

基于多元偏好信息的加权矩阵分解推荐算法

黄大广¹, 陆佳瑜²

(1. 中电鸿信信息科技有限公司, 江苏 南京 210000; 2. 中国电信股份有限公司张家港分公司, 江苏 张家港 215600)

摘要: 如何缓解数据稀疏性是推荐系统研究领域备受瞩目的问题之一,其目的是通过挖掘、融入异构的多元影响因素来拟合用户的隐藏偏好。现有推荐算法往往只关注单一的地理因素,容易忽视社交、时间、流行度等其他显著因素,使得推荐结果头部效应明显。为此,提出一种基于多元偏好信息的加权矩阵分解推荐算法 WMF-MP。该算法使用拉普拉斯核函数评估地理相关性,引入时间衰减因子模拟位置热度变化,设计可信度矩阵去除用户社交信息中的噪声,并设置权重矩阵增加推荐结果的多样性。在真实数据集 Gowalla 上进行实验,发现 WMF-MP 算法的精确率相较3个比较算法平均提高9%,召回率平均提高2%,验证了其有效性。

关键词: 兴趣点推荐; 矩阵分解; 数据稀疏性; 地理相关性; 社会相关性

DOI: 10.11907/rjdk.241752

开放科学(资源服务)标识码(OSID):

中图分类号: TP393

文献标识码: A

文章编号: 1672-7800(2025)007-0143-09



A Weighted Matrix Factorization Recommendation Algorithm Based on Multivariate Preference Information

HUANG Daguang¹, LU Jiayu²

(1. China Telecom Hongxin Information Technology Co., Ltd., Nanjing 210000, China;

2. Zhangjiagang Branch of China Telecom Co., Ltd., Zhangjiagang 215600, China)

Abstract: How to alleviate data sparsity is one of the highly anticipated issues in the field of recommendation system research, with the aim of fitting users' hidden preferences by mining and integrating heterogeneous and diverse influencing factors. Existing recommendation algorithms often only focus on a single geographical factor, which can easily overlook other significant factors such as social, time, and popularity, resulting in a significant head effect in recommendation results. Therefore, a weighted matrix factorization recommendation algorithm WMF-MP based on multiple preference information is proposed. This algorithm uses the Laplacian kernel function to evaluate geographic relevance, introduces a time decay factor to simulate changes in location popularity, designs a credibility matrix to remove noise from user social information, and sets a weight matrix to increase the diversity of recommendation results. Experiments were conducted on the real dataset Gowalla, and it was found that the accuracy of the WMF-MP algorithm increased by an average of 9% and the recall rate increased by an average of 2% compared to three comparison algorithms, verifying its effectiveness.

Key Words: POI recommendation; matrix factorization; data sparsity; geographical correlations; social correlation

0 引言

近年来,智能移动设备的普及以及5G网络的广泛覆盖推动了基于位置服务的应用迅速发展,衍生出一系列基于位置的社交网络(Location-based Social Networks, LB-

SN)。这种新兴的社交形式不仅使社交活动的个性化得以实现,而且可帮助用户更快地熟悉周围环境。因此,基于位置的兴趣点(Point of Interest, POI)推荐系统应运而生,成为用户发现共同好友、打卡热门地点的重要工具。

POI推荐算法与现实世界的地理位置联系紧密^[1-3]。近距离的POI往往比远距离的POI更容易影响到用户的选

收稿日期: 2024-08-30

扫描二维码阅读全文:

基金项目: 国家自然科学基金项目(61872196)

作者简介: 黄大广(1979-),男,硕士,中电鸿信信息科技有限公司工程师,研究方向为车联网、位置服务、推荐算法、机器学习等;陆佳瑜(1998-),女,硕士,中国电信股份有限公司张家港分公司工程师,研究方向为社交网络、位置服务、推荐算法、隐私保护等。本文通讯作者: 黄大广。



择。同时,一个POI的影响力更容易扩大到附近的位置点而不是远方的位置点。用户对不同POI的点赞、收藏、浏览量、评价等历史信息内容都能隐式地反映出用户偏好。如何利用好这些信息来提升POI推荐的准确率是该领域的重点研究课题。

1 相关研究

POI推荐的主要任务为计算出用户对尚未访问过的POI的偏好程度^[4]。影响推荐算法性能的因素非常广泛,包括地理位置坐标、地理位置语义、用户社交关系、时间因素、图像因素等^[5-6]。目前,国内外学者们通常会将这些因素融入POI推荐算法中以提高对用户偏好的学习效果,缓解签到数据稀疏性对推荐系统的影响。由于用户访问的POI受到地理距离的限制,学者们会使用高斯函数、决策树、随机森林、自适应带宽核估计、幂律分布等措施对统计区域的地理信息进行建模^[7-9]。

与传统的推荐系统相比,融入地理、社交信息的POI推荐系统更为复杂,具有以下特征:①地理信息影响。每个现实世界的POI都有唯一的经纬度坐标,可以与其他POI区分开。传统推荐系统中的物品可以是书籍、音乐、电影、商品等内容,而在POI推荐系统中,物品只能是POI;②社交信息影响。在LBSN中,一个人更可能喜欢朋友高度推荐的POI,即用户与朋友之间更可能分享共同的兴趣,而不是与陌生人分享。因此,用户的社交网络信息对于推荐系统也有极大影响。虽然一些研究者将地理信息和社交网络信息融入到推荐模型中,但他们普遍将POI的地理信息建模为位置间的距离分布,忽视了时间等其他因素。此外,部分研究者引入用户之间的置信度来加强用户相似度计算结果的可靠性,但大多数改进方法仍有其固有的局限性,例如相互信任的朋友不可能有完全一模一样的兴趣。因此,显式信任关系可能涉及过多噪声,从而影响推荐系统的性能。

协同过滤(Collaborative Filtering, CF)是一种经典的推荐算法,具体可分为基于用户的协同过滤(User-Based CF)和基于物品的协同过滤(Item-Based CF)两种。该算法通过计算用户相似度或位置相似度来为用户推荐得分最高的Top- n 个位置。例如,An等^[10]提出一种双向增强信任的CF模型,将时间因素引入用户的信任过滤,将地理位置和文本内容引入位置的信任过滤。Vahidnia^[11]提出一种基于相似度加权平均思想的空间核加权技术,能够替代高斯分布、幂律分布等其他分布为所有签到数据构建唯一的概率函数。Tourinho等^[12]提出一种基于模糊区域的协同过滤技术,利用用户活动来模拟其偏好并推荐下一次访问,特别适用于基于POI流行度的改进推荐算法。然而,CF十分依赖交互数据,很难应对数据稀疏性问题,并且随着用户数量、POI数量的增加,其计算复杂度会显著上升,

甚至难以运行。

矩阵分解(Matrix Factorization, MF)是POI推荐的另一种常用方法,其主要思想是将用户—POI的交互矩阵分解为两个低维潜在矩阵,通过训练这两个低维矩阵来使矩阵乘积能够逼近真实预测值,从而预估用户对尚未访问过的位置的偏好程度。例如,He等^[13]提出一种基于流行度的缺失数据加权方法,该方法比统一权重假设更有效、更灵活;同时设计出一种基于元素交替最小二乘技术的学习算法,显著提高了推荐模型的学习效率。Davalab等^[14]提出一种利用POI相似度与用户相似度的社会时空概率矩阵分解模型,根据不同空间中的POI相关性来估计用户对尚未访问过的POI的相关性得分。Zhou等^[15]提出一种改进的上下文感知加权矩阵分解POI推荐算法,使用艾宾浩斯遗忘曲线对时间衰减进行建模,精准捕获用户偏好随时间的波动情况。

虽然上述方法均对地理、社交等信息进行建模并将其引入MF模型中,实现了一定程度的性能提升,但仍有隐式信息提升的空间。为此,本文提出一种基于多元偏好信息的加权矩阵分解推荐算法(Weighted Matrix Factorization Recommendation Algorithm Based on Multivariate Preference Information, WMF-MP),额外将POI的位置语义、随时间衰减的位置热度融入地理建模中,能够缓解热门位置频繁被推荐的头部效应问题,亦能够为用户推荐位置语义相似的其他地点;同时通过sigmoid函数设计权重矩阵,以保障每个数据的权重值是平滑的,且具备鲁棒性,并为所有签到频次较低乃至为零的数据设置非零权值,以增加推荐结果的多样性。在真实数据集Gowalla上的实验结果证实了WMF-MP算法的有效性。

2 预备知识

2.1 相关定义

(1)签到矩阵。给定一个位置社交网络中用户历史签到的数据集,根据该数据集计算出用户—POI的签到矩阵 $R_{M \times N}$ 。数据集中包含 M 个用户和 N 个兴趣点,分别表示为 $U = \{u_1, u_2, \dots, u_M\}$, $POIs = \{POI_1, POI_2, \dots, POI_N\}$ 。矩阵元素 $r_{ui} \in R_{M \times N}$ 表示用户 u 对兴趣点 POI_i 的签到次数。

(2)位置热度。其是用于衡量位置受用户欢迎程度的指标。 POI_i 的位置热度计算公式为:

$$h_i = \frac{c/c'}{1 + \alpha |t_i - t_j|} \quad (1)$$

式中引入了时间衰减因子 $\alpha |t_i - t_j|$ 。其中, α 为控制时间衰减速度的参数; c 为 POI_i 最近被访问的次数; c' 为服务范围的时间段 $|t_i - t_j|$ 内 $POIs$ 被访问的总次数; t_i 为当前用户 u 访问 POI_i 的时间, t_j 为当前用户 u 访问 POI_j 的时间, t_i 与 t_j 越接近, h_i 值越大,表示 POI_j 对 POI_i 位置热度的影响越大。

(3)语义距离。对于任意两个兴趣点 POI_i 和 POI_j , 语义分别为 se_i 和 se_j 。则语义距离的计算公式为:

$$D(se_i, se_j) = \frac{D[|se_i|, |se_j|]}{\max(|se_i|, |se_j|)} \quad (2)$$

式中: $D[\cdot, \cdot]$ 为位置语义 se_i 与 se_j 的动态规划矩阵, 采用两者语义字符串长度的最大值来计算语义距离, 语义距离的值越大, 表示 POI_i 与 POI_j 的距离越远。

(4)皮尔逊相关系数。其能够度量两个变量之间的线性相关程度, 值通常介于 $[-1, 1]$ 。两个变量之间存在明显的线性关系时, 皮尔逊相关系数为 1 或 -1; 两个变量之间没有线性关系时, 皮尔逊相关系数为 0。一般情况下, 皮尔逊相关系数在 $[0.8, 1.0]$ 范围内表示极强相关, $[0.6, 0.8]$ 范围内表示强相关。皮尔逊相关系数的计算公式为:

$$\rho(X, Y) = \frac{E[(X - \delta_x)(Y - \delta_y)]}{\sigma_x \sigma_y} = \frac{E[(X - \delta_x)(Y - \delta_y)]}{\sqrt{\sum_{i=1}^n (X_i - \delta_x)^2} \sqrt{\sum_{i=1}^n (Y_i - \delta_y)^2}} \quad (3)$$

(5)Jaccard 相似系数。其通常用于衡量两个集合的相似度, 值越大, 表明两个集合的相似度越高。给定两个集合 A 和 B , 则集合相似性的计算公式为:

$$J(A, B) = \frac{|A \cap B|}{|A \cup B|} = \frac{|A \cap B|}{|A| + |B| - |A \cap B|} \quad (4)$$

使用 Jaccard 相似系数作为用户相似度计算中的权重值, 进而衡量共同签到过的 POI 对用户之间相似度的影响。

(6)MF。MF 起源于隐语义分析技术 (Latent Semantic Analysis, LSA), 其基本思想是将用户—POI 签到矩阵分解为两个低维潜在矩阵 P 和 Q , 则用户 u 对 POI_i 的预测值公式为:

$$\hat{r}_{ui} = P_u \cdot Q_i^T \quad (5)$$

式中: 矩阵 P 为用户低维潜在矩阵, $P = [p_1, p_2, \dots, p_M] \in \mathbb{R}^{M \times k}$; 矩阵 Q 为兴趣点低维潜在矩阵, $Q = [q_1, q_2, \dots, q_N] \in \mathbb{R}^{N \times k}$ 。

由于用户—POI 签到矩阵 R 具有稀疏性, 只有矩阵 R 中观察到的评级才能被因子分解。平方误差损失函数公式为:

$$L(P, Q) = \min_{P, Q} \frac{1}{2} \sum_{i=1}^M \sum_{j=1}^N (R_{ij} - P_i Q_j^T)^2 + \frac{\lambda_i}{2} \|P_i\|_F^2 + \frac{\lambda_j}{2} \|Q_j\|_F^2 \quad (6)$$

式中: $\lambda_i > 0, \lambda_j > 0$, 均为常数; $\|\cdot\|_F$ 为 Frobenius 范数。用户 u 对 POI_i 的偏好表示为 $p_u \cdot q_i^T$, 将用户 u 在 POI_i 上的签到次数记作 $\hat{r}_{ui} = p_u \cdot q_i^T$, POI_i 与向量 $q_i \in \mathbb{R}^k$ 有关, 用户 u 与 $p_u \in \mathbb{R}^k$ 有关。

通常通过最小化平方误差函数进行训练来得到最优模型。常见的更新矩阵 P 和 Q 的方法包括随机梯度下降

法和交替最小二乘法。本文采用交替最小二乘法进行模型训练。针对式 (6), 令 $\frac{\partial L}{\partial P_u} = 0, \frac{\partial L}{\partial Q_i} = 0$, 迭代计算得出 P_u 和 Q_i 的更新公式。表示为:

$$P_u \leftarrow r_{ui} Q_i (Q_i^T Q_i + \lambda_i I)^{-1} \quad (7)$$

$$Q_i \leftarrow r_{ui} P_u (P_u^T P_u + \lambda_j I)^{-1} \quad (8)$$

式中: I 为 $k \times k$ 维的单位矩阵; 求 P_u 的时间复杂度为 $O(k^2 A + k^3 M)$, 求 Q_i 的时间复杂度为 $O(k^2 A + k^3 N)$ 。

2.2 系统架构

推荐系统模型结构通常包括召回层、排序层和再排序层。不同层级的功能不同, 其中召回层采用高效的召回算法从海量的候选 POI 中迅速召回一批用户可能感兴趣的 POI; 排序层采用排序算法对初筛的 POI 进行精排; 再排序层通过引入一些策略确保最终推荐结果能够兼顾位置流行度、位置多样性等指标。本文重点研究排序层的推荐算法, 旨在根据用户特征和 POI 特征来预测用户对候选 POI 的喜好程度, 并将候选 POI 按照用户可能感兴趣的概率进行降序排列, 最终向用户呈现一批 POI。本文推荐算法使用 MF 思想, 主要分为数据收集与预处理、特征提取、MF 模型建立、模型训练与优化等步骤。数据收集步骤主要收集用户对位置的签到信息、用户社交关系信息、用户历史行为等。预处理是为了识别和处理数据中的错误、异常或不一致的部分, 包括处理缺失值、异常值、重复值等。该步骤可提高模型的准确性和稳定性, 避免由脏数据导致的模型训练和推荐结果偏差。特征提取指将原始数据转换为模型可以理解 and 处理的特征表示形式, 用于训练模型和生成推荐。建立 MF 模型后可输入提取到的特征信息, 根据推荐结果进行模型优化。以上步骤形成了一个闭环的推荐系统, 通过不断优化和更新模型可提高推荐的准确性和个性化程度, 进而提升用户的体验感和满意度。系统架构如图 1 所示。

3 WMF-MP 算法构建

3.1 地理信息建模

在位置社交网络中, 用户的行为与其所处的地理位置密切相关, 这也是 POI 推荐与其他商品推荐的不同之处。例如, 当用户需要储蓄时, 往往会选择上班地点/家庭住址周围的银行, 有时甚至会选择不符合个人偏好/利益但距离更近的银行。因此, 在地理分布上, 距离接近的 POI 容易呈现出空间聚集的现象。

本文使用拉普拉斯核函数 (Laplacian Kernel) 计算任意两个 POI 之间的相关程度。相较于其他核函数 (如高斯核函数), 拉普拉斯核函数具备一定优势: 首先, 其可以捕捉到数据的非线性特征, 能有效过滤掉相关程度较低的 POI 位置对, 更好地表达 POI 之间复杂的相似性和距离关系; 其次, 使用拉普拉斯核函数建模距离分布具有一定的




Fig. 1 System structure

图1 系统架构

可解释性,核函数值可以被解释为样本点之间的相似度或距离,有助于理解推荐模型的决策过程;最后,拉普拉斯核函数通常能够产生比较稀疏的解,有助于降低模型复杂度,提高泛化能力。具体而言,使用 $K(i, j)$ 表示任意两个POI(POI_i 和 POI_j)之间的相似度:

$$K(i, j) = e^{-\frac{\|x_i - x_j\|}{\sigma}} \quad (9)$$

首先计算出两个POI之间的曼哈顿距离,然后代入式(9)。当POI之间的距离较近时,拉普拉斯核函数的值将接近于1,表示它们的地理相似度较高;当POI之间的曼哈顿距离较远时,拉普拉斯核函数的值将逐渐减小,表示这两个点之间的相似度较低。

设计地理信息矩阵 $G_{M \times N}$,矩阵元素 g_{ui} 表示用户 u 对 POI_i 的地理偏好程度。计算公式为:

$$g_{ui} = \frac{\sum_{j \in N(u)} (\beta_1 K(i, j) + \beta_2 h_i + \beta_3 D(se_i, se_j)) \cdot r_{uj}}{\sum_{j \in N(u)} r_{uj}} \\ = \frac{\sum_{j \in N(u)} \left(\beta_1 K(i, j) + \beta_2 \frac{c/c'}{1 + \alpha |t_i - t_j|} + \beta_3 D(se_i, se_j) \right) \cdot r_{uj}}{\sum_{j \in N(u)} r_{uj}} \quad (10)$$

式中: $\beta_1, \beta_2, \beta_3$ 分别为距离分布 $K(i, j)$ 、位置热度 h_i 、语义距离 $D(se_i, se_j)$ 的超参数; α 为控制时间衰减速度的参数; $r_{uj} \in R_{M \times N}$; $N(u)$ 为用户 u 访问过的POI集合。用户的喜好会随着时间的推移而发生变化。例如,用户喜欢在周末去餐厅吃饭、商场购物,在工作日时间则趋向于两点一线的生活。本文提出的推荐算法会根据时间差来确定每个POI的热度 h_i ,在位置热度计算中引入时间衰减因子,强调用户近期签到的行为,减少早期签到行为对POI热度值

的影响。在推荐某个POI时,距离其最近签到的时间越远,推荐系统会认为用户访问该POI的可能性越小,POI位置热度越低。

3.2 社交关系建模

在日常生活中,有共同兴趣爱好用户容易形成好友关系,而且朋友之间经常会分享体验感比较好的场所。因此,将用户的社交关系引入模型中可在一定程度上提升推荐性能。

WMF-MP推荐算法通过充分考虑用户之间的置信度、相似度以及历史签到行为来建模社交关系,将其转化为用户访问POI的偏好概率。首先,采用皮尔逊相关系数计算出用户间的相似性。公式为:

$$sim_{um} = \frac{(r_{uj} - \bar{r}_u)(r_{mj} - \bar{r}_m)}{\sqrt{\sum_{j \in N(u) \cap N(m)} (r_{uj} - \bar{r}_u)^2} \sqrt{\sum_{j \in N(u) \cap N(m)} (r_{mj} - \bar{r}_m)^2}} \quad (11)$$

式中: $N(u) \cap N(m)$ 表示用户 u 与用户 m 共同访问过的位置集合; $\bar{r}_u, \bar{r}_m$ 分别为用户 u, m 访问POI的平均次数; $r_{uj} \in R_{M \times N}$,表示用户 u 访问POI j 的次数, r_{mj} 同理。

两个用户共同签到过的POI数量越多,其相似度越高,兴趣爱好更有可能相同;反之,若两个用户共同签到过的位置数量很少,则说明其相似度较低。采用Jaccard系数修饰用户相似度能够忽略用户行为的频率信息,只关注用户共同喜欢的位置。因此,本文引入Jaccard系数来计算共同签到POI对用户相似度的影响,计算公式见式(12)。式(13)为修正后的用户相似度。

$$JCC_{um} = \frac{|N(u) \cap N(m)|}{|N(u) \cup N(m)|} \quad (12)$$

$$sim_{um} = JCC_{um} \cdot \frac{(r_{uj} - \bar{r}_u)(r_{mj} - \bar{r}_m)}{\sqrt{\sum_{j \in N(u) \cap N(m)} (r_{uj} - \bar{r}_u)^2} \sqrt{\sum_{j \in N(u) \cap N(m)} (r_{mj} - \bar{r}_m)^2}} \quad (13)$$

虽然融入Jaccard系数的相似度能够衡量用户之间的相似性,但是为提高推荐系统的准确性和可靠性,确保推荐结果符合用户的实际需求和兴趣,还需要引入可信度进一步去除社交关系中的噪声,只有可信度满足阈值的相似度才会被推荐系统考虑。可信度的计算公式为:

$$Z_{um} = 1 - \frac{\sum_{j \in N(u) \cap N(m)} |r_{uj} - r_{mj}|}{r_{max}} \quad (14)$$

式中: Z_{um} 为用户 m 对于用户 u 的可信度; $N(u)$ 为用户 u 签到过的位置集合; $N(m)$ 为用户 m 签到过的位置集合; r_{uj}, r_{mj} 分别为用户 u 和 m 对POI j 的签到次数; r_{max} 为用户 u 访问次数最多的POI访问次数。

定义社交关系矩阵 $S_{M \times N}$,该矩阵能够刻画出用户社交关系对用户行为的影响程度。 $s_{ui} \in S_{M \times N}$ 表示用户 u 对

POI_i 的偏好概率。计算公式为:

$$s_{ui} = \frac{\sum_{m \in F(u)} sim_{um} \cdot Z_{um} \cdot C_{mi}}{\sum_{m \in F(u)} sim_{um}} \quad (15)$$

$$C_{mi} = \begin{cases} 1, & \text{用户 } m \text{ 访问过 POI}_i \\ 0, & \text{否则} \end{cases} \quad (16)$$

式中: 矩阵 C 为 0-1 矩阵, 如果用户 m 访问过 POI_i, 则 $C_{mi}=1$, 否则 $C_{mi}=0$; sim_{um} 为用户 u 与用户 m 的可信相似度, 计算方法见式 (13)。

3.3 多元偏好信息融入

将地理偏好信息与社交关系偏好信息线性组合^[16]。公式为:

$$e_{ui} = \mu g_{ui} + \varphi s_{ui} \quad (17)$$

式中: μ 用于控制地理偏好对用户访问 POI 行为的影响程度; φ 用于控制社交关系偏好对用户访问 POI 行为的影响程度。实际上, 对于不同 LBSNs 上的数据集, μ 和 φ 的值是不同的。一般情况下, $\mu > \varphi$, 地理因素的影响程度总是要比社交关系因素偏大一些。

MF 通过将高维的用户 POI 交互矩阵分解为两个空间中的低维潜在矩阵来降低计算复杂度。这两个矩阵为用户低维潜在矩阵和位置低维潜在矩阵, 分别用矩阵 $P_{M \times k}$ 和矩阵 $Q_{M \times k}$ 表示。MF 的过程表示为:

$$R \approx P \cdot Q^T \quad (18)$$

式中: $P_{M \times k} = [p_1, p_2, \dots, p_M]$, $Q_{M \times k} = [q_1, q_2, \dots, q_N]$, $k \ll \min(M, N)$ 。

根据前文计算地理偏好矩阵 G 和社交关系矩阵 S 。为了更精准地为用户推荐 POI, 在地理偏好矩阵中引入位置热度因素, 同时融入时间衰减因子, 确保始终跟上用户的兴趣变化。同时, 在社交关系矩阵中引入置信度及其权重, 确保能够从用户社交网络中挖掘出用户隐式偏好。因此, 推荐模型的目标函数为:

$$L(P, Q) = \min_{P, Q} \sum_{(u, i) \in R} (r_{ui} - \hat{r}_{ui} - e_{ui})^2 + \frac{\lambda_u}{2} \|P\|_F^2 + \frac{\lambda_i}{2} \|Q\|_F^2 + \frac{\lambda_g}{2} \|G\|_F^2 + \frac{\lambda_s}{2} \|S\|_F^2 \quad (19)$$

式中: $(r_{ui} - \hat{r}_{ui} - e_{ui})^2$ 为平方损失; 其余为加权正则项, $\lambda_u, \lambda_i, \lambda_g, \lambda_s$ 为正则项权重。

加权 MF 在大多数隐式反馈数据集中都能很好地运行, 因为其将没访问过的 POI 作为负反馈, 并为正反馈分配比负反馈更大的权重。如此以来, 负反馈的 POI 也有一定的机会被推荐, 可以帮助用户探索新的位置类型。加权矩阵 W 的计算公式为:

$$W_{ui} = \begin{cases} 1 + \frac{1}{1 + e^{-\theta \cdot r_{ui}}}, & \text{if } r_{ui} > 0 \\ 1, & \text{otherwise} \end{cases} \quad (20)$$

这种方式保证了所有的用户-POI 对都有一个非零的权重, 而且权重值会随着 r_{ui} 的增加而加大; 参数 $\theta > 0$, 用于控制权重随签到次数增长的速率。基于该加权矩阵, 隐

式反馈的目标函数更新为:

$$L(P, Q) = \min_{P, Q} \sum_{(u, i) \in R} (W \odot (R - PQ^T - \mu G - \varphi S))^2 + \frac{\lambda_u}{2} \|P\|_F^2 + \frac{\lambda_i}{2} \|Q\|_F^2 + \frac{\lambda_g}{2} \|G\|_F^2 + \frac{\lambda_s}{2} \|S\|_F^2 \quad (21)$$

式中: $\odot$ 为 Hadamard 运算符。设置权重后, 近似误差是在用户 POI 矩阵中的所有条目上求和, 计算量较大, 可通过最小交替二乘法有效降低计算复杂度。每次迭代的时间复杂度与访问位置的总数成比例, 即矩阵 R 中非零元素的数量。

在推荐系统中, 用户-位置的签到矩阵通常是稀疏的, 即 POI 的数量远远多于用户访问过的位置数量, 最小交替二乘法可以有效处理这种稀疏性。该算法的核心思想为通过交替优化用户和位置的低维潜在向量, 以最小化签到次数与实际签到次数之间的误差。在每次迭代中, 通过解决最小二乘问题来更新用户和位置的特征向量, 直到算法收敛为止。此外, 由于每次迭代只需要更新用户或位置的低维潜在向量, 算法可以有效利用并行计算资源加快训练速度, 即最小交替二乘法的迭代过程可以进行并行计算。具体步骤为:

(1) 固定变量 Q_i , 目标函数 $L(P, Q)$ 对变量 P_u 求偏导:

$$\frac{\partial L}{\partial P_u} = \sum_{(u, i) \in R} [2W_{ui}(P_u Q_i^T + \mu G_{ui} + \varphi S_{ui} - R_{ui})Q_i^T] + 2\lambda_u P_u \quad (22)$$

(2) 令目标函数 $L(P, Q)$ 对变量 P_u 偏导数为零, 求得 P_u 的更新为:

$$P_u \leftarrow (Q^T W_u Q + \lambda_u E)^{-1} Q^T W_u (R_u - \mu G_u - \varphi S_u) \quad (23)$$

(3) 固定变量 P_u , 目标函数 $L(P, Q)$ 对变量 Q_i 求偏导如下:

$$\frac{\partial L}{\partial Q_i} = \sum_{(u, i) \in R} [2W_{ui}(P_u Q_i^T + \mu G_{ui} + \varphi S_{ui} - R_{ui})P_u] + 2\lambda_i Q_i \quad (24)$$

(4) 令目标函数 $L(P, Q)$ 对变量 Q_i 偏导数为零, 求得 Q_i 的更新为:

$$Q_i \leftarrow (P^T W_i P + \lambda_i E)^{-1} P^T W_i (R_i - \mu G_i - \varphi S_i) \quad (25)$$

式中: $u \in \{u_1, u_2, \dots, u_M\}$, $i \in \{\text{POI}_1, \text{POI}_2, \dots, \text{POI}_N\}$ 。

综上所述, WMF-MP 算法的伪代码为:

输入: 用户-位置签到矩阵 $R_{M \times N}$, 潜在特征向量数 k , 正则化参数 $\lambda_u, \lambda_i, \lambda_g, \lambda_s$, 时间衰减因子 α , 参数 $\beta_1, \beta_2, \beta_3, \mu, \varphi, n$

输出: Top- n 个兴趣点

1 初始化低维潜在矩阵 $P_{M \times k}$ 和 $Q_{N \times k}$

2 计算地理偏好矩阵 $G_{M \times N}$

3 计算社会关系矩阵 $S_{M \times N}$

4 计算权重矩阵 $W_{M \times N}$

5 重构目标函数 $E(P, Q)$

6 while $\Delta error > \varepsilon$ or 迭代次数 $< \text{iteration}$

7 $P_u \leftarrow (Q^T W_u Q + \lambda_u E)^{-1} Q^T W_u (R_u - \mu G_u - \varphi S_u)$

8 $Q_i \leftarrow (P^T W_i P + \lambda_i E)^{-1} P^T W_i (R_i - \mu G_i - \varphi S_i)$

```

9   计算新的预测签到概率矩阵  $\hat{R} = P \cdot Q^T$ 
10  更新平方误差  $L(P, Q)$  的值
11  end while
12  for  $u \leftarrow 1$  to  $M$ 
13   for  $i \leftarrow 1$  to  $N$ 
14     $\hat{R}_{ui} = P_u \cdot Q_i^T$ 
15   end for
16 end for
17 对目标用户的推荐列表进行降序排序
18 return Top- $n$  个兴趣点

```

WMF-MP算法的输入参数为用户-位置的交互矩阵 $R_{M \times N}$ 、地理偏好矩阵 $G_{M \times N}$ 、社会关系矩阵 $S_{M \times N}$ 、权重矩阵 $W_{M \times N}$ 。在前文已经详细阐述过计算方法。初始化用户低维潜在矩阵 $P_{M \times k}$ 和兴趣点低维潜在矩阵 $Q_{N \times k}$ 后,按照预设的目标函数使用最小交替二乘法进行迭代,直至迭代次数结束或误差小于阈值。根据训练得到的低维潜在矩阵 P 和 Q 计算出用户对每个尚未访问过的 POI 的偏好值,并根据预设的 Top- n 值为用户推荐访问概率最大的前 n 个 POI,生成推荐列表。该算法的复杂度为 $O(N^2)$ 。具体参数设置需根据不同的数据集而定。

4 实验方法与结果分析

4.1 实验环境与参数设置

采用 Pycharm 2023.3 (Community Edition) 开发平台和 Python 编程语言对 WMF-MP 算法进行仿真实验。核函数的参数 σ 设置为 0.5,控制时间衰减速度的参数 α 设置为 0.1,控制正负反馈置信度的参数 θ 设置为 0.25,正则项权重 $\lambda_u = \lambda_i = \lambda_g = \lambda_s = 20$ 。在地理偏好矩阵 G 中,参数 $\beta_1, \beta_2, \beta_3$ 的大小可以按照对地理距离分布、位置流行度、位置语义距离的偏好程度个性化设置,本文将其均设定为 0.5。在目标函数 $L(P, Q)$ 中控制隐反馈项的参数 μ 和 φ 分别设置为 0.3 和 0.1,因为地理因素对决策的影响往往大于社交关系,具体可根据应用场景作适当调整。实验迭代轮数设置为 100 轮,实验精度设置为 0.000 1。

4.2 实验数据集

选取一个热门且具备代表性的 LBSN 数据集 Gowalla 来评估所提算法性能。该数据集集中有 18 737 个用户、32 510 个 POI、1 278 274 个签到记录、86 985 个好友关系数量,矩阵密度为 1.3×10^{-3} 。签到记录属性包括用户 id (user)、时间戳 (timestamp)、POI 纬度 (latitude)、POI 经度 (longitude)、POI id (location id)。社会关系用边关系来记录,一条记录所包含的 2 个用户 id 代表相应 2 个用户有社交关系。随机选取 Gowalla 数据集中 70% 的数据作为训练集,剩余 30% 作为测试集。

4.3 对照模型

为验证 WMF-MP 算法的性能,选取以下基于 MF 的推荐模型作为对照,分别为:①WMF (Weighted Matrix Factor-

ization)^[17]。该模型通过将用户-位置的交互矩阵分解为两个低维度的矩阵来进行推荐,同时引入加权项来考虑签到记录的权重,更好地反映用户的兴趣所在;②RME (Regularizing Matrix Factorization with User and Item Embeddings for Recommendation)^[18]。该模型结合加权 MF 嵌入共同喜欢位置和共同不喜欢位置,适用于显式和隐式反馈的数据集;③TRST (A Novel POI Recommendation Method Based on Trust Relationship and Spatial-Temporal Factors)^[19]。该模型设计了一种综合的信任关系计算方法,能够衡量用户之间的直接和间接信任关系;同时考虑了物品吸引力、物品之间的相关性、位置组成的轨迹以及兴趣遗忘在推荐结果生成过程中的影响,适用于复杂移动场景下的个性化 POI 推荐任务。

4.4 评价指标

采用精确率 (Precision) 和召回率 (Recall) 评估各模型性能。计算公式分别为:

$$Precision = \frac{1}{M} \sum_{u=1}^M \frac{|\xi(u) \cap \psi(u)|}{n} \quad (26)$$

$$Recall = \frac{1}{M} \sum_{i=1}^M \frac{|\xi(u) \cap \psi(u)|}{\psi(u)} \quad (27)$$

式中: $\xi(u)$ 为推荐模型为用户 u 预测的 POI 集合列表; $\psi(u)$ 为用户 u 在测试集中访问过的 POI 集合; n 为推荐列表长度, $|\xi(u)| = n$ 。

4.5 实验结果与分析

4.5.1 低维潜在矩阵维度的影响

图 2 为各算法精确率随低维潜在矩阵维度 K 值变化的趋势。可以看出,WMF-MP 算法的精确率最高,且会随着 K 值的增大而迅猛增加,其他算法则变化不那么明显和有规律性。增加 K 值意味着模型可以更好地捕捉用户偏好和 POI 特征,相当于增加了模型容量,使得模型可以更好地拟合训练数据,从而提高了推荐准确性。当然,增加 K 可能会增加复杂度和计算成本,需要在精确率与效率之间进行权衡。

图 2(a)、(b)、(c) 中的 top- n 值分别为 10、20 和 30。随着 top- n 值的增大,各算法的精确率反而在逐渐降低。这是由于增大 Top- n 值会使推荐模型提供更多不同类型的 POI,以满足用户的多样化需求,同时也增加了推荐列表中包含非用户感兴趣 POI 的可能性。当 top- $n=10$ 时,WMF-MP 算法的精确率平均比 RME 提高 0.185 9,比 WMF 提高 0.149 0,比 TRST 提高 0.157 1。当 top- $n=20$ 时,WMF-MP 的精确率平均比 RME 提高 0.149 5,比 WMF 提高 0.115 2,比 TRST 提高 0.130 4。当 top- $n=30$ 时,WMF-MP 的精确率平均比 RME 提高 0.127 4,比 WMF 提高 0.094 9,比 TRST 提高 0.113 1。

图 3 为各算法召回率随低维潜在矩阵维度 K 值变化的趋势。可以看出,WMF-MP 算法的召回率总体呈上升趋势,但增长速度逐渐放缓;WMF 算法的召回率是先增加再




(a) $\text{top-}n=10$ (b) $\text{top-}n=20$ (c) $\text{top-}n=30$

Fig. 2 The trend of accuracy of each algorithm with the variation of the low dimensional latent matrix dimension K value

图 2 各算法精确率随低维潜在矩阵维度 K 值变化的趋势

减小; RME 和 TRST 算法的召回率是 4 个模型中表现较差的, 但是总体趋于稳定。这是由于 RME 算法除了收集用户—POI 的交互信息外, 还额外收集用户之间的共同喜好和共同厌恶反馈, 后者收集起来比较困难, 因此其表现受到数据集的限制。而 TRST 算法中地理因素影响与信任关系影响的结合是简单的相乘, 学习到的特征有限。随着 $\text{top-}n$ 值的增大, 可以看到融入地理偏好和社交关系偏好的 WMF-MP 算法的表现越来越好, 意味着其能逐渐涵盖更多用户可能感兴趣的 POI。在 WMF-MP 算法中, 如果一个 POI 有着更少的访问次数, 则用户对其未访问过的 POI

成为负样本的概率会更高。相反, 用户经常访问的 POI 会有更高的权重, 更容易成为正例。在权重矩阵中, 使用 sigmoid 函数引入非线性因素有助于模型更好地设置不同签到记录的权重。实验结果表明, 当 $\text{top-}n=10$ 时, WMF-MP 算法的召回率平均比 RME 提高 0.026 9, 比 WMF 降低 0.004 3, 比 TRST 提高 0.025 1; 当 $\text{top-}n=20$ 时, WMF-MP 算法的召回率平均比 RME 提高 0.041 1, 比 WMF 提高 0.012 5, 比 TRST 提高 0.039 7; 当 $\text{top-}n=30$ 时, WMF-MP 算法的召回率平均比 RME 提高 0.051 4, 比 WMF 提高 0.024 0, 比 TRST 提高 0.049 1。




(a) $\text{top-}n=10$ (b) $\text{top-}n=20$ (c) $\text{top-}n=30$


Fig. 3 The trend of recall of each algorithm with the variation of the low dimensional latent matrix dimension K value

图 3 各算法召回率随低维潜在矩阵维度 K 值变化的趋势


4.5.2 正则项参数的影响

正则化是一种防止过拟合的技术,而正则项参数则用于控制正则化项的强度。一般情况下,正则项参数值并不是越大越好。设置越大的正则项参数则惩罚力度越重,模型越倾向于简单的解,可能会导致欠拟合。设置越小的正则项参数则惩罚力度越轻,模型能更好地训练数据并捕捉其模式,但可能导致过拟合。前文实验中的正则项参数值设置为 20。以下研究正则项参数在 $[0, 10, 20, 30, 40, 50]$ 范围内变化时对各算法精确率的影响,结果见图 4。


可以看出,正则项参数以 10 的步长增加时对各算法的



(a) top-n=10



(b) top-n=20



(c) top-n=30

Fig. 4 The trend of accuracy of each algorithm with the variation of regularization parameters

图 4 各算法精确率随正则项参数变化的趋势

整体准确率影响并不大。随着推荐列表变多,WMF-MP 算法的精确率反而有细微下降,而 WMF、RME 和 TRST 算法的精确率几乎不变。这是由于推荐列表扩大后,WMF-MP 算法会考虑为用户推荐更多类别的 POI,导致精确率受到影响。具体而言,当 top-n=10 时,WMF-MP 算法的精确率平均比 RME 提高 0.094 7,比 WMF 提高 0.083 3,比 TRST 提高 0.058 2;当 top-n=20 时,WMF-MP 算法的精确率平均比 RME 提高 0.070 7,比 WMF 提高 0.059 5,比 TRST 提高 0.043 8;当 top-n=30 时,WMF-MP 算法的精确率平均比 RME 提高 0.055 3,比 WMF 提高 0.045 6,比 TRST 提高 0.036 1。

图 5 为各算法召回率随正则项参数变化的趋势。整体来看,WMF 和 WMF-MP 算法的召回率较高,随着推荐列表的增加,WMF-MP 算法的召回率也随之增加,逐渐超过 WMF。正则项参数的增大增加了惩罚力度,使得各算法在训练集和测试集上的性能有所下降,召回率出现较大波动。WMF-MP 算法中有地理信息和社交信息作为额外的特征,能够提供更多辅助信息,帮助模型更好地学习用户与 POI 之间的关系。因此,即使正则项参数在逐步变大,WMF-MP 算法仍然可以通过地理信息和社交信息来补充特征,减轻了正则项对模型性能的影响,因此召回率波动相对较小。RME 算法由于对用户之间共同不喜欢的 POI 的依赖性较大,在 Gowalla 数据集上表现不佳,召回率增长速度比较平缓。TRST 算法的召回率随着推荐列表长度的增加而逐渐增大,这是由于该模型中不同 POI 对用户相似度的贡献与该 POI 受欢迎的程度和时间遗忘系数有关,导致不受欢迎的商品也有很高的概率会被推荐给目标用户。具体而言,当 top-n=10 时,WMF-MP 算法的召回率平均比 RME 提高 0.005 7,比 WMF 降低 0.008 6,比 TRST 提高 0.011 5;当 top-n=20 时,WMF-MP 算法的召回率平均比 RME 提高 0.013 8,比 WMF 提高 0.001 2,比 TRST 提高 0.011 3;当 top-n=30 时,WMF-MP 算法的召回率平均比 RME 提高 0.017 8,比 WMF 提高 0.007 5,比 TRST 提高 0.015 6。

5 结语

为提高推荐算法的准确性和个性化程度,本文提出一种基于多元偏好信息的加权矩阵分解推荐算法 WMF-MP。该算法在地理信息中不仅考虑了 POI 地理距离上的分布,而且考虑了各个 POI 随着时间推移的位置热度变化以及语义类型;同时在用户社交关系中考虑了好友的兴趣影响,引入可信度矩阵和 Jaccard 稀疏来去除无效噪声。在 Gowalla 数据集上将 WMF-MP 算法与一些常用推荐算法进行比较,较高的精确率和召回率证实了所提算法的有效性。然而,POI 推荐需要向服务提供商提供精确的位置和查询 POI 的内容,这可能会给用户带来个人隐私泄露的风险。今后需要研究位置隐私保护相关技术,以确保推荐服务的安全性和私密性。




Fig. 5 The trend of recall of each algorithm with the variation of regularization parameters

图5 各算法召回率随正则项参数变化的趋势

参考文献:

- [1] ZHU J H, MING Q. POI recommendation by incorporating trust-distrust relationship in LBSN [J]. Journal on Communications, 2018, 39 (7): 157-165.
朱敬华, 明霄. LBSN 中融合信任与不信任关系的兴趣点推荐[J]. 通信学报, 2018, 39(7): 157-165.
- [2] MENG X F, ZHANG X Y, TANG Y H, et al. A diversified and personalized recommendation approach based on geo-social relationships [J]. Chinese Journal of Computers, 2019, 42(11): 2574-2590.
孟祥福, 张霄雁, 唐延欢, 等. 基于地理-社会关系的多样性与个性化兴趣点推荐[J]. 计算机学报, 2019, 42(11): 2574-2590.
- [3] LI S, LIU G Y, HE X X. A recommendation method for point-of-interest

partition based on category transfer weighted tensor decomposition model [J]. Journal of Electronics & Information Technology, 2022, 44 (1): 203-210.

李胜, 刘桂云, 何熊熊. 基于类别转移加权张量分解模型的兴趣点分区推荐[J]. 电子与信息学报, 2022, 44(1): 203-210.

- [4] GUO L, JIANG H, WANG X, et al. Learning to recommend point-of-interest with the weighted Bayesian personalized ranking method in LBSNs [J]. Information, 2017, 8(1): 20.
- [5] ROSSI L, WILLIAMS M, STICH C, et al. Privacy and the city: user identification and location semantics in location-based social networks [C]//Proceedings of the International AAAI Conference on Web and Social Media, 2015: 387-396.
- [6] ZHOU J, LIU B, CHEN Y, et al. UFC: a unified POI recommendation framework [J]. Arabian Journal for Science and Engineering, 2019, 44: 9321-9332.
- [7] CHANG L, CHEN W, HUANG J, et al. Exploiting multi-attention network with contextual influence for point-of-interest recommendation [J]. Applied Intelligence, 2021, 51: 1904-1917.
- [8] ZHANG J D, CHOW C Y. Geosoca: exploiting geographical, social and categorical correlations for point-of-interest recommendations [C]//Proceedings of the 38th International ACM SIGIR Conference on Research and Development in Information Retrieval, 2015: 443-452.
- [9] MO F, YAMANA H. Point of interest recommendation by exploiting geographical weighted center and categorical preference [C]//2019 International Conference on Data Mining Workshops (ICDMW), 2019: 73-76.
- [10] AN J, JIANG W, LI G. Bidirectional trust-enhanced collaborative filtering for point-of-interest recommendation [J]. Sensors, 2023, 8: 4140.
- [11] VAHIDNIA M H. Point-of-interest recommendation in location-based social networks based on collaborative filtering and spatial kernel weighting [J]. Geocarto International, 2022, 37(26): 13949-13972.
- [12] TOURINHO I A D S, RIOS T N. FACF: Fuzzy areas-based collaborative filtering for point-of-interest recommendation [J]. International Journal of Computational Science and Engineering, 2021, 24(1): 27-41.
- [13] 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, 2016: 549-558.
- [14] DAVTALAB M, ALESHEIKH A A. A POI recommendation approach integrating social spatio-temporal information into probabilistic matrix factorization [J]. Knowledge and Information Systems, 2021, 63: 65-85.
- [15] ZHOU X, WANG Z, LIU X, et al. An improved context-aware weighted matrix factorization algorithm for point of interest recommendation in LBSN [J]. Information Systems, 2024, 122: 102366.
- [16] PENG H W, JIN Y Y, LYU X Q. Context-aware POI recommendation based on matrix factorization [J]. Chinese Journal of Computers, 2019, 42(8): 1797-1811.
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, 42(8): 1797-1811.
- [17] HU Y, KOREN Y, VOLINSKY C. Collaborative filtering for implicit feedback datasets [C]//2008 Eighth IEEE International Conference on Data Mining, 2008: 263-272.
- [18] TRAN T, LEE K, LIAO Y, et al. Regularizing matrix factorization with user and item embeddings for recommendation [C]//Proceedings of the 27th ACM International Conference on Information and Knowledge Management, 2018: 687-696.
- [19] XU C, DING A S, ZHAO K. A novel POI recommendation method based on trust relationship and spatial-temporal factors [J]. Electronic Commerce Research and Applications, 2021, 48: 101060.

(责任编辑: 尹晨茹)