



武汉大学学报(信息科学版)

Geomatics and Information Science of Wuhan University

ISSN 1671-8860, CN 42-1676/TN

《武汉大学学报(信息科学版)》网络首发论文

题目: 顾及微地图推荐因子的深度信念网络
作者: 牛雪磊, 杨军, 闫浩文
DOI: 10.13203/j.whugis20230053
收稿日期: 2023-06-04
网络首发日期: 2023-07-14
引用格式: 牛雪磊, 杨军, 闫浩文. 顾及微地图推荐因子的深度信念网络[J/OL]. 武汉大学学报(信息科学版). <https://doi.org/10.13203/j.whugis20230053>



网络首发: 在编辑部工作流程中, 稿件从录用到出版要经历录用定稿、排版定稿、整期汇编定稿等阶段。录用定稿指内容已经确定, 且通过同行评议、主编终审同意刊用的稿件。排版定稿指录用定稿按照期刊特定版式(包括网络呈现版式)排版后的稿件, 可暂不确定出版年、卷、期和页码。整期汇编定稿指出版年、卷、期、页码均已确定的印刷或数字出版的整期汇编稿件。录用定稿网络首发稿件内容必须符合《出版管理条例》和《期刊出版管理规定》的有关规定; 学术研究成果具有创新性、科学性和先进性, 符合编辑部对刊文的录用要求, 不存在学术不端行为及其他侵权行为; 稿件内容应基本符合国家有关书刊编辑、出版的技术标准, 正确使用和统一规范语言文字、符号、数字、外文字母、法定计量单位及地图标注等。为确保录用定稿网络首发的严肃性, 录用定稿一经发布, 不得修改论文题目、作者、机构名称和学术内容, 只可基于编辑规范进行少量文字的修改。

出版确认: 纸质期刊编辑部通过与《中国学术期刊(光盘版)》电子杂志社有限公司签约, 在《中国学术期刊(网络版)》出版传播平台上创办与纸质期刊内容一致的网络版, 以单篇或整期出版形式, 在印刷出版之前刊发论文的录用定稿、排版定稿、整期汇编定稿。因为《中国学术期刊(网络版)》是国家新闻出版广电总局批准的网络连续型出版物(ISSN 2096-4188, CN 11-6037/Z), 所以签约期刊的网络版上网络首发论文视为正式出版。

DOI:10.13203/j.whugis20230053

引用格式：

牛雪磊, 杨军, 闫浩文. 顾及微地图推荐因子的深度信念网络[J]. 武汉大学学报(信息科学版), 2023, DOI: 10.13203/j.whugis20230053 (NIU Xuelei, YANG Jun, YAN Haowen. Deep Belief Networks Considering WeMaps' Recommendation Factors [J]. *Geomatics and Information Science of Wuhan University*, 2023, DOI: 10.13203/j.whugis20230053)

顾及微地图推荐因子的深度信念网络

牛雪磊¹, 杨军^{1,2*}, 闫浩文¹

¹兰州交通大学测绘与地理信息学院, 甘肃 兰州 730070;

²兰州交通大学电子与信息工程学院, 甘肃 兰州 730070

摘要：在微地图推荐系统的冷启动阶段，针对传统深度信念网络无法高效挖掘数据中的细粒度信息而导致推荐精度下降的问题，提出了顾及微地图推荐因子的深度信念网络。利用聚类的结构化信息和深度信念网络中丰富的语义信息缓解推荐系统在冷启动阶段推荐精度低的问题，并且挖掘出用户和微地图的隐语义交互信息，达到“千人千面”的推荐效果。首先，采用针对噪声数据的基于密度的空间聚类算法对用户与微地图历史样本进行聚类；然后，选取出核心点（即推荐因子）、边界点及离群点，将聚类后的推荐因子构建成不同的可视层与隐含层；最后，将受限玻尔兹曼机的可视神经元替换为高斯单元，利用深度信念网络对输入数据从低层到高层进行逐层微调训练，以提升推荐的准确性。在美食、自驾、旅游、校园四类微地图数据集上推荐的精度分别为 0.77532、0.76818、0.77518、0.77464，推荐的均方误差分别为 0.19078、0.19476、0.19033、0.19092。实验结果表明，本文算法可以为用户准确地推荐感兴趣的微地图信息。

关键词：微地图；推荐系统；深度信念网络；推荐因子；特征值

Deep Belief Networks Considering WeMaps' Recommendation Factors

NIU Xuelei¹, YANG Jun^{1,2}, YAN Haowen¹

1. Faculty of Geomatics, Lanzhou Jiaotong University, Lanzhou 730070, China;

2. School of Electronic and Information Engineering, Lanzhou Jiaotong University, Lanzhou 730070, China

项目资助：国家自然科学基金（42261067）；2021年度中央引导地方科技发展资金（2021-51）；兰州市人才创新创业项目（2020-RC-22）；兰州交通大学天佑创新团队（TY202002）。

第一作者：牛雪磊，博士生，主要从事深度学习、地理信息系统等研究。E-mail: NXLnxl186186@163.com

***通讯作者：**杨军，博士，教授，主要从事深度学习、三维模型空间分析、遥感大数据智能解译、地理信息系统等研究。E-mail: yangj@mail.lzjtu.cn

Abstract: Objectives: In the cold start phase of the Wemaps' recommendation system, traditional deep belief networks have low efficiency in mining fine-grained information, resulting in a decrease in recommendation accuracy. Therefore, this paper proposes a **Deep Belief** network considering WeMaps' recommendation **Factors** (DBRFact). The structured information of clustering and rich semantic information in the deep belief networks are used to alleviate the problem of low recommendation accuracy during the cold start. In addition, the implicit semantic interaction information between the users and the WeMaps is mined to implement customized recommendations. **Methods:** First, a Density-Based Spatial Clustering of Application with Noise clustering algorithm is employed to cluster the historical samples of the users and the WeMaps. Secondly, the core points (i.e., recommendation factors), boundary points, and outliers are selected, and the recommendation factors are constructed into different visual and hidden layers. Finally, the visual neurons of the restricted Boltzmann machine are replaced with Gaussian units. Then, a deep belief network is used to fine-tune the input data from low level to high level to improve the recommendation accuracy. **Results:** The accuracies on the FoodMaps, DrivingMaps, TourMaps, and SchoolMaps datasets were 0.77532, 0.76818, 0.77518 and 0.77464, respectively, and the Root Mean Square Errors (RMSE) were 0.19078, 0.19476, 0.19033 and 0.19092, respectively. **Conclusions:** The experimental results have showed that the proposed algorithm can accurately recommend the interested WeMaps' information for users.

Key words: WeMaps; recommendation system; deep belief network; recommendation factor; eigenvalue

现代社会正在经历从工业化到信息化的转变, 自媒体是在互联网技术的发展普及和后现代文化的双重影响下出现的^[1-2], 以平民化、个性化、低门槛、易操作、微内容、交互强、传播快^[3]为特点的自媒体信息传播模式, 已经对各行各业产生深远的影响。地图是地理空间信息的记录载体和传播工具, 对人类社会至关重要^[4-7]。由于传统地图制作门槛高、更新难、传播慢等特点, 无法满足自媒体时代大众地理信息传播的需求。在自媒体时代制作地图需有大众用户的实时参与, 在分发和传播上需要及时、方便、快捷, 在信息传播时不但具有由点到面的广播功能, 而且要有点到点^[8]和面到面的互播功能, 因此微地图的概念应运而生。微地图^[8]是面向平民大众的“草根”地图, 对精度等数学基础要求不高, 制作者无需进行严格的专业培训, 地图用户能够参与地图制作, 地图可以如微信一样方便、快捷地交互传播和应用, 在投入使用后势必产生海量的数据, 可能造成因信息量远超微地图

用户信息需求、信息处理及信息利用能力, 导致用户无法准确挑选与运用有效信息。所以, 为满足地图的智能化、个性化^[9]推荐, 有必要从历史数据中尽可能挖掘潜在的经济和社会价值, 从而预测用户的需求并推荐给用户感兴趣的内容。

推荐算法^[10]为用户推荐相关领域感兴趣的内容, 也为商业决策提供帮助。传统的商品、电影推荐算法一般采用显式评分的方式获取用户偏好和历史行为, 结合用户的历史行为采用协同过滤^[11]、采用基于内容的推荐方法^[12]或采用基于混合推荐方法^[13]就能够实现较准确的推荐结果。其中, 文献[14]使用幂函数的方式进行协同过滤, 利用用户与项目之间的交互信息为用户推荐, 然而该算法遭遇严重的冷启动问题(新用户和新项目往往没有历史评分数据)。基于内容的推荐方法, 文献[15]使用用户感兴趣的项目寻找其他类似属性的候选项目, 该算法严重依赖于人工设计特征, 其有效性及可扩展性非常有限, 降低了基于内容推荐方法的性能。微

地图推荐相对于传统电影、商品推荐主要存在以下两个方面的困难与挑战：一方面，用户的偏好往往以隐式的方式存在于历史签到数据中，以签到次数或签到频率表示偏好，致使无法准确理解用户具体的偏好程度；另一方面，现实世界中位置众多，而每个用户访问的地点只是其中极少的一部分，用户没有在访问的地点进行签到行为。由此造成了微地图历史签到信息存在数据量大、间歇性、稀疏性等问题，用户对推荐的内容体验效果较差，亟需收到与自己兴趣相关的高质量信息。

随着互联网中越来越多的数据能够被获取，包括图像、文本、标签在内的多源异构数据，其蕴含着丰富的用户行为信息以及个性化需求信息，能够缓解推荐系统中冷启动问题，因此，融合多源异构辅助信息(Side Information)的混合推荐方法^[16-17]越来越受到重视。由于辅助信息往往具有多模态、数据异构、大规模、数据稀疏和分布不均匀等复杂特征，融合多源异构数据的混合推荐方法依然面临着严峻的挑战^[18-19]。

微地图个性化推荐^[20-21]取得了突破性的进展，为微地图推荐系统的研究带来新的机遇。为解决冷启动阶段的推荐精度低的问题，聚类分析是推荐系统中数据分析与挖掘应用的有效方法，它通过衡量研究对象之间的相似度，将相似度高的对象划分为同类。针对噪声数据的基于密度的空间聚类算法^[22](Density-Based Spatial Clustering of Application with Noise, DBSCAN)主要目标是寻找被低密度区域分离的高密度区域，无需指定簇的个数，能够对任意形状的数据集进行聚类，常用于离群点监测。文献[23]提出嵌入异构情感意识的兴趣推荐，整合基于社区情感提取的潜在概率分布得到情感与感知网络嵌入模型，学习用户和文本感情等重要因素在低维嵌入网络中表达，并利用联合训练对异构网络中所有的边进行交替采样。然而，该算法偏向于学习相邻特征的组合，难以适用于无时序关系的数据。受限玻尔兹曼机^[24](Restricted Boltzmann Machine,

RBM)是在玻尔兹曼机(Boltzmann Machine, BM)的基础上，采用对比散度^[25](Contrastive Divergence, CD)算法，只需迭代一次就可获得对模型的估计，使得RBM的训练效率在一定程度上得以提升。深度信念网络(Deep Belief Network, DBN)是一种由多层非线性变量连接组成的生成模型，通过逐层抽取输入信息的无监督学习和用固定标签微调整个网络的监督学习，解决了学习多个隐含层参数的难度问题。

综上所述，随着微地图推荐系统应用场景的不断扩大及复杂性的增强，现有研究成果在单独使用深度信念网络进行模型训练时，由于缺乏深入研究用户显式的特征，忽略了用户的差异性，致使用户自身的多样性特征没有被充分挖掘和利用，势必会导致推荐算法的灵活性较差；而若单独使用DBSCAN聚类算法分别对用户、微地图数据进行聚类，不能有效挖掘用户与微地图交互的隐式特征，由于隐式特征具有灵活多变、不宜捕捉的特点，缺乏隐式特征时往往存在难以跨越从低阶特征到高阶特征的语义鸿沟，导致“数据丰富、但语义信息匮乏”的问题，从而降低了微地图在冷启动阶段推荐的精度。因此本文结合DBSCAN和深度信念网络，提出顾及微地图推荐因子的深度信念网络(Deep Belief networks considering WeMaps recommendation Factors, DBRFact)，可以融合描述微地图推荐系统中微地图、用户之间的关系模型，使得微地图推荐算法不再局限于分析用户或地图之间关系，从而使用户获得个性化的精准推荐。

1 原理方法

用户与微地图数据不仅数量大，而且存在噪声，导致用户与微地图数据对DBN的预测精度产生较大影响。如果将所有的用户与微地图数据都加入到预测模型中，会带来大量的数据噪声，降低推荐的精度。本文旨在微地图推荐系统的冷启动阶段也能有较好的推荐效果，笔者提出

顾及微地图推荐因子的深度信念网络，在深度信念网络训练前，先使用 DBSCAN 对微地图用户进行预处理，选取出核心点（微地图的推荐因子），即从影响用户选择的优先程度、用户因素界定的难易程度等不同方面考虑，细粒度挖掘推荐因子，为深度信念网络在编码多尺度特征向量时，提供有效的推荐因子进行模型训练，以提高微地图推荐系统在冷启动阶段的推荐精度。

1.1 模型架构

本文提出了顾及微地图推荐因子的深度信念网络模型（DBRFact），其网络结构如图 1 所示，主要由四部分组成：输入数据、DBSCAN、深度信念网络和输出微地图推荐结果。

(1) 输入数据

输入为可扩展数据：通用的各类专题微地图的历史数据、以及用户与各类专题微地图历史交互数据。

(2) DBSCAN

使用 DBSCAN 算法对微地图数据集、微地图与用户交互的历史样本数据进

行聚类，并选择出核心点即影响微地图推荐的推荐因子。

(3) 深度信念网络

由于深度信念网络输入的可视层必须是二元值，因此将其第一层 RBM 替换为高斯二元受限玻尔兹曼机（Gaussian-binary Restricted Boltzmann Machine, GRBM），GRBM 的输出作为第二层 RBM 的输入，以此类推，直到第五层 RBM。如图 1 所示，深度信念网络结构中的 v 为输入， $O(v)$ 为模型的输出， b_i 表示可视层节点 i 的偏置， c_j 表示隐含层节点 j 的偏置。在开始训练网络之前，随机初始化权重矩阵 w_{ij} 、可视层 v 的阈值和隐含层 h 的阈值，然后基于逐层预训练和微调更新 w_{ij} 、 v 和 h 的值，直到达到收敛。

(4) 输出微地图推荐结果

模型最终输出用户感兴趣的微地图推荐结果，如旅游微地图、校园微地图、美食微地图和自驾微地图等等。

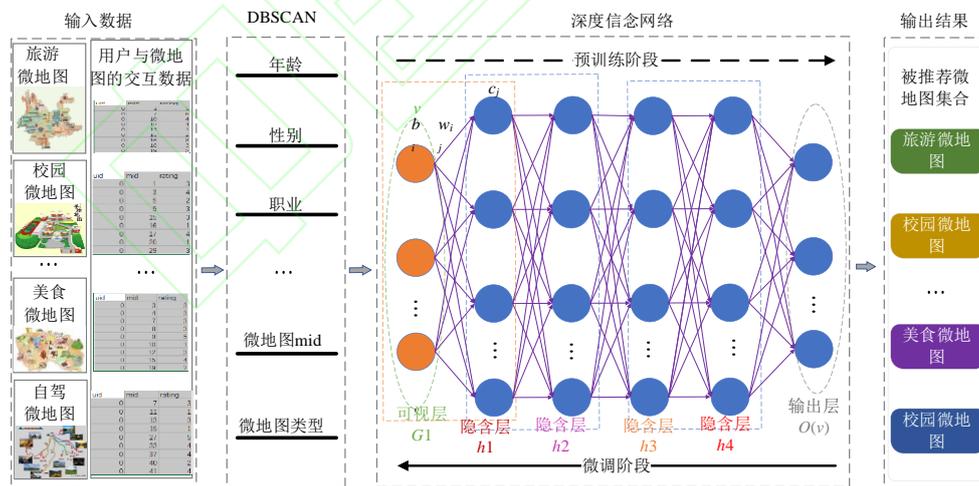


图 1 顾及微地图推荐因子的深度信念网络结构图

Fig.1 Structure of DBRFact Algorithm

1.2 DBSCAN 聚类

微地图数据集中的密度分布是对微地图空间现象的一种场表达，能够反映不同

用户群体对不同专题微地图的偏好程度。在实际的地理空间中，人类的社会经济活动在不同的空间尺度下，往往表现为若干兴趣点的聚集，并在不同的空间统计单元

中形成强度等级各异的聚集中心。不同微地图区域下聚集不同的中心区，通过密度噪声应用空间聚类，能够较全面地反映微地图的空间分布，表达不同层次微地图中心的显著程度。基于密度的噪声应用聚类方法主要目标是寻找被低密度区域分离的高密度区域，通过过滤低密度区域，发现稠密样本点，能够形成不同形状的簇，并且可以消除孤立点和噪声对聚类质量的影响。本文采用 DBSCAN 聚类算法，在未知训练样本标记信息的情况下，识别出噪声点并生成任意形状的簇，有效区分各类别之间的差异。该算法通过参数(ϵ , $Minpts$)来描述样本分布紧密程度。其中， ϵ 是邻域的半径， $Minpts$ 是聚类为一簇所需要的最少采样点的数量。

1.3 深度信念网络

受限玻尔兹曼机(Restricted Boltzmann Machine, RBM)是一种满足玻尔兹曼分布与热力学能量分布的概率图模型，如图 2 所示。通过训练不断更新网络参数的权重值，旨在使模型中的数据分布尽可能拟合训练数据的分布。由 n 个可视层节点与 m 个隐含层节点组成受限玻尔兹曼机的能量函数 $E(\mathbf{v}, \mathbf{h})$ ，如式 1 所示：

$$E(\mathbf{v}, \mathbf{h}) = -\left(\sum_{i=1}^n \sum_{j=1}^m v_i w_{ij} h_j + \sum_{i=1}^n b_i v_i + \sum_{j=1}^m c_j h_j\right) \quad (1)$$

其中， \mathbf{v} 表示可视层， \mathbf{h} 表示隐含层， v_i 表示第 i 个可视层节点， h_j 表示第 j 个隐含层节点， w_{ij} 表示可视节点 i 与隐含节点 j 之间的权重值， b_i 表示可视节点 i 的偏置， c_j 表示隐含节点 j 的偏置。

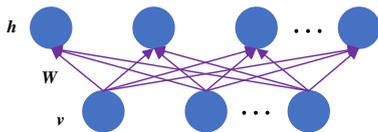


图 2 RBM 网络结构图

Fig.2 The Structure of RBM

给定能量函数后，所有可视层与隐含层的联合概率分布 $p(\mathbf{v}, \mathbf{h})$ 如式 2 所示：

$$p(\mathbf{v}, \mathbf{h}) = \frac{e^{-E(\mathbf{v}, \mathbf{h})}}{\mathbf{Z}} \quad (2)$$

其中， \mathbf{Z} 为配分函数，也被称为归一化因子，如式 3 所示。

$$\mathbf{Z} = \sum_{\mathbf{v}} \sum_{\mathbf{h}} e^{-E(\mathbf{v}, \mathbf{h})} \quad (3)$$

在采样过程中，当给定可视层节点状态 \mathbf{v} 时，第 j 个隐含层节点 h_j 的激活概率，如式 4 所示：

$$p(h_j = 1 | \mathbf{v}) = f\left(c_j + \sum_{i=1}^n w_{ij} v_i\right) \quad (4)$$

其中， $f(x) = \frac{1}{1 + e^{-x}}$ 。

同理，当给定隐含层节点状态 \mathbf{h} 时，第 i 个隐含节点 v_i 的激活概率，如式 5 所示：

$$p(v_i = 1 | \mathbf{h}) = f\left(b_i + \sum_{j=1}^m w_{ij} h_j\right) \quad (5)$$

深度信念网络(Deep Belief Network, DBN)是由多层的 RBM 叠加而成的神经网络，其训练过程使用无监督贪婪算法。具有两个隐含层的 DBN 的训练过程为：

- (1) 充分训练第一层 RBM；
- (2) 确定第一层 RBM 的权重和阈值，然后使用其隐含神经元的状态作为第二层 RBM 输入向量；
- (3) 在完成训练第二层 RBM 之后，将第二层 RBM 堆叠在第一层 RBM 之上。在所有 RBM 训练完成后，给定原始输入和目标输出作为监督信号，使用梯度下降法对网络进行监督训练，这是一个微调过程。DBN 的训练过程如图 3 所示。

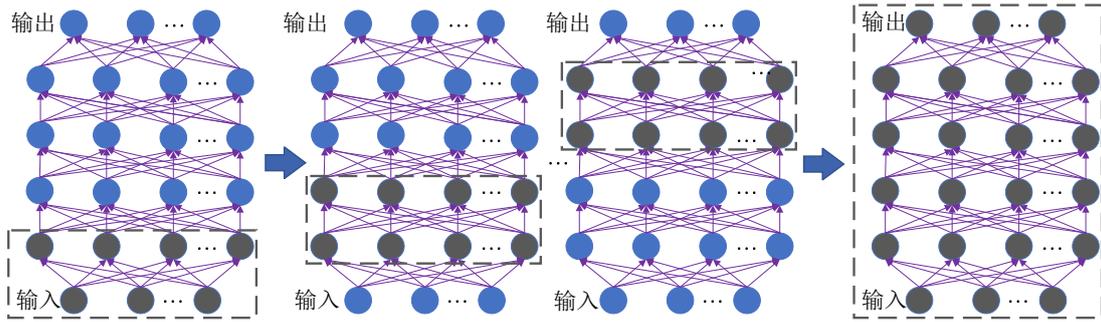


图3 DBN 训练过程

Fig.3 Training Process of the DBN

1.4 高斯二元受限玻尔兹曼机

RBM 可视层节点的神经元必须是二值的，然而，微地图推荐模型的输入数据是连续分布的。因此，本文将 DBN 可视层的第一层替换为高斯二元限制玻尔兹曼机 (Gaussian-binary Restricted Boltzmann Machine, GRBM)。

GRBM 的能量函数 $E(\mathbf{v}, \mathbf{h})$ ，如式 6 所示：

$$E(\mathbf{v}, \mathbf{h}) = \sum_{i=1}^n \frac{(v_i - b_i)^2}{2\sigma_i^2} - \sum_{j=1}^m c_j h_j - \sum_{i=1}^n \sum_{j=1}^m \frac{v_i}{\sigma_i} h_j w_{ij} \quad (6)$$

其中， σ_i 是样本数据的方差。可视层节点的激活概率 $p(v_i=1 | \mathbf{h})$ ，如式 7 所示：

$$p(v_i = 1 | \mathbf{h}) = f\left(b_i + \sigma_i \sum_{j=1}^m w_{ij} h_j, \sigma_i^2\right) \quad (7)$$

为有效的挖掘用户对不同专题微地图的长期兴趣及短期兴趣，有必要对用户与微地图交互数据中提取用户特征向量和微地图特征向量，其中用户特征向量包括用户的显式特征和隐式特征；微地图特征向量包括微地图的标号唯一标识符和微地图的名称。因此本文采用激活函数来学习用户特征及用户与微地图特征之间潜在的非线性交互特征，从而提供更丰富的语义表达，为微地图推荐精度的提升奠定一定的

基础。此外，本文采用的激活函数在训练过程中可以有效避免梯度消失的问题，从而加快反向传播算法的收敛速度。

2 实验及结果分析

2.1 实验环境及数据集

本实验的硬件环境为 Intel Core i9-9900k + RTX 3090，软件环境为 Windows10 + CUDA 11.1 + cuDNN8.5.0 + TensorFlow + Python3.6。实验迭代次数为 100 次，学习率为 0.005，DBN 的 RBM 层数为 5 层。

使用爬虫技术对百度图片进行爬取，并增加手绘地图，经过数据清洗、语义对齐等操作构建了 WeMaps 数据集，其记录了 2915 张微地图数据相关的地图信息，包括 978 张旅游微地图数据(TourMaps)、600 张校园微地图数据(SchoolMaps)、682 张美食微地图数据(FoodMaps)、655 张自驾微地图数据(DrivingMaps)等信息。WeMaps 数据集的字段信息如表 1 所示，包括微地图的唯一标识号(mid)、微地图名称(title)。

表 1 微地图数据集中的字段信息

Tab.1 Field Information of the WeMap Data Sets

| TourMaps | | SchoolMaps | | FoodMaps | | DrivingMaps | |
|----------|-------|------------|----------|----------|-------|-------------|-------|
| mid | title | mid | title | mid | title | mid | title |
| 1 | 天桥山 | 1 | 上海视觉艺术学院 | 1 | 撒汤 | 1 | 武威 |

| | | | | | | | |
|-----|-----|-----|--------|-----|------|-----|-----|
| 2 | 洞口市 | 2 | 武汉东湖学院 | 2 | 幺铺毛肚 | 2 | 兰州 |
| ... | ... | ... | ... | ... | ... | ... | ... |

目前，由于顾及微地图推荐因子的深度信念网络推荐系统在冷启动阶段，缺少相应的用户数据，通过调查问卷的方法收集用户信息和相应的用户行为，共收到有效数据 604 份，字段信息如表 2 所示。从影响用户选择的优先程度、用户因素界定的难易程度等不同方面考虑，将用户属性情景分为显式和隐式两种。显式特征是描述用户的基本情况，属性相对清晰，短时间内稳定不变，不会发生突变情况。本文除了分析用户年龄，性别等基础的用户信息外，结合微地图大众性的特点，还将重点分析用户职业，更能表现出用户对微地图的掌握及使用情况。用户隐式特征主要研究用户在不同情景下的心理变化情况，有着灵活多变、不易捕捉的特点。在对微地图用户研究中，具体将研究用户需求心态、行为习惯等因素，把握用户在制图和用图过程中的操作习惯，如表 3 所示。在用户使用微地图的过程中，隐式属性对用户需求具有隐性持续的影响，但由于用户不能准确表达，相关算法也不能准确捕捉，无法进行定质、定量的描述，所以在用户表现出需求和实现需求的操作过程

中，对用户隐式特征进行捕捉分类。在此先将隐性属性因素进行说明，参考相关心理学文献，对相关因素阈值或选项进行分类。

表 2 微地图用户显式属性信息

Tab.2 Explicit Attribute Information of WeMaps Users

| 因素 | 阈值或选项 |
|-----|---|
| 性别 | 男/女 |
| 年龄 | 18 岁以下、18-24、25-34、35-44、45-49、50-55、56 岁以上 |
| 职业 | 未定义、教育从业者、艺术家、行政人员、研究生、客服、医生、管理者、农民、家庭主妇、律师、程序员、退休人员、销售、科学家、创业者、工程师、工人、失业者、作家 |
| ... | ... |

表 3 微地图用户隐式属性信息

Tab.3 Implicit Attribute Information of WeMaps Users

| 因素 | 描述 | 阈值或选项 |
|------|-----------------|------------|
| 需求心态 | 影响微地图的使用人群范围 | 工作、生活、社会需求 |
| 识图能力 | 影响用户获取地图信息的难易程度 | 初级、中级、高级 |
| 分享意识 | 影响微地图的传播范围 | 薄弱、一般、良好 |
| ... | ... | ... |

2.2 评价指标

本文微地图推荐算法的性能用准确率 (Accuracy, Acc) 与均方误差 (Root Mean Square Error, RMSE) 来进行评估。

(1) 准确率 (Accuracy, Acc)

准确率指微地图推荐算法在训练过程中采用吉布斯采样得到的样本量符合用户偏好样本量的占比, 准确率越高, 说明微地图地名推荐越准确, 其计算如式 8 所示:

$$Acc = \frac{N_{TP} + N_{TN}}{N_{TP} + N_{FP} + N_{TN} + N_{FN}} \quad (8)$$

其中, N_{TP} 为真正例的数量, 表示预测值为 1, 真实值为 1; N_{FP} 为假正例的数量, 表示预测值为 1, 真实值为 0; N_{TN} 为真负例的数量, 表示预测值为 0, 真实值为 0; N_{FN} 为假负例的数量, 表示预测值为 0, 真实值为 1。

(2) 均方误差 (Root Mean Square Error, RMSE)

均方误差指推荐算法在训练过程中采用吉布斯采样后的样本 $\hat{y}(i)$ 与原始样本 $y(i)$ 的偏差, 其计算如式 9 所示:

$$RMSE = \sqrt{\frac{1}{t} \sum_{i=1}^t [y(i) - \hat{y}(i)]^2} \quad (9)$$

其中, t 表示推荐微地图的数量, $y(i)$ 表示推荐列表中原始微地图标签真实值, $\hat{y}(i)$ 表示推荐列表中采用吉布斯采样后微地图标签值。

2.3 校园微地图的 DBSCAN 聚类

以校园微地图为例, 使用 DBSCAN 算法进行聚类, 探究校园微地图的推荐因子。该算法通过参数 (ϵ , $Minpts$) 来描述样本分布紧密程度, 其中, ϵ 是邻域的半径, $Minpts$ 是聚类为一簇所需要的最少采样点的数量。本文设置 $\epsilon = 2$, $Minpts = 12$, 聚类结果如图 4 所示。该图分为直方图和散点图。左上角的直方图是 mid 的核密度估计图, 右下角的直方图是校园微地图类型的核密度估计图, 右上角和左下角的聚类图是 mid 与校园微地图类型之间的密度散点图, 将所有数据点绘制在图上, 可以直观呈现校园微地图 mid 特征与校园微地图类型特征的分布情况, 用来探究 mid 与校园微地图类型是否是影响校园

微地图推荐的推荐因子。可以看出, mid 共有 600 个簇 (即数据集中包含 600 张校园微地图), 校园微地图类型共有 7 个簇 (用数字 0 - 6 分别表示为综合类院校、艺术类院校、理工类院校、医科类院校、财经农业师范类院校、技术学院类、其他类)。从校园微地图类型角度分析: 占比最多的是综合类院校, 占比第二多的理工类院校, 占比最少是艺术类院校。校园微地图存在长尾分布, 导致校园微地图样本分布不均衡, 对于“热门推荐”的校园微地图样本, 模型对此类样本学习效果较好, 而对长尾效应的“冷门推荐”校园微地图, 模型对此类的样本理解不够充分, 长期以往导致总体推荐精度下降。由此, 为了能够有效挖掘具有长尾效应的校园微地图, 可为用户个性化推荐不同类型的校园微地图, 验证了本文聚类算法在对校园微地图数据集历史样本聚类过程中, 能够细粒度挖掘校园微地图的推荐因子 (即校园微地图的类型), 为深度信念网络在编码多尺度特征向量时有效结合推荐因子信息进行训练奠定了一定的基础。

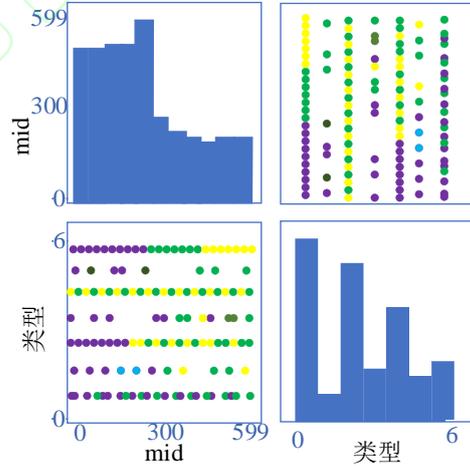


图 4 校园微地图的 DBSCAN 聚类结果图
Fig.4 DBSCAN Clustering Results for SchoolMaps

2.4 基于 DBSCAN 的校园微地图用户数据集聚类

对用户数据使用 DBSCAN 算法进行聚类, 探究校园微地图的用户数据集推荐因子与微地图推荐结果的相关性。仍然通过参数 (ϵ , $Minpts$) 来描述样本分布紧密程度, 文中设置 $\epsilon = 2$, $Minpts = 12$, 聚类结

果如图 5 所示。从左上角开始，第 1 行第 1 列是年龄的核密度估计图，第 2 行第 2 列是性别的核密度估计图，第 3 行第 3 列是职业的核密度估计图，第 1 行第 2 列与第 2 行第 1 列是年龄与性别之间的密度散点图，第 1 行第 3 列与第 3 行第 1 列是年龄与职业之间的密度散点图，第 2 行第 3 列与第 3 行第 2 列是性别特征与职业特征的散点图。将所有的数据点绘制在图上，可以直观呈现校园微地图的用户数据集中年龄特征与性别特征、年龄特征与职业特征的分布情况，用来探究年龄、性别和职业等推荐因子对校园微地图的推荐结果的影响。在图中，年龄分为 7 个簇（用数字 0-6 分别表示：18 岁以下、18 岁 - 24 岁、25 岁 - 34 岁、35 岁 - 44 岁、45 岁 - 49 岁、50 岁 - 55 岁及 56 岁以上）。性别分为 2 个簇（用数字 0 和 1 分别表示：男性和女性）。职业分为 20 个簇（用数字 0-19 分别表示：未定义、教育从业者、艺术家、行政人员、研究生、客服、医生、管

理者、农民、家庭主妇、律师、程序员、退休人员、销售、科学家、创业者、工程师、工人、失业者、作家）。从年龄角度分析可知，占比最多用户群体的年龄在 56 岁以上，占比第二多的用户群体为 45 岁 - 49 岁年龄段的用户，占比第三多的用户群体为 18 岁 - 24 岁，占比最少的用户群体是 18 岁以下的用户。从职业角度分析可知，占比最多为未定义用户，占比第二多的用户群体是艺术家，占比第三多的用户群体是行政人员、占比最少的用户群体是律师。由此，验证了本文聚类算法在对校园微地图的用户数据集的历史样本聚类过程中，能够细粒度挖掘校园微地图用户的推荐因子，即用户的年龄、性别和职业，为深度信念网络在编码多尺度特征向量时有效结合上下文信息进行训练奠定一定的基础，使用顾及微地图推荐因子的深度信念网络产生推荐结果后，可以研究不同年龄、不同职业、不同性别用户个性化推荐因子与推荐结果的相关性。

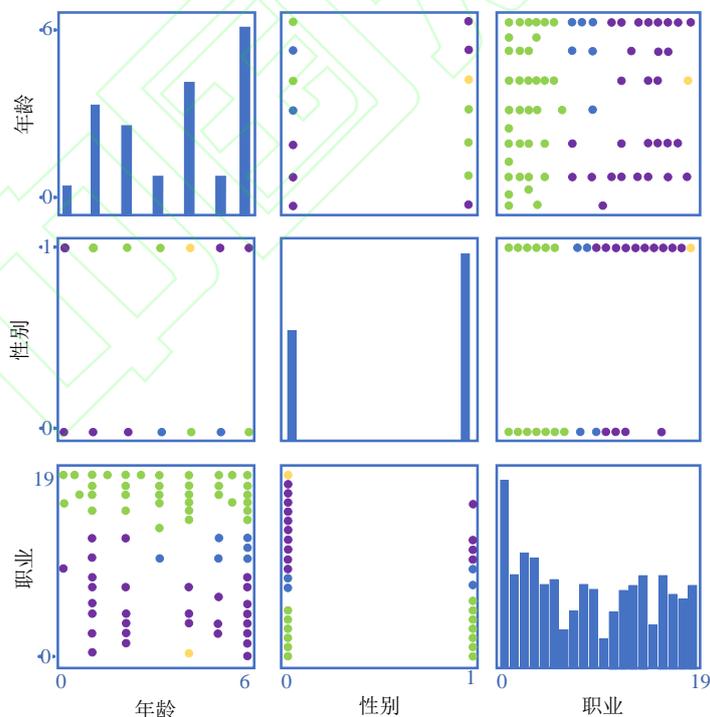


图 5 微地图用户的 DBSCAN 聚类结果图
Fig.5 DBSCAN Clustering Result of WeMap Users

2.5 校园微地图预测

使用本文所提出的顾及微地图推荐因子的深度信念网络对用户进行校园微地图预测。以 uid 为 214 号的用户为例，其对不同类型校园微地图的关注程度汇总如表 4 所示。214 号用户分别对综合类院校评分数据为 46 条、艺术类院校为 3 条、理工院校为 41 条等，其中综合类院校占比最多，其次是理工类院校，占比最少的是艺术类院校。按照本文的顾及微地图推荐因子的深度信念算法为 214 号用户预测“感兴趣”的 10 个校园微地图，预测结果如表 5 所示，推荐得分排名前三位的校园微地图分别为 mid 为 78 号的上海海洋大学、mid 为 322 号的广西大学西校区、mid 为 407 号的江西理工大学。由此验证了本文算法在编码多尺度特征向量时，能够有效结合校园微地图推荐因子的语义信息。此外，本文推荐算法还为 214 号用户预测了技术学院类院校，说明算法能够有效挖掘具有长尾效应的校园微地图，可为用户个性化推荐不同类型的校园微地图。

表 4 214 号用户对不同类型校园微地图的关注程度汇总表

Tab.4 No. 214 User Prefer Different Types of SchoolMaps Summary Table

| uid | 校园微地图类型 | 条 |
|-----|-----------|----|
| 214 | 综合类院校 | 46 |
| 214 | 艺术类院校 | 3 |
| 214 | 理工类院校 | 41 |
| 214 | 医科类院校 | 4 |
| 214 | 财经农业师范类院校 | 21 |
| 214 | 技术学院类院校 | 9 |
| 214 | 其他类院校 | 6 |

表 5 为 214 号用户预测 10 个“感兴趣”的校园微地图

Tab.5 Predict 10 Preferred SchoolMaps for No. 214

| | | User | | |
|-----|----------|------|-----------|----------|
| mid | title | uid | 校园微地图类型 | 推荐得分 |
| 78 | 上海海洋大学 | 214 | 综合类院校 | 1.0 |
| 322 | 广西大学西校区 | 214 | 综合类院校 | 1.0 |
| 407 | 江西理工大学 | 214 | 理工类院校 | 0.9999 |
| 311 | 暨南大学 | 214 | 综合类院校 | 0.999981 |
| 167 | 西安翻译学院 | 214 | 技术类院校 | 0.999951 |
| 82 | 香港大学 | 214 | 综合类院校 | 0.999928 |
| 353 | 广西大学 | 214 | 综合类院校 | 0.999763 |
| 358 | 华北水利水电大学 | 214 | 理工类院校 | 0.999725 |
| 197 | 厦门大学 | 214 | 综合类院校 | 0.999686 |
| 113 | 华南师范大学 | 214 | 财经农业师范类院校 | 0.998262 |

2.6 不同专题微地图推荐对比

图 6 和图 7 分别给出了本文算法在旅游、校园、美食和自驾微地图数据集上推荐的精度、均方误差与迭代次数的统计结果，其中，横坐标均为训练迭代次数，图 6 的纵坐标为推荐精度，图 7 的纵坐标为推荐的均方误差。图中的方框为实验结果（灰色阴影区域）的局部放大图。可以看出，在训练初期，由于网络训练过程中不断优化参数，由 DBN 网络学习到的特征对微地图数据集的描述准确度不断提高，随着迭代次数的增加，推荐的精度逐渐提

高, 推荐的均方误差呈下降趋势。当迭代次数达到 100 次时算法收敛, 推荐的精度和均方误差均趋于稳定, 模型趋于收敛, 说明算法中的参数已达到最优, 此时再增加迭代次数对推荐精度和均方误差几乎没有影响。实验结果充分验证了本文算法在训练过程中能够不断提取用户与微地图交

互的细粒度语义信息, 有效地为用户推荐“感兴趣”的微地图。

为了探究本文构建算法的有效性, 分别在旅游、校园、美食及和自驾微地图数据集上进行训练并测试, 实验结果如表 6 所示。

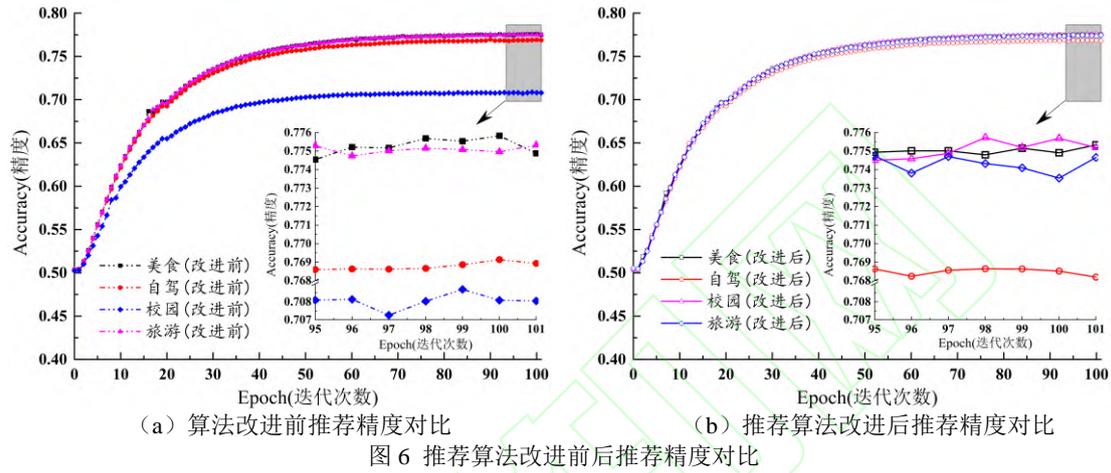


图 6 推荐算法改进前后推荐精度对比

Fig.6 Comparison of Recommendation Accuracy Before and After Algorithm Improvement

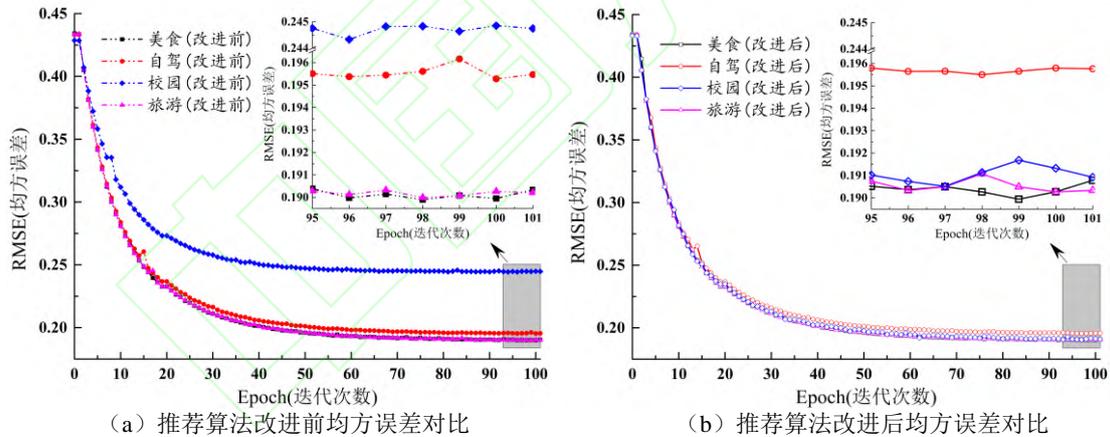


图 7 推荐算法改进前后推荐均方误差对比

Fig.7 Comparison of Recommendation RMSE Before and After Algorithm Improvement

在这四类专题微地图上只采用 DBN 网络的推荐算法(改进前(DBN))与顾及微地图推荐因子的深度信念网络算法(改进后(DBSCAN + DBN))进行推荐的精度和均方误差对比。改进后算法(DBSCAN + DBN)在美食、自驾、旅游和校园微地图数据集上的推荐精度分别为 0.77532、0.76818、0.77518、0.77464, 微地图推荐的均方误差分别为 0.19078、0.19476、

0.19033、0.19092。微地图推荐精度提升最为明显的是校园微地图, 比改进前(DBN)的推荐精度提升了 9.4%; 微地图推荐的均方误差下降最为明显的是校园微地图, 比改进前(DBN)的均方误差降低了 21.9%, 主要原因是深度信念网络采用微调学习策略能够捕捉细粒度用户与微地图交互的语义信息, 同时深度信念网络在编码多尺度特征向量时可以有效结合上下文

信息。由于本文构建的顾及微地图推荐因子的深度信念网络更关注于校园与美食微地图的多样性与丰富性，而在一定程度上忽略了旅游与自驾微地图的线路推荐，所以在美食微地图与校园微地图推荐精度提升，而在旅游微地图与自驾微地图推荐精度有所下降，此外，由于旅游微地图与自驾微地图推荐强调线路合理性，不仅局限

于推荐的多样性，且用户与这两类微地图交互数据存在数据稀疏性问题，说明这两类专题地图的隐式属性更难挖掘，用户对旅游微地图、自驾微地图的兴趣转移较快且不宜捕捉，但本文构建的顾及微地图推荐因子的深度信念网络也能为用户推荐旅游微地图与自驾微地图。

表 6 本文算法在改进前后推荐精度与均方误差对比

Tab.6 Accuracy and RMSE Comparison of Recommendation Before and After Improvement of Algorithms

| | 精度(Accuracy) | | 误差(RMSE) | |
|-------|--------------|-----------------------|--------------|-----------------------|
| | 改进前 (DBN) | 改进后 (DBSCAN + DBN) | 改进前 (DBN) | 改进后 (DBSCAN + DBN) |
| 美食微地图 | 0.77487 | 0.77532 | 0.19034 | 0.19078 |
| 自驾微地图 | 0.76892 | 0.76818 | 0.19547 | 0.19476 |
| 旅游微地图 | 0.77531 | 0.77518 | 0.19021 | 0.19033 |
| 校园微地图 | 0.70804 | 0.77464 | 0.24474 | 0.19092 |

3 结论与展望

在微地图推荐系统中的冷启动阶段，针对传统深度信念网络无法高效挖掘数据中的细粒度信息，本文提出了一种顾及微地图推荐因子的深度信念网络算法。该算法首先通过 DBSCAN 算法对用户和微地图历史样本进行聚类，选取出核心点(即推荐因子)、边界点以及离群点；其次，把用户与微地图历史样本聚类后的推荐因子构建成不同的可视层与隐含层，利用深度信念网络对输入数据微调训练，从而实现数据的降维并提升推荐的准确性。该算法不仅考虑到用户使用微地图的偏好习惯，而且考虑到微地图地名之间的内部联系，所获得的个性化推荐结果合理且符合个人生活偏好。在美食、旅游、校园及自驾四类微地图数据集上验证了本文所提的顾及微地图推荐因子的深度信念网络推荐算法，推荐精度、均方误差都获得了令人满意的结果。

微地图推荐致力于个性化服务，但是由于用户使用微地图的偏好不同，想达到多维传播的效果，需要更具有个性化的地图服务。由于目前数据只构建了旅游、美

食、自驾和校园微地图这 4 类专题微地图，正在研发的顾及微地图推荐因子的深度信念网络推荐系统手机应用端还需构建更多种类的专题微地图，利用深度学习等智能化处理方法分析用户行为，以满足各种不同场景及不同使用人群的需求。未来的研究工作将会针对旅游与自驾微地图中的线路推荐的合理化进行动态研究，对不同的使用人群进行调查问卷和建模，综合考虑推荐系统的可解释性等因素，以满足不同需求的用户，进一步提高推荐效率，完善现有的微地图推荐系统。

参考文献

- [1] Zhao Qianwei, Ma Yuanyuan. A Probe into the Spreading Characteristics of WeChat Rumors in the Era of We Media[J]. Journal of News Research, 2014, 5(16): 11. (赵前未, 马缘园. 自媒体时代微信谣言传播特点初探[J]. 新闻研究导刊, 2014, 5(16): 11)
- [2] Wang Haiying, Yan Haowen, Tian JiangPeng, et al. WeMaps in the Perspective of the Post-Modernist Philosophy[J]. Geomatics and Information Science of Wuhan University, 2022, 47(12): 2026-2037. (王海鹰, 闫浩文, 田江鹏, 等. 后现代哲学视野下的微地图[J].

- 武汉大学学报·信息科学版, 2022, 47(12): 2026-2037.)
- [3] Shen Jinxia. Information Propagational Features of the We Media[J]. *Today's Massmedia*, 2012, 20(9): 94-96. (申金霞. 自媒体时代的信息传播特点探析[J]. *今媒体*, 2012, 20(9): 94-96.)
- [4] Guo Renzhong, Chen Yebin, Zhao Zhigang, et al. Scientific Concept and Representation Framework of Maps in the ICT Era[J]. *Geomatics and Information Science of Wuhan University*, 2022, 47(12): 1978-1987. (郭仁忠, 陈业滨, 赵志刚, 等. ICT时代地图的科学概念及表达框架[J]. *武汉大学学报·信息科学版*, 2022, 47(12): 1978-1987.)
- [5] Wang Jiayao, Wu Fang, Yan Haowen. Cartography: Its Past, Present and Future[J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(6): 829 - 84. 2(王家耀, 武芳, 闫浩文. 大变化时代的地图学[J]. *测绘学报*, 2022, 51(6): 829 - 842.)
- [6] Liu Yu, Guo Hao, Li Haifeng, et al. A Note on GeoAI from the Perspective of Geographical Law[J]. *Acta Geodaetica et Cartographica Sinica*, 2022, 51(6): 1062 - 1069. (刘瑜, 郭浩, 李海峰, 等. 从地理规律到地理空间人工智能[J]. *测绘学报*, 2022, 51(6): 1062 - 1069.)
- [7] Ying Shen, Hou Siyuan, Su Junru, et al. Characteristics of the Game Maps[J]. *Geomatics and Information Science of Wuhan University*, 2020, 45(9): 1334 - 1443. (应申, 侯思远, 苏俊如, 等. 论游戏地图的特点. *武汉大学学报·信息科学版*, 2020, 45(9): 1334 - 1443.)
- [8] Adomavicius G, Tuzhilin A. Toward the next Generation of Recommender Systems: A Survey of the State-of-the-art and Possible Extensions[J]. *IEEE Transactions on Knowledge and Data Engineering*, 2005, 17(6): 734-749.
- [9] Su X Y, Khoshgoftaar T M. A Survey of Collaborative Filtering Techniques[J]. *Advances in Artificial Intelligence*, 2009, 2009: 2.
- [10] Verbert K, Manouselis N, Ochoa X, et al. Context-aware Recommender Systems for Learning: A Survey and Future Challenges[J]. *IEEE Transactions on Learning Technologies*, 2012, 5(4): 318-335.
- [11] Mooney R J, Roy L. Content-based Book Recommending Using Learning for Text Categorization[C]//*Proceedings of the fifth ACM conference on Digital libraries*. San Antonio, Texas, USA, 2000: 195-204.
- [12] Ye M, Yin P F, Lee W C. Location Recommendation for Location-based Social Networks[C]//*Proceedings of the 18th SIGSPATIAL International Conference on Advances in Geographic Information Systems*. San Jose, California, 2010: 458-461.
- [13] Ma C, Zhang Y X, Wang Q L, et al. Point-of-interest Recommendation: Exploiting Self-attentive Autoencoders with Neighbor-aware Influence[C]//*Proceedings of the 27th ACM International Conference on Information and Knowledge Management*. Torino, Italy, 2018: 697-706.
- [14] Davidson J, Liebald B, Liu J N, et al. The YouTube Video Recommendation System[C]//*Proceedings of the fourth ACM conference on Recommender systems*. Barcelona, Spain, 2010: 293-296.
- [15] Bordes A, Usunier N, Garcia-Durán A, et al. Translating Embeddings for Modeling Multi-Relational Data[C]// *Proceedings of the 26th International Conference on Neural Information Processing Systems*, New York: ACM, 2013, 2: 2787 - 2795.
- [16] Wang H, Wang N Y, Yeung D Y. Collaborative Deep Learning for Recommender Systems[C]// *Proceedings of the 21st ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Sydney, Australia, 2015: 1235 - 1244.
- [17] Zhang F Z, Nicholas J Y, Lian D F, et al. Collaborative Knowledge Base Embedding for Recommender Systems[C]// *Proceedings of the 22nd ACM SIGKDD International*

- Conference on Knowledge Discovery and Data Mining. San Francisco, USA, 2016: 353 - 362.
- [18] He Yang, Yan Haowen, Wang Zhuo, et al. Landmark Extraction Method and Personalized Wayfinding Application for We-Map[J]. Journal of Geo-information Science, 2022, 24(5): 827 - 836. (何阳, 闫浩文, 王卓, 等. 面向微地图的地标提取方法及个性化寻路应用[J]. 地球信息科学学报, 2022, 24(5): 827 - 836.)
- [19] Niu Xuelei, Yang Jun, Yan Haowen. 2022. WeMap Recommendation by Fusion of Knowledge Graph and Collaborative Filtering. Journal of Geo-information Science. (牛雪磊, 杨军, 闫浩文. 融合知识图谱与协同过滤的微地图推荐[J]. 地球信息科学学报.) (网络优先出版)
- [20] Dai Shaosheng, Liu Xiaobing, Lai Zhiying, et al, Gridded Local Adaptive DBSCAN Clustering Algorithm[J]. Journal of Chongqing University of Posts and Telecommunications(Natural Science Edition), 2022, 34(2): 250 - 257. (代少升, 刘小兵, 赖智颖, 等. 网格化局部自适应 DBSCAN 聚类算法[J]. 重庆邮电大学学报(自然科学版), 2022, 34(2): 250 - 257.)
- [21] Xiong Xi, Qiao Shaojie, Han Nan, et al. Affective Impression: Sentiment-Awareness POI Suggestion via Embedding in Heterogeneous LBSNs IEEE Transactions on Affective Computing, 2019. 13(1): 272-284.
- [22] Fischer A, Igel C, Training Restricted Boltzmann Machines: An Introduction. Pattern Recognition, 2014, 47: 25 - 39.
- [23] Hinton G E. A Practical Guide to Training Restricted Boltzmann Machines. Springer Neural Networks: Tricks of the Trade. Lecture Notes in Computer Science, 2012, 7700: 599 - 619.
- [24] Hinton G E, Osindero S, Teh Y W. A Fast Learning Algorithm for Deep Belief Nets. Neural Computation, 2006, 18(7): 1527 - 1554.
- [25] Zhang Shuhua, Li Haiying, Liu Fang. Review on research of identity[J]. Psychological Research, 2012, 5(1): 21-27. (张淑华, 李海莹, 刘芳. 身份认同研究综述[J]. 心理研究, 2012, 5(1): 21-27.)

网络首发:

标题: 顾及微地图推荐因子的深度信念网络

作者: 牛雪磊, 杨军, 闫浩文

DOI: 10.13203/j.whugis20230053

收稿日期: 2023-06-04

引用格式:

牛雪磊, 杨军, 闫浩文. 顾及微地图推荐因子的深度信念网络[J]. 武汉大学学报(信息科学版), 2023, DOI: 10.13203/j.whugis20230053 (NIU Xuelei, YANG Jun, YAN Haowen. Deep Belief Networks Considering WeMaps' Recommendation Factors [J]. *Geomatics and Information Science of Wuhan University*, 2023, DOI: 10.13203/j. whugis20230053)

网络首发文章内容和格式与正式出版会有细微差别, 请以正式出版文件为准!

您感兴趣的其他相关论文：

利用深度信念网络进行滑坡易发性评价

陈涛, 钟子颖, 牛瑞卿, 刘桐, 陈胜云

武汉大学学报（信息科学版），2020, 45(11): 1809-1817

<http://ch.whu.edu.cn/cn/article/doi/10.13203/j.whugis20190144>

