随着智能手机的普及以及各类应用数量的增加,用户往往会使用多个社交网络应用,即一个 LBSN 中的新用户很可能是其他社交网络的老用户。因此可以通过“跨站链接(cross-site linking)”<sup>[67]</sup>的方式从其他网络中获取更多用户相关数据来帮助兴趣点推荐。迁移学习<sup>[68]</sup>也是一种可以被运用的技术,它根据两个任务之间的相关性,重利用在一个任务上训练的模型去处理另一个任务。目前仅有很少一些工作<sup>[69-70]</sup>尝试使用迁移模型根据本地用户的偏好来推断新移民或游客的偏好。未来一个 LBSN 可以从其他 LBSN 或传统社交网络中获取更多反映用户、兴趣点特征以及社交关系的信

息以提升兴趣点推荐的效果。此外由于时空特征是兴趣点推荐的一个重要影响因子,因此一些交通数据可以被用来辅助推荐。

第三,用户的偏好是动态变化的,一个 LBSN 提供的兴趣点推荐服务不是一次性的服务,兴趣点推荐取决于已知的用户偏好,但同时用户偏好的变化也会受历史推荐的影响。现有的工作仅仅最优化了当前一次推荐的用户满意度而忽视了本次推荐对未来用户偏好的影响。强化学习<sup>[71]</sup>可以被引入兴趣点推荐以建模用户偏好的动态特征,该方法已被广泛应用于其他推荐系统如商品推荐<sup>[72]</sup>和新闻推荐中<sup>[73]</sup>,其主要思路是将推荐系统看作是一种追求用户效用(即奖励, reward)最大的策略(policy),每次推荐根据当前状态(state)计算出最优的动作(action),即推荐的兴趣点,再根据该行为进行状态转化,最终目标是最大化用户访问的兴趣点序列的效用之和,进而提高综合推荐效果。对于具体强化学习方法的选择,由于用户状态的刻画较复杂,状态空间较大,因此推荐系统中一般使用是深度强化学习模型,在文献[72]和[73]中均采用了基于值函数的 Deep Q-Learning (DQN)<sup>[74]</sup>的算法。由于候选兴趣点数量较大,动作空间也较大,在未来兴趣点推荐的研究中也可尝试使用基于策略梯度的深度强化学习算法,如 DDPG 算法<sup>[75]</sup>。为了解决兴趣点推荐中通常缺乏用户对历史签到的具体评分反馈导致效用无法判定的问题,使用逆强化学习(Inverse Reinforcement Learning, IRL)的方法在构建策略的同时获得奖励方程<sup>[76]</sup>。强化学习方法在模型训练时相较于监督学习需要的数据量更多,但在在线推荐场景下不会带来额外的效率损失,而在推荐时考虑未来用户长期满意度可以有效提升长期使用该 LBSN 的用户体验,提高应用的用户粘性。

## 7 结束语

本论文探讨了深度学习方法在兴趣点推荐上的应用,总结了兴趣点推荐中的四个挑战并回顾了使用深度学习解决这四个挑战的相关工作。深度学习的引入帮助兴趣点推荐系统更充分地从 LBSN 中的历史签到数据、用户生成内容、社交关系等信息中提取特征并获取多特征对于用户偏好的综合影响。此外,可以在一定程度上缓解数据稀疏性问题,提升了兴趣点推荐的效果。通过对深度学习方法应用的系统性分析,我们认为未来工作可进一步改进深度学习模型以克服现有相关工作的不足,增量学习、迁移学习和强化学习等方法可被应用以实现更新更快、效率更高、用户长期体验更好的兴趣点推荐系统。

## 参考文献

- [1] Koren Y, Bell R, Volinsky C. Matrix Factorization Techniques for Recommender Systems[J]. Computer, 2009, 42(8): 30-37
- [2] Mnih A, Salakhutdinov R R. Probabilistic Matrix Factorization[C] //Proc of Advances in Neural Information Processing Systems. Cambridge, MA: MIT, 2008: 1257-1264
- [3] Fouss F, Faulkner S, Kolp M, et al. Web Recommendation System Based on a Markov-Chain Model[C] //Proc of Int Conf on Enterprise Information Systems. New York: ACM, 2005: 56-63
- [4] Ahmed A A, Salim N. Markov Chain Recommendation System (MCRS)[J]. International Journal of Novel Research in Computer Science and Software Engineering, 2016, 3: 11-26
- [5] Wang S L, Chen Y L, Kuo A M H, et al. Design and evaluation of a cloud-based Mobile Health Information Recommendation system on wireless sensor networks[J]. Computers & Electrical Engineering, 2016, 49: 221-235
- [6] Bao J, Zheng Y, Wilkie D, et al. Recommendations in location-based social networks: a survey[J]. Geoinformatica, 2015, 19(3): 525-565
- [7] Liu S, Meng X. Recommender Systems in Location-Based Social Networks[J]. Chinese Journal of Computers. 2015, 38(02): 322-336 (in Chinese)  
(刘树栋,孟祥武.基于位置的社会化网络推荐系统[J].计算机学报, 2015, 38(02): 322-336)
- [8] Jiao X, Xiao Y, Zheng W, Zhu K. Research Progress of Recommendation Technology ins Location-Based Social Networks[J]. Journal of Computer Research and Development, 2018, 55(10):2291-2306 (in Chinese)  
(焦旭,肖迎元,郑文广,朱珂.基于位置的社会化网络推荐技术研究进展[J].计算机研究与发展, 2018, 55(10): 2291-2306)
- [9] Tobler W R. A Computer Movie Simulating Urban Growth in the Detroit Region[J]. Economic Geography, 1970, 46(sup1): 234-240
- [10] Mikolov T, Sutskever I, Chen K, Corrado GS, Dean J. Distributed Representations of Words and Phrases

- and their Compositionality[C] //Proc of Advances in Neural Information Processing Systems. Cambridge, MA: MIT, 2013: 3111–3119
- [11] Gao H, Tang J, Hu X, Liu H. 2013. Exploring Temporal Effects for Location Recommendation on Location-Based Social Networks[C] //Proc of the 7th ACM conference on Recommender systems (RecSys '13). Association for Computing Machinery, New York, NY, USA, 93–100.
- [12] Zhao S, Zhao T, Yang H, et al. STELLAR: Spatial-Temporal Latent Ranking for Successive Point-of-Interest Recommendation[C]//Proc of the AAAI Conf on Artificial Intelligence. 2016, 30(1).
- [13] Wang H, Shen H, Ouyang W, et al. Exploiting POI-Specific Geographical Influence for Point-of-Interest Recommendation[C]// Proc of the Twenty-seventh Int Joint Conf on Artificial Intelligence. 2018: 3877-3883.
- [14] Liu X, Liu Y, Li X. Exploring the Context of Locations for Personalized Location Recommendations[C] //Proc of the Int Joint Conf on Artificial Intelligence. Amsterdam: Elsevier, 2016: 1188-1194
- [15] Zhao S, Zhao T, King I, et al. Geo-Teaser: Geo-Temporal Sequential Embedding Rank for Point-of-interest Recommendation[C] //Proc of the World Wide Web Conf Companion. New York: ACM, 2017: 153-162
- [16] Feng S, Cong G, An B, et al. POI2Vec: Geographical Latent Representation for Predicting Future Visitors[C] //Proc of the 31st AAAI Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2017: 102-108
- [17] Pineda F J. Generalization of back-propagation to recurrent neural networks[C] //Proc of the Int Conf on Neural Information Processing Systems. New York: ACM, 1987:602-611
- [18] Hochreiter S, Schmidhuber J. Long Short-Term Memory[J]. Neural Computation, 1997, 9(8): 1735-1780
- [19] Yu F, Cui L, Guo W, et al. A Category-Aware Deep Model for Successive POI Recommendation on Sparse Check-in Data[C] //Proc of the World Wide Web Conf. New York: ACM, 2020: 1264-1274
- [20] Liu Q, Wu S, Wang L, et al. Predicting the Next Location: A Recurrent Model with Spatial and Temporal Contexts[C] //Proc of the 30th AAAI Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2016: 194-200
- [21] Al-Molegi A, Jabreel M, Ghaleb B. STF-RNN: Space Time Features-based Recurrent Neural Network for predicting people next location[C] //Prof of IEEE Symposium Series on Computational Intelligence. Piscataway, NH: IEEE, 2016: 1-7
- [22] Chen Y C, Thaipisutikul T, Shih T K. A Learning-Based POI Recommendation With Spatiotemporal Context Awareness[J]. IEEE Transactions on Cybernetics, 2020: Early Access.
- [23] Yao D, Zhang C, Huang J, et al. SERM: A Recurrent Model for Next Location Prediction in Semantic Trajectories[C] //Proc of the 2017 ACM on Conf on Information and Knowledge Management. New York: ACM, 2017: 2411-2414
- [24] Zhan G, Xu J, Huang Z, et al. A Semantic Sequential Correlation Based LSTM Model for Next POI Recommendation[C]//Proc of the 20th IEEE Int Conf on Mobile Data Management (MDM). IEEE, 2019: 128-137.
- [25] Huang J, Ling C X. Using AUC and Accuracy in Evaluating Learning Algorithms[J]. IEEE Transactions on Knowledge and Data Engineering, 2005, 17(3): 299-310
- [26] Liu T, Liao J, Wu Z, et al. A Geographical-Temporal Awareness Hierarchical Attention Network for Next Point-of-Interest Recommendation[C] //Proc of the 2019 on Int Conf on Multimedia Retrieval. New York: ACM, 2019: 7-15
- [27] Wang H, Li P, Liu Y, et al. Towards real-time demand-aware sequential POI recommendation[J]. Information Sciences, 2020, 547: 482-497
- [28] Li R, Shen Y, Zhu Y. Next Point-of-Interest Recommendation with Temporal and Multi-level Context Attention[C] //Proc of 2018 IEEE Int Conf on Data Mining. Piscataway, NH: IEEE, 2018: 1110-1115
- [29] Wu Y, Li K, Zhao G, et al. Long-and Short-term

- Preference Learning for Next POI Recommendation[C] //Proc of the 28th ACM Int Conf on Information and Knowledge Management. New York: ACM, 2019: 2301-2304
- [30] Feng J, Li Y, Zhang C, et al. DeepMove: Predicting Human Mobility with Attentional Recurrent Networks[C] //Proc of the World Wide Web Conf. New York: ACM, 2018: 1459-1468
- [31] Ma C, Zhang Y, Wang Q, et al. Point-of-Interest Recommendation: Exploiting Self-Attentive Autoencoders with Neighbor-Aware Influence[C] //Proc of the 27th ACM Int Conf on Information and Knowledge Management. New York: ACM, 2018: 697-706
- [32] McPherson M, Smith-Lovin L, Cook J M. BIRDS OF A FEATHER: Homophily in Social Networks[J]. Annual Review of Sociology, 2001, 27(1): 415-444
- [33] Fukushima K, Miyake S. Neocognitron: A Self-Organizing Neural Network Model for a Mechanism of Visual Pattern Recognition[M] //Competition and Cooperation in Neural Nets. Berlin: Springer, 1982: 267-285
- [34] Simonyan K, Zisserman A. Very Deep Convolutional Networks for Large-Scale Image Recognition[C] //Proc of Int Conf on Learning Representations, San Diego, CA, 2015
- [35] Wang S, Wang Y, Tang J, et al. What Your Images Reveal: Exploiting Visual Contents for Point-of-Interest Recommendation[C] //Proc of the World Wide Web Conf. New York: ACM, 2017: 391-400
- [36] Zhang Z, Zou C, Ding R, et al. VCG: Exploiting visual contents and geographical influence for Point-of-Interest recommendation[J]. Neurocomputing, 2019, 357: 53-65.
- [37] Yang D, Zhang D, Yu Z, et al. A Sentiment-Enhanced Personalized Location Recommendation System[C] //Proc of the 24th ACM Conf on Hypertext and Social Media. New York: ACM, 2013: 119-128
- [38] Xu G, Fu B, Gu Y. Point-of-Interest Recommendations via a Supervised Random Walk Algorithm[J]. IEEE Intelligent Systems, 2016, 31(1): 15-23
- [39] Blei D M, Ng A Y, Jordan M I. Latent Dirichlet Allocation[J]. Journal of Machine Learning Research, 2003, 3(Jan): 993-1022
- [40] Gao R, Li J, Du B, Yu Y, Song C, Ding Yss. A Synthetic Recommendation Model for Point-of-Interest on Location-Based Social Networks: Exploiting Contextual Information and Review[J]. Journal of Computer Research and Development, 2016, 53(04): 752-763 (in Chinese)  
(高榕,李晶,杜博,余永红,宋成芳,丁永刚.一种融合情景和评论信息的位置社交网络兴趣点推荐模型[J]. 计算机研究与发展, 2016, 53(04): 752-763)
- [41] Jiao X, Xiao Y, Zheng W, et al. R2SIGTP: A Novel Real-Time Recommendation System with Integration of Geography and Temporal Preference for Next Point-of-Interest[C] //Proc of the World Wide Web Conf. New York: ACM, 2019: 3560-3563
- [42] Xing S, Wang Q, Zhao X, et al. Content-aware point-of-interest recommendation based on convolutional neural network[J]. Applied Intelligence, 2019, 49(3): 858-871
- [43] Baral R, Zhu X L, Iyengar S S, et al. Reel: Review aware Explanation of Location Recommendation[C] //Proc of the 26th Conf on User Modeling, Adaptation and Personalization. 2018: 23-32.
- [44] Kim Y. Convolutional Neural Networks for Sentence Classification[C] //Proc of the 2014 Conf on Empirical Methods in Natural Language Processing. Stroudsburg: ACL, 2014: 1746-1751
- [45] Li H, Ge Y, Hong R, et al. Point-of-Interest Recommendations: Learning Potential Check-ins from Friends[C] //Proc of the 22nd ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining. New York: ACM, 2016: 975-984
- [46] Zhang S, Cheng H. Exploiting Context Graph Attention for POI Recommendation in Location-Based Social Networks[C] //Proc of Int Conf on Database Systems for Advanced Applications. Berlin: Springer, 2018: 83-99
- [47] Yang C, Bai L, Zhang C, et al. Bridging Collaborative Filtering and Semi-Supervised Learning: A Neural

- Approach for POI Recommendation[C] //Proc of the 23rd ACM SIGKDD Int Conf on Knowledge Discovery and Data Mining. New York: ACM, 2017: 1245-1254
- [48] Zhang J, Chow C. MOCA: Multi-Objective, Collaborative, and Attentive Sentiment Analysis[J]. IEEE Access, 2019, vol. 7, pp. 2019:10927-10936
- [49] Al-Smadi M, Talafha B, Al-Ayyoub M, et al. Using long short-term memory deep neural networks for aspect-based sentiment analysis of Arabic reviews[J]. International Journal of Machine Learning and Cybernetics, 2019, 10(8): 2163-2175.
- [50] He X, Liao L, Zhang H, et al. Neural Collaborative Filtering[C] //Proc of the World Wide Web Conf. New York: ACM, 2017: 173-182
- [51] Yin H, Wang W, Wang H, et al. Spatial-Aware Hierarchical Collaborative Deep Learning for POI Recommendation[J]. IEEE Transactions on Knowledge and Data Engineering, 2017, 29(11): 2537-2551
- [52] Longstaff I D, Cross J F. A pattern recognition approach to understanding the multi-layer perception[J]. Pattern Recognition Letters, 1987, 5(5): 315-319
- [53] Hinton G E. Deep belief networks[J]. Scholarpedia, 2009, 4(5): 5947
- [54] Chang B, Jang G, Kim S, et al. Learning Graph-Based Geographical Latent Representation for Point-of-Interest Recommendation[C] //Proc of the 29th ACM Int Conf on Information & Knowledge Management. 2020: 135-144.
- [55] Zhu J, Guo X. Deep Neural Model for Point-of-Interest Recommendation Fused with Graph Embedding Representation[C] //Proc of Int Conf on Wireless Algorithms, Systems, and Applications. Springer, 2019: 495-506.
- [56] Han H, Zhang M, Hou M, et al. STGCN: A Spatial-Temporal Aware Graph Learning Method for POI Recommendation[C] //Proc of 2020 IEEE Int Conf on Data Mining (ICDM). IEEE, 2020: 1052-1057.
- [57] Qiao Y, Luo X, Li C, et al. Heterogeneous graph-based joint representation learning for users and POIs in location-based social network[J]. Information Processing & Management, 2020, 57(2): 102151.
- [58] Yang D, Qu B, Yang J, et al. Revisiting User Mobility and Social Relationships in LBSNs: A Hypergraph Embedding Approach[C] //Proc of the World Wide Web Conf. New York: ACM, 2019: 2147-2157
- [59] Qian T, Liu B, Nguyen Q V H, et al. Spatiotemporal Representation Learning for Translation-Based POI Recommendation[J]. ACM Transactions on Information Systems, 2019, 37(2): 1-24
- [60] Kipf T N, Welling M. Semi-Supervised Classification with Graph Convolutional Networks[C] //Proc of Int Conf on Learning Representations. La Jolla, CA: ICLR, 2017:1-14
- [61] Wang Z, Zhang J, Feng J, et al. Knowledge Graph Embedding by Translating on Hyperplanes[C] //Proc of the 28th AAAI Conf on Artificial Intelligence. Menlo Park, CA: AAAI, 2014, 14(2014): 1112-1119[62] Liu W, Wang Z J, Yao B, et al. Geo-ALM: POI Recommendation by Fusing Geographical Information and Adversarial Learning Mechanism[C] //Proc of the Twenty-Eighth Int Joint Conf on Artificial Intelligence. 2019: 1807-1813
- [63] Zhou F, Yin R, Zhang K, et al. Adversarial Point-of-Interest Recommendation[C] //Proc of the World Wide Web Conf. New York: ACM, 2019: 3462-34618
- [64] Goodfellow I, Pouget-Abadie J, Mirza M, et al. Generative Adversarial Nets[C] //Proc of Advances in Neural Information Processing System. Cambridge, MA: MIT, 2014: 2672-2680
- [65] Rebuffi S A, Kolesnikov A, Sperl G, et al. iCaRL: Incremental Classifier and Representation Learning[C] //Proc of the IEEE conf on Computer Vision and Pattern Recognition. Piscataway, NH: IEEE, 2017: 2001-2010
- [66] He X, Zhang H, Kan M Y, et al. Fast Matrix Factorization for Online Recommendation with Implicit Feedback[C] //Proc of the 39th Int ACM SIGIR conf on Research and Development in Information Retrieval. New York: ACM, 2016: 549-558
- [67] Gong Q, Chen Y, Hu J, et al. Understanding

- Cross-Site Linking in Online Social Networks[J]. ACM Transactions on the Web, 2018, 12(4): 1-29
- [68] Pan W. A Survey of Transfer Learning for Collaborative Recommendation with Auxiliary Data[J]. Neurocomputing, 2016, 177: 447-453
- [69] Li D, Gong Z, Zhang D. A Common Topic Transfer Learning Model for Crossing City POI Recommendations[J]. IEEE Transactions on Cybernetics, 2018, 49(12): 4282-4295
- [70] Ding J, Yu G, Li Y, et al. Learning from Hometown and Current City: Cross-city POI Recommendation via Interest Drift and Transfer Learning[J]. Proc of the ACM on Interactive, Mobile, Wearable and Ubiquitous Technologies, 2019, 3(4): 1-28
- [71] Kaelbling L P, Littman M L, Moore A W. Reinforcement Learning: A Survey[J]. Journal of Artificial Intelligence Research, 1996, 4: 237-285
- [72] Chen S Y, Yu Y, Da Q, et al. Stabilizing Reinforcement Learning in Dynamic Environment with Application to Online Recommendation[C]//Proc of the 24th ACM SIGKDD Int Conf on Knowledge Discovery & Data Mining. 2018: 1187-1196.
- [73] Zheng G, Zhang F, Zheng Z, et al. DRN: A Deep Reinforcement Learning Framework for News Recommendation[C] //Proc of the World Wide Web Conf. New York: ACM, 2018: 167-176
- [74] Mnih V, Kavukcuoglu K, Silver D, et al. Human-level control through deep reinforcement learning[J]. nature, 2015, 518(7540): 529-533.
- [75] Silver D, Lever G, Heess N, et al. Deterministic Policy Gradient Algorithms[C]//Int conf on machine learning. PMLR, 2014: 387-395.
- [76] Massimo D, Ricci F. Harnessing a Generalised User Behaviour Model for Next-POI Recommendation[C]//Proc of the 12th ACM Conf on Recommender Systems. 2018: 402-406.