

文章编号: 2095-4980(2019)03-0502-07

基于深度学习与社交感知的地点推荐

王磊¹, 高宸², 周蓓², 李勇²

(1.天津市人民检察院, 天津 300222; 2.清华大学 电子工程系, 北京 100084)

摘要: 随着基于位置的社交网络的普及, 地点推荐作为推荐系统的重要分支, 在解决信息过载、提升用户体验、增加平台收益等方面的作用愈加明显。现有的地点推荐算法大多基于矩阵分解, 难以刻画用户和地点之间复杂的交互关系; 此外, 在基于位置的社交网络中, 社交信息是建立用户画像的重要数据来源, 如何融合社交信息辅助地点推荐成为亟待解决的问题。本文研究了基于深度神经网络的地点推荐解决方案, 通过设计基于社交信息的新型采样方式和正则化损失函数, 从两个角度融合社交信息。在两个真实世界数据集上的实验表明, 本文提出的方案可以极大提升地点推荐的精准度。

关键词: 地点推荐; 社交网络; 深度学习

中图分类号: TN915.5

文献标志码: A

doi: 10.11805/TKYDA201903.0502

Deep learning based social-aware location recommendation

WANG Lei¹, GAO Chen², ZHOU Bei², LI Yong²

(1.Tianjin Municipal People's Procuratorate, Tianjin 300222, China;

2.Department of Electronic Engineering, Tsinghua University, Beijing 100084, China)

Abstract: With the development of location based social network, location recommendation, a typical recommender system, plays a more and more significant role in addressing data overloading, enhancing user engagement and improving platforms' profit. Most existing researches on location recommendation are based on matrix factorization, which cannot capture the complicated relation between users and locations. In addition, in location based social network, social relation data is important for building user demographics, and therefore it becomes a major concern that how to combine social relation data to help improving recommendation quality. In this paper, a location recommendation approach based on deep learning is studied. By designing two novel designs, a social-aware sampler and a social-enhanced regularizer, the social information is integrated. Extensive experiments on two real-world datasets demonstrate that the proposed methods can significantly improve the recommendation accuracy compared with existing models.

Keywords: location recommendation; social network; deep learning

推荐系统是帮助用户以个性化方式发现可能感兴趣的内容信息的一种有用的筛选和过滤工具。随着在线信息的规模、复杂度和动态性的不断增加, 推荐系统已经成为解决这种信息过载问题并提供个性化服务的关键性解决方案。同时, 随着互联网和移动应用终端的普及, 推荐系统也成为许多在线网站和移动应用促进销售和提升服务质量的重要方式。地点(Point-of-Interest, POI)推荐作为推荐系统研究的一个重要分支, 在基于位置的社交网络(Location Based Social Network, LBSN)中发挥着重要作用。当前, 基于位置的社交网络在人们的日常生活中十分流行。国内常见的基于位置的社交网络如微信、大众点评等, 国外常见的如 Foursquare, Yelp 等。这些平台基于用户各自的偏好帮助用户发现其可能感兴趣的地点(如餐馆、酒店、旅游景点等), 并且允许用户通过签到(check-in)来分享自己的位置给朋友, 或通过发表评论来分享所去过地点的体验。以 Foursquare 这一流行的基于位置的社交网络为例, 截至 2018 年 4 月, Foursquare 收集了全球超过 120 亿次地点签到记录, 且月活用户数量达到 5 000 万人次^[1]。

在这样的实际背景下，通过挖掘用户地点签到记录和社交关系来改善地点推荐质量，从而改善基于位置的社交网络中的用户体验，不仅能够帮助 LBSN 服务提供商增加用户粘度，促进地点所属商家的发展机会，而且为数以千万计的用户带来更为便捷舒适的生活体验。因此，研究如何提供更好的地点推荐服务具有十分重要的研究意义和应用价值。

1 算法设计

已有的地点推荐方法大致可分为两类：一类是基于传统的矩阵分解方法，这类方法假定用户偏好是静态的，因此这类方法的局限性在于用户以不同顺序访问同样的地点集合将会获得相似的推荐结果^[2]；另一类方法是假定用户偏好是动态的，但已有的利用马尔可夫链(Markov Chain)建模用户访问地点的动态关系的方法^[3]只能对每对相邻反馈项之间的局部时序行为建模。

针对上述问题，许多研究者尝试基于深度学习方法来建模用户动态偏好，以提高地点推荐质量。其中，循环神经网络(Recurrent Neural Network, RNN)模型是最常见的用于从序列数据中捕获用户动态偏好的深度学习模型。如，F. Yu 等^[4]采用 RNN 模型扩展基于矩阵分解的带有隐式反馈的贝叶斯个性化排序(Bayesian Personalized Ranking, BPR)算法，该改进算法能够根据用户之前的购物车物品序列，向用户推荐一个购买物品排序列表。而 J. Manotumruksa 等^[5]针对 LBSN 中的地点推荐问题在文献[6]提出的 NeuMF 模型基础上加入 RNN 模型，提出了深度递归协同过滤(Deep Recurrent Collaborative Filtering, DRCF)模型，该模型能够同时建模用户的静态和动态偏好。但该模型并没有考虑用户间的社交关联，而用户间的社交关联是 LBSN 中用于辅助推荐的十分重要的信息来源^[7]。

1.1 深度递归协同过滤模型

DRCF 模型^[5]是在 NeuMF 模型^[6]的基础上针对 LBSN 中的地点推荐问题而设计的方法。DRCF 模型的主要贡献是在 NeuMF 模型基础上引入 RNN 模型来补充学习用户地点交互的动态时序特征，从而提升在这一特定应用场景下的推荐效果。DRCF 模型考虑到在地点推荐问题中，用户对地点的偏好不是静态的，而是随时间动态变化的，如用户可能喜欢在白天去商场，而在夜晚去酒吧。这种时序上可能存在的动态变化规律可以通过 RNN 模型来学习。因此，DRCF 模型中加入 RNN 部分来学习签到(checkin)数据中的用户动态偏好。值得注意的是，由于地点推荐任务在本质上是给用户生成一个地点推荐列表。因此，与基本的 NeuMF 模型不同，DRCF 模型采用以排序为目的的 pairwise loss 作为目标函数，即用户去过的地点排名应当高于用户并未去过的地点排名。另外，DRCF 模型中的 RNN 部分可以采用其他更为复杂的基于 RNN 的模型，如改进的长短期记忆网络(Long Short-Term Memory, LSTM)模型等。DRCF 模型结构如图 1 所示。

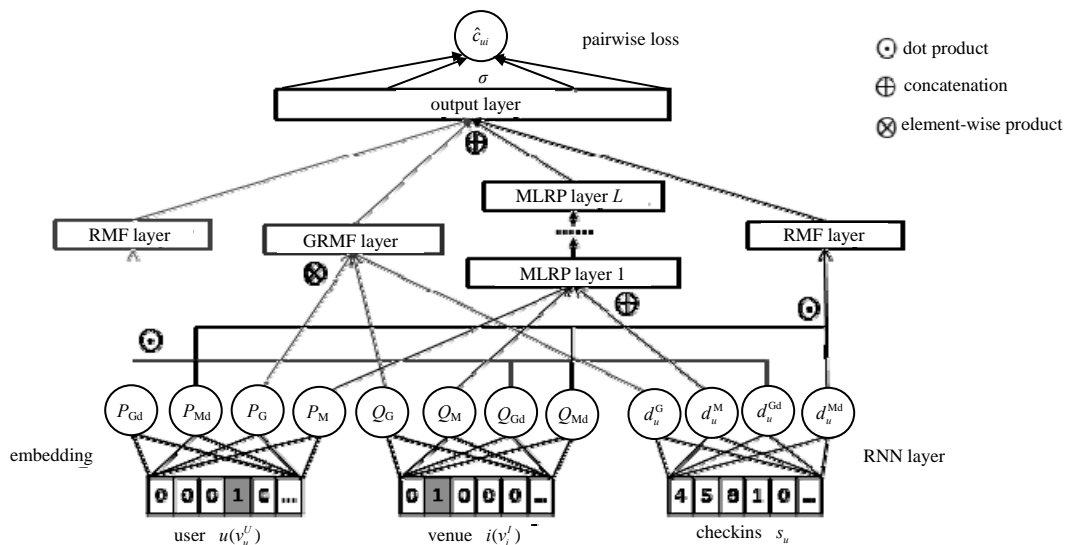


Fig.1 Deep Recurrent Collaborative Filtering(DRCF) model

图 1 深度递归协同过滤(DRCF)模型

DRCF 模型主要由三部分组成，分别为：GRMF(Generalized Recurrent Matrix Factorization); MLRP(Multi-Layer Recurrent Perceptron); RMF(Recurrent Matrix Factorization)。GRMF 用于学习用户地点交互的线性关系，

其采用的主要方式为逐元素点乘(模型中以 \otimes 表示); MLRP 学习用户地点交互的非线性关系; RMF 将用户静态 embedding 向量和用户动态时序特征向量逐元素相加, 得到一个表征用户静态(static)和动态(dynamic)偏好的向量, 然后再将这个向量与地点 embedding 向量做点积(模型中以 \odot 表示), 因此, RMF 学习的是另一种形式的用户地点交互的线性关系。最后, 将模型 3 个主要组成部分的输出向量进行拼接, 再经过输出层的非线性映射, 得到用户 u 对地点 i 进行签到(check-in)的预测概率值 \hat{c}_{ui} 。

1.2 融合社交网络的深度递归协同过滤模型

DRCF 模型考虑了用户的动静态偏好和地点的访问时序影响, 但该模型并未考虑 LBSN 中用户的社交关系属性, 而用户的社交关系是十分重要的可用于辅助推荐的信息来源^[7]。为方便理解用户的社交关系在地点推荐中的作用, 给出一个简化的 LBSN 模型, 如图 2 所示。

从图 2 中可以看出, LBSN 中用户访问过的地点与其具有社交关联的朋友所访问过的地点有一定重合。如, 用户 u_i 和其朋友 f_3 都访问过 l_2 这一地点。这种重合性体现了用户和其朋友在偏好上的相似以及用户和其朋友之间可能存在的社交影响。这种相似性和社交影响可用来辅助推荐, 并能有效解决冷启动用户问题。




Fig.2 Location Based Social Network
图 2 基于位置的社交网络

1.2.1 基于社交负采样改进的 DRCF 模型

基于社交负采样方案是从带有隐式反馈的地点推荐问题中的负样本采样角度来考虑用户的社交关系属性。在带有隐式反馈的推荐系统中, 由于真实负样本的缺乏, 如何对负样本进行采样是一个需要考虑的问题。传统的负样本采样方式是从用户没有访问过的地点中随机选择一些地点作为负样本用来训练^[6,8]。但针对 LBSN, 这种负样本采样方式过于简单, 随机采出的负样本与真实意义上的负样本可能存在很大差异。考虑到 LBSN 中社交关联用户的偏好相似性及用户间的社交影响, 本文提出基于社交关系的负采样方案, 即社交负采样方案。该方案假设用户和其具有社交关联的用户都没有访问过的地点更可能成为一个真实意义上的负样本。

为方便表述, 将用户 u_i 和其具有社交关联的用户 $\{z_1, z_2, \dots, z_k\}$ 都没有访问过的地点集合记作 \mathbf{R}_S , 将仅用户自己没有访问过的地点集合记作 \mathbf{R}_u 。在社交负采样过程中, 为了增加方案的灵活性, 引入 friend_prob 这一具有概率意义的参数。对训练过程中的每一次负样本采样, 都随机生成一个在 $[0,1]$ 之间的值, 如果该值小于 friend_prob, 则从地点集合 \mathbf{R}_S 中进行负样本采样, 也即得到的负样本被认为更接近真实意义上的负样本; 如果该值大于 friend_prob, 则从地点集合 \mathbf{R}_u 中进行负样本采样。通过调节 friend_prob 这一参数, 选择对用户进行普通负采样和社交负采样的最优比例。特别地, 如果将 friend_prob 设置为 1, 则对每一个用户而言, 都将为其进行社交负采样, 即都将在地点集合 \mathbf{R}_S 中进行负样本采样。

1.2.2 基于社交正则项改进的 DRCF 模型

从设计模型的目标函数角度来考虑用户的社交关系属性, 提出一种将社交正则项引入到 DRCF 模型的改进方案, 即社交正则项方案。该方案在 DRCF 模型的目标函数中增加社交正则项进行联合优化, 其数学表述为:

$$J(\theta) = \sum (\log(1 + e^{-\epsilon_u - \epsilon_{uk}})) + \lambda \text{Social}(\Omega, S) + \|\theta\|_F^2 \quad (1)$$

式中: θ 表示从社交信息中学习到的模型参数; S 表示用户间的社交关系; $\lambda \text{Social}(\Omega, S)$ 为社交正则项。

值得注意的是, 增加的社交正则项 $\lambda \text{Social}(\Omega, S)$, 从原则上来讲可以采用基于不同假设的不同社交正则方法。本文采用另外一种典型的社交正则方法 SocialMF^[9], 该方法更能够体现社交网络中朋友关系的信任强度和传递性^[10]。

SocialMF 方法的基本假设是认为用户的偏好应当和其具有社交关联的朋友们的平均偏好相似, 即认为用户自身的偏好隐向量应当和其朋友们的加权偏好隐向量在隐空间中的距离尽可能接近。SocialMF 方法的社交正则项定义为:

$$\text{Social}(\Omega, S) = \sum_{u \in U} \| \mathbf{p}_u - \sum_{s_{uu'} \in S} s_{uu'} \mathbf{p}_{u'} \|^2 \quad (2)$$

式中: \mathbf{p}_u 为用户 u 的偏好隐向量; $\mathbf{p}_{u'}$ 为用户 u 的其中一个社交关联朋友的偏好隐向量, $s_{uu'}$ 为用户 u 与用户 u' 之间的信任强度且取值在 $[0,1]$ 之间。一个用户 u 有多个朋友的情况下, SocialMF 方法将每个朋友各自的偏好隐向量以相同的权重 $s_{uu'}$ 进行求和, 这里需要将 $s_{uu'}$ 归一化, 即使得 $\sum_{u=1}^N s_{uu'} = 1$ 。在本文提出的社交正则项方案下,

引入 SocialMF 方法的 DRCF-SoReg 模型的完整目标函数表达式为：

$$J(\Theta) = \sum (\log(1 + e^{-(\hat{c}_{ui} - \hat{c}_{uk})})) + \lambda \sum_{u \in U} \|p_u\| - \sum_{s_{uu'} \in S} s_{uu'} \|p_u\|_2^2 + \|\Theta\|_F^2 \quad (3)$$

式中 λ 为控制社交正则项在整个目标函数中所占权重的超参数。由于 SocialMF 方法在本质上认为用户的每一个朋友对其影响都是相同的(归一化后每个朋友的偏好隐向量被分配了相同的权重值 $s_{uu'}$)，且拥有朋友数越多的用户，其每个朋友所分配的信任强度 $s_{uu'}$ 越低，因此，SocialMF 方法可能存在的局限性是不能很好地区分用户朋友中的强关联(strong tie)朋友和弱关联(weak tie)朋友，即用户朋友中有些朋友对该用户所起影响较大或共同偏好较多，有些用户所起影响较小或共同偏好较少。

2 实验验证

2.1 实验设置

2.1.1 实验环境

进行实验所使用的深度学习平台，其操作系统为 Ubuntu 16.04.3，其上安装有 Anaconda 2 Linux 4.3.1 Python 2.7。实验中使用的深度学习框架为 TensorFlow^[11]，版本 1.3.0。此外，为支持高效运算，深度学习平台配置了 2 个 NVIDIA TitanX GPU 和 2 个 NVIDIA TitanXp GPU，内存大小均为 16 G。同时，还安装有支持并行计算的 cuda-8.0 和基于深度学习的加速库 cudnn-v5.1。

2.1.2 实验数据

Brightkite 数据集^[12]是斯坦福大学(Stanford Network Analysis Project, SNAP)研究组公开的数据集。Brightkite 曾是一家 LBSN 服务提供商，用户可以通过签到来分享他们的位置，并拥有各自的朋友圈。Brightkite 数据集包含从 2008 年 4 月至 2010 年 10 月期间的用户日志，该数据集由两部分组成：用户进行签到操作的时间及位置数据；用户的朋友关系数据。其中，为简化社交网络分析，SNAP 研究组将 Brightkite 原始数据中有向(directed)的朋友关系处理为无向(undirected)的朋友关系，即 Brightkite 数据集中用户间的朋友关系是双方共有的。Yelp 数据集^[13]是由 Yelp 这一当前流行的 LBSN 服务提供商在其主办的数据挑战赛上公开的数据集。Yelp 数据集包含从 2009 年 4 月至 2017 年 12 月期间的用户日志，该数据集包含用户画像、商家属性、用户对商家的评论和用户的朋友关系等丰富的数据信息。其中，朋友关系数据中用户间的朋友关系是无向的。

经过预处理后的 Brightkite 数据集和 Yelp 数据集的基本统计信息如表 1 所示。

表 1 两个数据集的统计信息

Table 1 Statistics of two datasets

dataset	Brightkite	Yelp
number of users	7 703	13 420
number of users with social relation	7 037	7 352
number of locations	9 084	9 997
number of check-in records	464 405	201 349
sparsity of interaction matrix	0.66	0.15

2.1.3 评价方法与评价指标

为了评价模型的推荐性能，采用留一验证法(leave-one-out)作为模型的评价方法，该方法在带有隐式反馈的推荐系统研究中被广泛采用^[14,6,8]。留一验证法是将每个用户最近发生的一条交互记录留出并作为测试集，其余记录均作为训练集。考虑到时间成本，在实际测试时，对每个用户，采样 100 个该用户未曾访问过的地点作为负样本，然后通过模型预测该用户真实访问过的地点在这 100 个负样本中的排序。对于排序结果的评价，采用 2 种常用的评价指标，分别为：

1) HR@K: Hit Ratio(HR)评价的是用户地点交互值为 1 的测试地点集合中，即 Ground-Truth(GT)集合中，有多少地点出现在了最终推荐给用户的 top-K 推荐地点列表中。HR 的计算公式为：

$$HR@K = \frac{NumberOfHits@K}{|GT|} \quad (4)$$

2) NDCG@K: Normalized Discounted Cumulative Gain(NDCG)进一步考虑测试地点在最终地点推荐列表中的排序位置。如果排序靠前，证明推荐效果更好，则 NDCG 值更高；否则，NDCG 值较低。由于考虑的是带有隐式反馈的推荐问题，NDCG 的计算公式可以简化为：

$$NDCG@K = \sum_{i=1}^K \frac{1}{\log_2(i+1)} \quad (5)$$

2.1.4 实验参数设置

为对比本文提出的 2 种 DRCF-Social 模型的推荐性能，采用基准模型(baseline)包括第 NeuMF 模型和 DRCF 模型。由于 NeuMF 模型已经被实验证明其性能显著好于其他传统的基于矩阵分解的模型，如 BPR^[8]、eALS^[14]，

因此本文不再将其他基于矩阵分解的模型作为 baseline 加以考虑。本文所有模型的实现均基于 TensorFlow 这一开源的深度学习框架。按照 DRCF 模型中提出的参数设置方法, 将 DRCF-Social 模型(即 DRCF-SoSam 模型和 DRCF-SoReg 模型)中 embedding 层的用户隐向量和地点隐向量的维度, 以及 RNN 层的用户动态偏好隐向量的维度均设为相同的值, 即 $K=10$ 。由于 DRCF-Social 模型与 NeuMF 模型都采用多层感知机部分, 为保证公平的模型性能对比, 将 2 个模型该部分的隐藏层(hidden layer)的层数均设置为 $L=3$ 。用均值为 0, 标准差为 0.01 的高斯分布随机初始化所有的 embedding 向量、RNN 层输出向量以及多层感知机部分各隐藏层的权重矩阵和偏置。在模型训练时, 采用 Mini-Batch Adam^[15]优化上述模型参数, 该优化方法被证明能够比普通的随机梯度下降(Stochastic Gradient Descent, SGD)方法更快地收敛, 并且能够在每一次迭代时自动调整学习速率, 并在 [0.000 1, 0.001, 0.01] 范围内搜索初始学习率。对于社交负采样模型, 以 0.1 的步长在 [0, 1] 范围内对采样系数进行栅格搜索; 对于社交正则项模型, 在 [0.000 1, 0.001, 0.01, 0.1] 范围内搜索正则项系数。对于比较的基线方法, 同样进行超参数调优得到最优性能。

2.2 实验结果与分析

2.2.1 基于社交负采样方案的 DRCF-Social 模型

将基于社交负采样方案的 DRCF-Social 模型简记为 DRCF-SoSam, 以方便在实验结果图中进行标示。根据 HR@10 和 NDCG@10 两个模型性能评价指标, 分别在 Brightkite 数据集和 Yelp 数据集上对 NeuMF, DRCF 和 DRCF-SoSam 模型进行实验。为对比上述 3 个模型的性能, 记录每个模型在 50 次迭代过程中的训练误差 (Training Loss)、HR@10 和 NDCG@10。同时, 为分析 DRCF-SoSam 模型中 friend_prob 社交参数的影响, 选取不同的 friend_prob 参数值进行实验。

对于 Brightkite 数据集, 分析图 3 中实验结果, 可以得出: HR@10 评价指标中, DRCF-SoSam 模型的最优性能相较于 DRCF 模型和 NeuMF 模型分别提升约 1.9% 和 12.7%; NDCG@10 评价指标中, DRCF-SoSam 模型的最优性能相较于 DRCF 模型和 NeuMF 模型分别提升约 2.8% 和 38.2%。这表明, 针对 Brightkite 数据集, 基于社交负采样方案的 DRCF-SoSam 模型可以有效地改善地点推荐效果。

对于 Yelp 数据集, 分析图 4 中实验结果, 可以得出: DRCF-SoSam 模型在 HR@10 评价指标中最优性能比 DRCF 模型和 NeuMF 模型分别提升约 5.0% 和 7.0%; 在 NDCG@10 评价指标中, DRCF-SoSam 模型的最优性能比 DRCF 模型和 NeuMF 模型分别提升约 8.8% 和 19.3%。这表明, 针对 Yelp 数据集, DRCF-SoSam 模型同样能够显著改善 LBSN 中的地点推荐效果。

综合上述 2 个数据集的实验结果, 可以得出如下结论: 采用社交负采样方案的 DRCF-SoSam 模型, 通过选取合适的社交参数即 friend_prob 值, 可以有效提升 DRCF 和 NeuMF 模型的推荐性能。




Fig.3 Performance on Brightkite dataset
图 3 Brightkite 数据集性能

Fig.4 Performance on Yelp dataset
图 4 Yelp 数据集性能

2.2.2 基于社交正则项方案的 DRCF-Social 模型

同样, 将基于社交正则项方案的 DRCF-Social 模型简记为 DRCF-SoReg, 以方便在实验结果图中进行标示。分别在 Brightkite 数据集和 Yelp 数据集上对 DRCF-SoReg 模型进行实验, 并将其性能与 NeuMF 模型和 DRCF 模型进行对比。

Brightkite 数据集实验结果如图 5 所示, 可以看出, 在 Brightkite 数据集上, 采用社交正则项方案的 DRCF-SoReg 模型的推荐性能明显好于 DRCF 模型和 NeuMF 模型, 对于 HR@10 和 NDCG@10 两个评价指标的相对提升分别为 5.8% 和 4.5%。这种推荐性能上的提升反映了用户和其朋友间的地点访问偏好存在一定的相似性, 因此, 采用社交正则项来约束用户偏好隐向量和其朋友偏好隐向量间距离能够发挥其作用, 从而进一步改善 BSN 中的地点推荐质量。

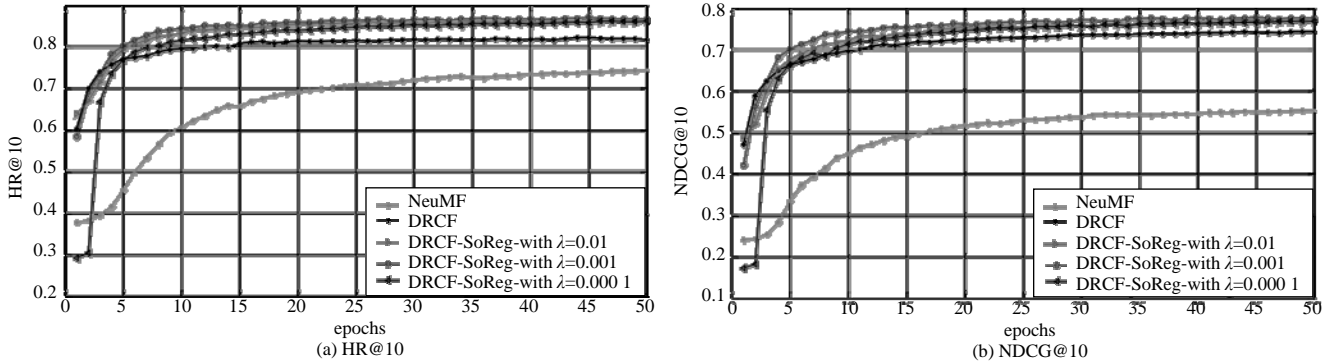


Fig.5 Performance on Brightkite
图 5 Brightkite 数据集性能

从图 6 可以看出，在 Yelp 数据集上，选取合适的社交正则项系数 λ ，DRCF-SoReg 模型性能可以显著优于 DRCF 模型和 NeuMF 模型。此外，对 Yelp 数据集，当 λ 取值为 0.000 1 时，DRCF-SoReg 模型在 2 个性能指标 HR@10 和 NDCG@10 上均达到最优，对于 HR@10 和 NDCG@10 两个评价指标的相对提升分别为 5.1% 和 3.7%；当 λ 取值为 0.001 时，DRCF-SoReg 模型的性能次之；当 λ 取值为 0.01 时，DRCF-SoReg 模型的 HR@10 性能接近于 λ 取值为 0.001 时的性能，但其 NDCG@10 性能则差于 DRCF 模型。

综合上述 2 个数据集的实验结果，可以得出如下结论：

1) 采用社交正则项方案的 DRCF-SoReg 模型，选取合适的社交正则项权重 λ ，能够显著提升模型的推荐性能。对于 Brightkite 数据集，HR@10 和 NDCG@10 两个评价指标的相对提升分别为 5.8% 和 4.5%；对于 Yelp 数据集，HR@10 和 NDCG@10 两个评价指标的相对提升分别为 5.1% 和 3.7%。

2) 不同的数据集，最优的 λ 参数取值不同。对于 Brightkite 数据集，当 λ 取值为 0.001 时，DRCF-SoReg 模型性能最优；对于 Yelp 数据集，当 λ 取值为 0.000 1 时，DRCF-SoReg 模型性能最优。

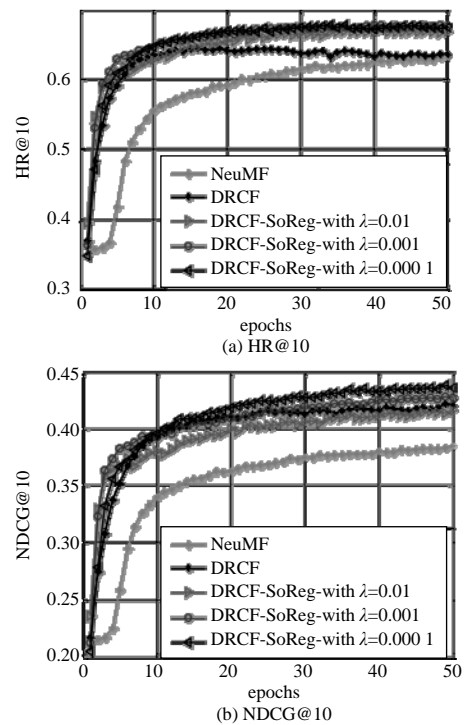


Fig.6 Performance on Yelp
图 6 Yelp 数据集性能

3 结论

本文研究了如何利用用户的社交关联来提高 LBSN 中的地点推荐质量。通过在 DRCF 模型基础上引入用户社交属性信息，提出了基于社交负采样的 DRCF-SoSam 模型、基于社交正则项的 DRCF-SoReg 模型，对提出的 2 个模型在 2 个公开的真实 LBSN 数据集 Brightkite 和 Yelp 上进行充分实验。实验结果表明，本文提出的 DRCF-SoSam 模型和 DRCF-SoReg 模型均能够一致且显著地提升地点推荐效果。

参考文献：

[1] Foursquare. About-Foursquare[EB/OL]. [2018-12-10]. <https://foursquare.com/about>.
 [2] LIAN D,ZHAO C,XIE X,et al. GeoMF: joint geographical modeling and matrix factorization for point-of-interest recommendation[C]// ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. New York,USA: ACM, 2014:831-840.
 [3] CHENG C,YANG H,LYU M R,et al. Where you like to go next: successive point-of-interest recommendation[C]// Proceedings of the Twenty-Third International Joint Conference on Artificial Intelligence. Beijing,China:AAAI Press, 2013:2605-2611.
 [4] YU F,LIU Q,WU S,et al. A dynamic recurrent model for next basket recommendation[C]// Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval. New York,USA:ACM, 2016: 729-732.

- [5] MANOTUMRUKSA J,MACDONALD C,OUNIS I. A deep recurrent collaborative filtering framework for venue recommendation[C]// Proceedings of the 2017 ACM on Conference on Information and Knowledge Management. New York, USA:ACM, 2017:1429–1438.
- [6] HE X,LIAO L,ZHANG H,et al. Neural collaborative filtering[C]// International Conference on World Wide Web Companion. Perth,Australia:[s.n.], 2017:173–182.
- [7] ZHAO S,KING I,LYU M R. A survey of point-of-interest recommendation in location-based social networks[C]// 2015 International Workshop on Trajectory-based Behaviour Analytics. Austin Texas,USA:AAAI, 2016:53–60.
- [8] RENDLE S,FREUDENTHALER C,GANTNER Z,et al. BPR:Bayesian personalized ranking from implicit feedback[C]// Proceedings of the Twenty-Fifth Conference on Uncertainty in Artificial Intelligence. Montreal,Canada:AUI, 2009:452–461.
- [9] JAMALI M,ESTER M. TrustWalker:a random walk model for combining trust-based and item-based recommendation[C]// ACM SIGKDD International Conference on Knowledge Discovery and Data Mining. Paris,France:ACM, 2009:397–406.
- [10] JAMALI M,ESTER M. TrustWalker:a random walk model for combining trust-based and item-based recommendation[C]// Proceedings of the 15th ACM SIGKDD international conference on knowledge discovery and data mining. New York,USA: ACM, 2009:397–406.
- [11] GOOGLE. Tensorflow[EB/OL]. [2018-12-10]. <https://www.tensorflow.org/>.
- [12] SNAP. Brightkite[DB/OL]. [2018-12-10]. <https://snap.stanford.edu/data/loc-brightkite.html>.
- [13] YELP. Yelp open dataset[DB/OL]. [2018-12-10]. <https://www.yelp.com/dataset>.
- [14] HE X,ZHANG H,KAN M Y,et al. Fast matrix factorization for online recommendation with implicit feedback[C]// Proceedings of the 39th International ACM SIGIR conference on Research and Development in Information Retrieval. New York,USA:ACM, 2016:549–558.
- [15] KINGMA D,BA J. Adam:a method for stochastic optimization[C]// 3rd International Conference for Learning Representations. San Diego,CA,USA:[s.n.], 2015:1–15.

作者简介:



王 磊(1980–), 男, 全日制硕士研究生, 从事信息化技术方向, 擅长网络建设、软件开发、深度学习等技术 .email:wangzhaolei929@163.com.

高 宸(1992–), 男, 安徽省泰州市人, 在读博士研究生, 主要研究方向为推荐系统.

周 蓓(1995–), 女, 北京市人, 在读硕士研究生, 主要研究方向为推荐系统.

李 勇(1985–), 男, 湖北省荆州市人, 在读博士研究生, 主要研究方向为大数据与人工智能.