

面向多源异构数据的个性化搜索和推荐算法综述

暴琳¹, 朱志宇^{1†}, 孙晓燕², 徐标³

(1. 江苏科技大学 自动化学院, 江苏 镇江 212100; 2. 中国矿业大学 信息与控制工程学院, 江苏 徐州 221116;

3. 汕头大学 工学院, 广东 汕头 515063)

摘要: 高效精准的个性化搜索、推荐等服务可为人们生产生活带来极大便利, 而随着互联网技术的迅猛发展, 面向多源异构数据的个性化搜索和推荐任务逐渐变得日趋复杂, 也是当前大数据分析及个性化服务领域的研究热点和难点. 个性化搜索和推荐算法广泛收集多源异构数据, 获取用户偏好信息, 利用各类机器学习、深度学习等技术, 构建用户兴趣偏好模型, 预测用户偏好, 推荐满足用户个性化需求和偏好的项目或内容, 提升用户的使用体验和网站平台的商业利益. 本文介绍面向多源异构数据的个性化搜索问题的数学描述, 综述面向多源异构数据的个性化搜索和推荐算法的相关研究工作, 包括: 传统个性化搜索和推荐算法、融合多源异构数据的个性化搜索和推荐算法以及动态个性化搜索和推荐算法等相关研究现状, 整理了算法常用数据集、性能评价指标及评估体系, 进一步阐明了目前面向多源异构数据的个性化搜索和推荐方法的实际应用场景及今后研究的发展方向, 并讨论了存在的不足及所面临的严峻挑战, 期望为相关领域的研究人员提供有益帮助.

关键词: 个性化搜索; 多源异构数据; 用户兴趣模型; 深度学习

引用格式: 暴琳, 朱志宇, 孙晓燕, 等. 面向多源异构数据的个性化搜索和推荐算法综述. 控制理论与应用, 2024, 41(2): 189 – 209

DOI: 10.7641/CTA.2023.20100

Review on personalized search and recommendation algorithms for multi-source heterogeneous data

BAO Lin¹, ZHU Zhi-yu^{1†}, SUN Xiao-yan², XU Biao³

(1. College of Automation, Jiangsu University of Science and Technology, Zhenjiang Jiangsu 212100, China;

2. School of Information and Control Engineering, China University of Mining and Technology, Xuzhou Jiangsu 221116, China;

3. College of Engineering, Shantou University, Shantou Guangdong 515063, China)

Abstract: Efficient personalized search service can bring great convenience in the production and life. With the rapid development of Internet technology, personalized search and recommendation task tends to become increasingly complex and is a hot research topic in the field of big data analysis. Personalized search and recommendation algorithms extensively collect user-generated content and obtain users' preference information. By using various machine learning, deep learning and other technologies, these algorithms build user interest preference models, predict users' behaviors, and recommend personalized items. It will improve users' experiences and commercial benefits. This paper introduces the description of the personalized search problem, and reviews the research work on the personalized search and recommendation algorithms for multi-source heterogeneous data. It includes traditional personalized search algorithms, personalized search algorithms with multi-source heterogeneous data and dynamic personalized search algorithms. It sorts out common data sets and evaluation indicators, and clarifies the practical application scenarios and development directions of the personalized search methods for multi-source heterogeneous data. It also discusses the deficiencies and challenges, which is expected to be helpful to researchers in related fields.

Key words: personalized search; multi-source heterogeneous data; user interest model; deep learning

Citation: BAO Lin, ZHU Zhiyu, SUN Xiaoyan, et al. Review on personalized search and recommendation algorithms for multi-source heterogeneous data. *Control Theory & Applications*, 2024, 41(2): 189 – 209

收稿日期: 2022-02-08; 录用日期: 2023-03-30.

†通信作者. E-mail: zzydzz@163.com; Tel.: +86 511-84401153.

本文责任编辑: 张丽清.

国家自然科学基金项目(61671222, 61876184), 广东省自然科学基金项目(2021A1515011709), 广东省数字信号与图像处理技术重点实验室开放基金项目(2021GDDSIPL-06)资助.

Supported by the National Natural Science Foundation of China (61671222, 61876184), the National Natural Science Foundation of Guangdong Province (2021A1515011709) and the Open Foundation of the Key Laboratory of Digital Signal and Image Processing of Guangdong Province (2021GDDSIPL-06).

1 引言

近年来,随着互联网、大数据等技术的迅猛发展,互联网规模和用户数量呈现急剧增长的态势^[1-5].用户作为数据的主动创造者,在网络中进行各种各样的行为和活动,包括:浏览网页、观看时事新闻、接收内容推荐、购物、出行通讯、休闲娱乐等事务,聚集了大量的多源异构用户生成内容(user generated contents, UGCs),如:用户画像、用户评分、类别标签、用户行为、文本评论、图像、音频、视频、位置信息、社交知识等,用户之间形成了日益错综复杂的社交网络关联.同时,这些UGCs数据蕴含着丰富的用户偏好信息,具有数量巨大、来源与结构多样化、多模态、稀疏性、无序性、不完整性、动态演化及传播社会性等特点,成为典型的个性化搜索和推荐系统的大数据环境.此外,这些海量多源异构UGCs也是各类互联网平台和移动应用商家获取信息、提高业绩、提升用户满意度和服务质量的重要来源.然而,这些海量信息给用户带来新资讯的同时,也将湮没大量有用信息,增加了用户筛选、甄别、处理信息,并最终做出决策的难度,即带来了“信息过载”问题^[6-10].

个性化搜索和推荐算法作为一种重要的智能信息过滤手段和服务方式,帮助用户从海量信息中搜寻满足其潜在需求及兴趣偏好的项目或内容(如:商品、音乐、微博、新闻等).同时,利用算法精确定目标受众,让一些有价值的信息能够触达潜在用户,有效缓解“信息过载”,提升用户的实际使用体验和电子商业平台的经济效益,更好地服务于国计民生,实现供需双赢^[11-15].近年来,涌现出了许多电子商务、信息检索、新闻推送、音乐/视频点播等领域的商用个性化搜索和推荐系统,例如:为用户推荐商品的亚马逊、中国电子商务平台淘宝网、电影推荐平台豆瓣网、信息检索平台百度、文章推荐系统GroupLens等,通过将浏览者转化为购买者,增加交叉销售、建立客户忠诚度、增强用户粘性,成功实现经济效益转化.

然而,在复杂环境下的个性化搜索和推荐任务中,由于各用户的生活习惯、文化背景等差异较大,且当用户无明确信息需求或搜索意图时,使用传统大范围、无差别的推荐方法,往往无法取得良好的推荐效果,难以满足个性化需求,同时无端耗费了用户获取有用信息的精力及专注力.如何在复杂海量多源异构用户生成数据环境中,深入挖掘用户兴趣偏好,及时跟踪用户偏好,期望通过具体方法自动搜寻情景、项目、用户三者之间的最佳匹配,实现高效而精准的个性化搜索和推荐,提高个性化服务综合质量,从而有效处理现实生产、生活中的工程实际问题.上述内容已成为当前人工智能领域的迫切需求、研究热点及目标.面向多源异构数据的个性化搜索和推荐系统将大数据处理、机器学习、深度学习等技术有机结合,新颖

且富有挑战性,具有十分重要的理论研究价值和广阔的实际应用前景,受到学术界和工业界的广泛关注.

本文主要介绍面向用户生成内容个性化搜索和推荐任务的相关背景知识,对于面向多源异构数据的个性化搜索和推荐算法及其相关应用研究进行全面综述.主要研究内容框图如图1所示.

首先,需明确面向多源异构数据的个性化搜索和推荐任务解决问题的数学描述,理清求解思路和建模方法;其次,对于建模、求解过程中的子任务,依次设计合理的解决方案,如:多源异构数据的特征提取、融合多源异构数据、用户兴趣偏好模型构建等内容;然后,针对不同情况下的实际真实场景,提出高效的个性化搜索和推荐算法.在个性化搜索和推荐系统研究领域已存在许多研究工作,基本沿袭上述研究思路.本文对于面向多源异构数据的个性化搜索和推荐算法相关工作进行了全面而系统的综述,将从多视角、多方面分析、归纳、总结不同领域个性化搜索和推荐方法的关键技术、工程应用及实际效果.

本文内容组织结构安排如下:第2节给出面向用户生成内容个性化搜索的数学描述;第3节阐述了个性化搜索和推荐算法的相关工作及研究现状;第4节展示了个性化搜索和推荐算法的常用数据集;第5节说明了算法的性能评价体系及评价指标;第6节讨论了个性化搜索和推荐系统的实际应用场景及未来研究发展方向;最后,第7节总结全文.

2 面向用户生成内容个性化搜索的数学描述

面向UGCs的个性化搜索和推荐任务是在海量动态搜索空间中,深入挖掘多源异构用户生成数据,建立用户兴趣偏好模型,抽取用户偏好,帮助用户搜寻满足其潜在需求和个性化偏好的项目或内容,为用户推荐其感兴趣的个性化项目推荐列表.在个性化搜索过程中,用户需依据认知经验、兴趣偏好等,对于搜索对象进行定性分析、评价和决策,而该过程往往具有渐进性、主观性、模糊性、多样性、不确定性、不一致性、动态演化等复杂特性.因而,这类问题难以建立明确定义的数学模型及目标函数,且用户满意解的界定也是主观且因人而异的,其搜索结果和推荐效果完全由用户偏好主观决定.例如:对于同一任务(如:购买图书、搜索电影等),不同用户的需求和兴趣不同,同一用户不同时间段的需求和兴趣也可能不相同.另外,随着时间推移、环境迁移、信息量增加等多种因素影响,用户潜在需求和兴趣偏好逐渐清晰,甚至可能发生动态变化.因此,面向UGCs的个性化搜索和推荐问题本质上是一类复杂动态定性指标优化问题.

面向多源异构UGCs个性化搜索任务的基本框图如图2所示.

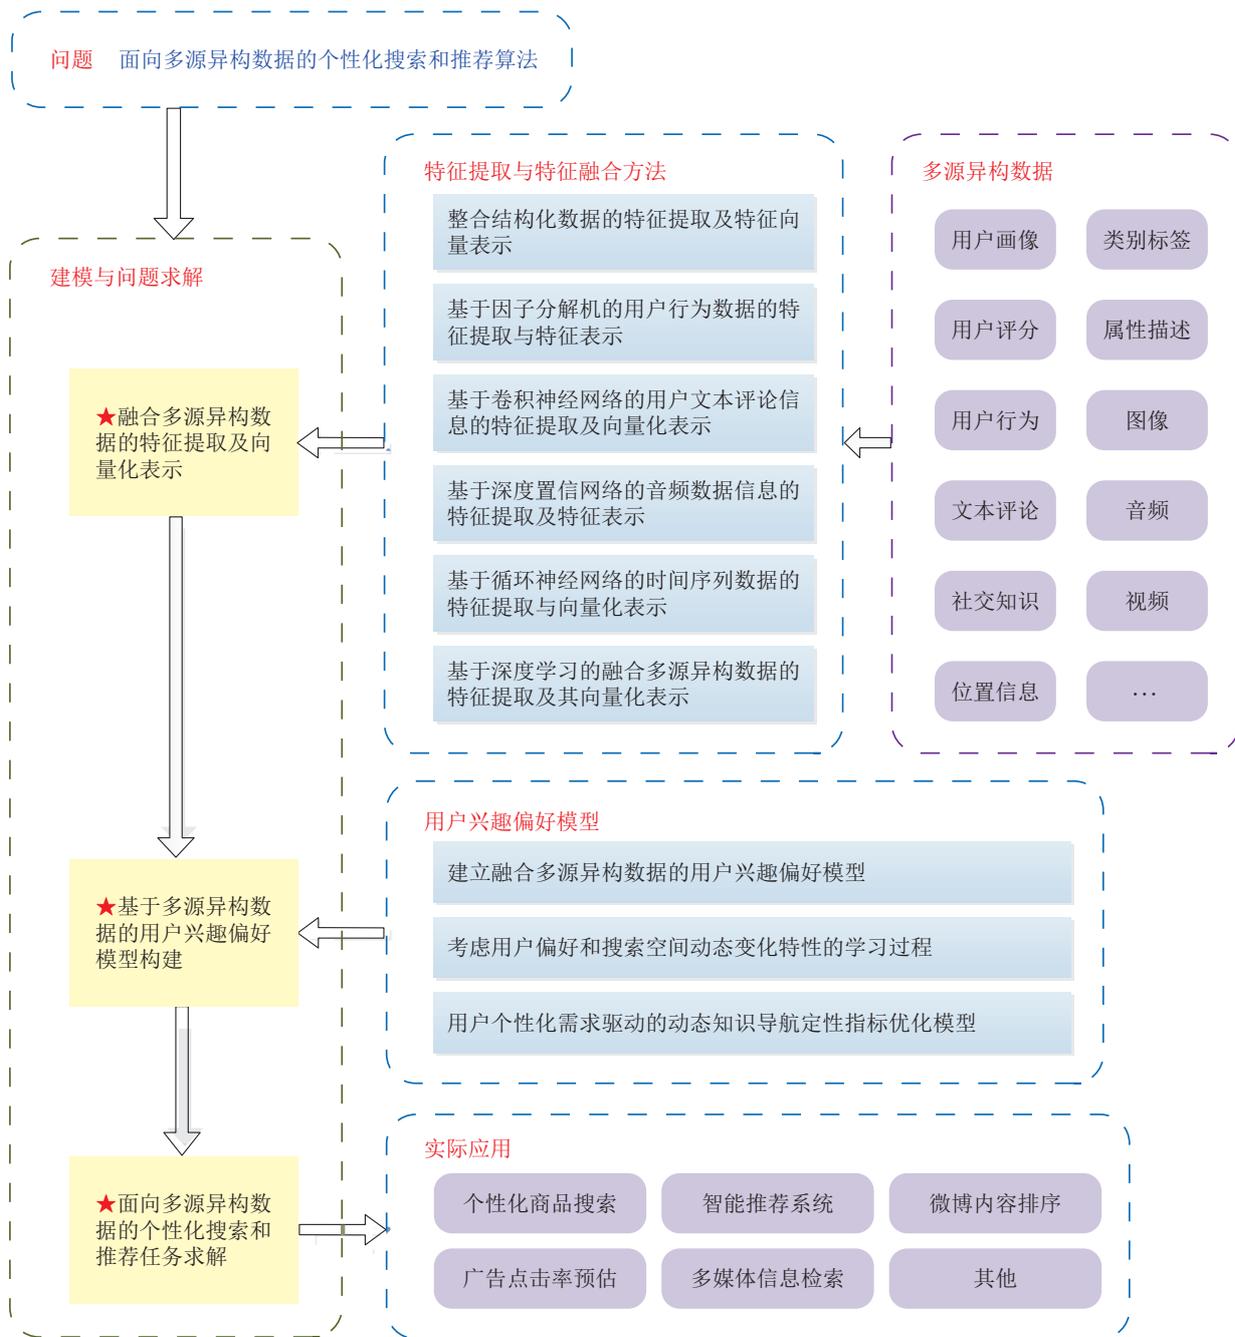


图 1 面向多源异构数据的个性化搜索和推荐算法及其应用的研究内容框图

Fig. 1 Diagram of personalized search and recommendation algorithms with multi-source heterogeneous data

图2对于处理实际面向多源异构UGCs个性化搜索任务的过程进行了详细展示, 将图1概要性、静态性的说明以动态信息流转的方式呈现, 更清晰地展现了个性化搜索和推荐过程中数据传导流向和问题求解过程. 根据基本框图中各模块功能, 面向多源异构UGCs的个性化搜索任务可分为数据预处理模块、多源异构数据模块和个性化推荐模块. 数据预处理模块主要收集互联网中产生的海量数据, 并接收用户交互过程中产生的新的用户生成数据及新出现的项目, 将这些信息进行初步的数据预处理. 多源异构数据模块将上级模块输入的信息分门别类, 进行相应的数据向量化表

示, 这里不同类型的数据处理方法不同, 与后续构建的模型息息相关. 个性化推荐模块将充分挖掘多源异构UGCs, 构建基于多源异构数据的用户兴趣偏好模型, 抽取用户偏好, 设计面向多源异构数据的个性化搜索和推荐算法, 预测用户未来可能的行为模式, 并向用户推荐其可能感兴趣的项目或内容, 生成项目推荐列表, 提交给当前用户. 若用户搜索到用户满意解, 则交互式个性化搜索过程结束; 否则, 收集用户对于推荐结果的评价反馈, 并进行效用评价. 通过模型管理优化调整基于多源异构数据的用户兴趣偏好模型及相应的个性化搜索策略, 进一步提高模型预测精度

和推荐效果.

这里, 面向多源异构数据的个性化搜索和推荐问题的目标函数 $f_u(\mathbf{x})$ 定义如下:

$$f_u(\mathbf{x}), \text{ s.t. } u \in U, \mathbf{x} \in X, \quad (1)$$

其中: $U = \{u_1, u_2, \dots, u_{|U|}\}$ 是用户集合, $|U|$ 表示用户数量; $X = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_{|X|}\}$ 是项目集合(可行解

空间), 通常 X 很大且稀疏, $|X|$ 表示项目数量, 项目(解) \mathbf{x}_i 含有 n 个决策变量, 表示为 $\mathbf{x}_i = [x_{i1} \ x_{i2} \ \dots \ x_{in}]$; 用户 u 对于项目 \mathbf{x} 的偏好程度为 $f_u(\mathbf{x})$, 其无法用具体数学函数精确量化表示, 由用户 u 的认知经验和兴趣偏好决定, 且在个性化搜索过程中可能发生动态变化.

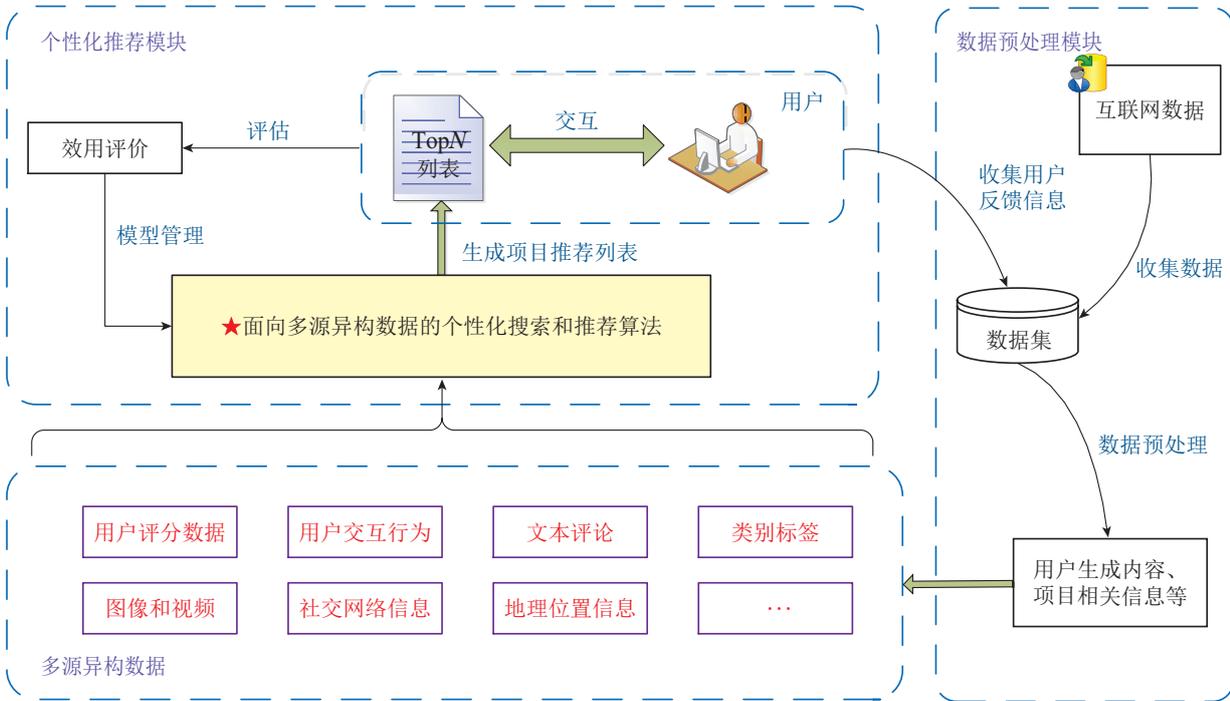


图2 面向多源异构UGC的个性化搜索任务的基本框图

Fig. 2 Diagram of personalized search task with multi-source heterogeneous UGCs

个性化搜索算法和推荐算法将在可行域空间搜寻一组满足当前用户潜在需求且其可能感兴趣的项目推荐列表TopN, 即 N 个具有较高 $f_u(\mathbf{x})$ 值的项目集合, 进行有效的个性化项目推荐. 因此, 如何精准描述表达用户偏好的目标函数 $f_u(\mathbf{x})$, 辅助用户在复杂海量信息环境中尽快搜寻到用户满意解, 是面向多源异构数据个性化搜索和推荐任务的重点及难点, 也是目前人工智能领域亟待解决的难题.

3 个性化搜索和推荐算法相关工作

广泛收集互联网中的用户生成内容和相关项目内容信息, 如: 用户画像、项目类别标签、项目内容属性、用户历史交互行为记录(包括点击、浏览、评分、收藏、申领优惠券等行为)、用户评论、时间上下文、地理位置、社交网络信息等, 这些数据包含了大量的用户兴趣偏好信息. 个性化搜索和推荐算法通过分析并深入挖掘含有用户需求及个性化偏好的UGC信息, 建立用户兴趣偏好模型, 预测用户对于项目的潜在需求和兴趣偏好, 帮助用户尽快搜寻其满意解, 提供个性化服务.

近年来, 个性化推荐系统采用多种用户偏好提取技术、个性化推荐关键技术等, 在一定程度上解决了个性化搜索和推荐的实际问题, 展现出良好的搜索效率及推荐结果. 从不同视角出发, 对于个性化搜索和推荐算法的分类方法各有不同, 主要包括: 基本分类方法、采用各种机器学习技术的方法、利用不同类型用户生成内容的方法以及个性化动态搜索方法等. 这些分类方式的分类结果互有重叠和交叉, 从不同方面展现了个性化搜索和推荐算法丰富的多面性. 这里总结了个性化搜索和推荐算法的分类方法的总体框架如图3所示.

图3呈现了个性化搜索和推荐算法的分类方法及其相应的各种个性化搜索和推荐算法, 本小节对于相关工作和算法的阐述与总结也将围绕图3展开. 其中, 基本分类方法将个性化搜索和推荐算法分为基于内容的推荐算法、协同过滤推荐技术和混合推荐算法, 已有许多相关综述论文对于这类基本分类方式的内容进行了介绍. 因此, 本文将着重论述利用机器学习或深度学习的方法、深入挖掘用户生成内容, 以及考虑个性化动态搜索过程的个性化搜索和推荐算法.

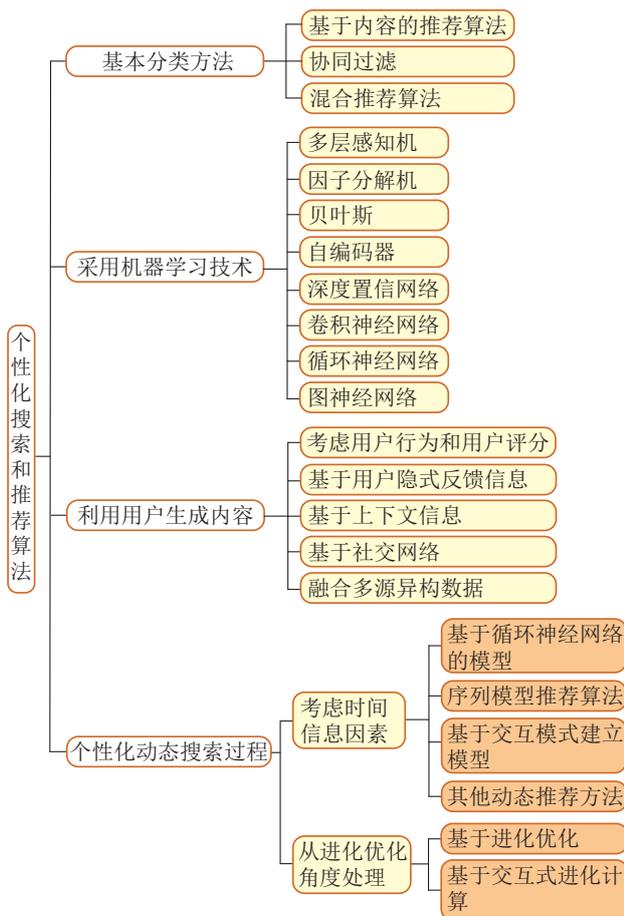


图3 个性化搜索和推荐算法分类

Fig. 3 Classification on personalized search and recommendation algorithms

3.1 个性化搜索和推荐算法

在实现个性化搜索和推荐任务过程中, 面向UGCs 构建用户兴趣偏好模型是核心. 当前流行的建模方法包括: 多层感知机(multilayer perceptron, MLP)^[16-17]、因子分解机(factorization machine, FM)^[18-19]、贝叶斯(Bayesian)模型^[20-21]、自编码器(autoencoder)^[22-23]、深度置信网络(deep belief networks, DBN)^[24-25]、卷积神经网络(convolutional neural network, CNN)^[26-27]、循环神经网络(recurrent neural network, RNN)^[28-29]、图神经网络(graph neural network, GNN)^[30-31]等, 这些模型都取得了较好的个性化推荐效果. 另一方面, 从合理利用数据的角度, 个性化搜索和推荐算法可分为: 考虑用户行为和用户评分、考虑用户隐式反馈信息、基于上下文信息、结合社交网络、融合多源异构数据等方法. 上述分类方法是从建立模型和可用数据两方面进行归纳与总结. 然而, 这些构建用户兴趣模型的算法和利用用户生成内容的方法又是相辅相成、紧密联系的, 因此, 本节将对这些方法进行有机关联的综述.

3.1.1 考虑用户行为和用户评分的推荐算法

早期推荐技术主要采用协同过滤推荐算法, 通过相似性度量衡量不同用户或项目之间的相似性, 实现个性化搜索和推荐任务. 网络中大量存在的用户交互行为和用户评分数据包含了表达用户兴趣偏好的有用信息. Rendle等人^[32]利用源于问题的贝叶斯, 分析最大后验估计, 提出了贝叶斯个性化排序模型, 并给出了协同排序的通用框架及其贝叶斯解释. 进一步, Rendle^[18]联合支持向量机和因子分解模型, 利用因子化参数模拟变量间的交互关系, 在稀疏数据中获取交互信息, 提出了FM模型. FM模型作为机器学习任务的通用学习框架, 模拟任意特征之间的二阶交互, 其公式如下:

$$\hat{y}(x) = \varpi_0 + \sum_{i=1}^n \varpi_i x_i + \sum_{i=1}^{n-1} \sum_{j=i+1}^n \varpi_{ij} x_i x_j, \quad (2)$$

其中: x_i 和 x_j 分别表示两个不同的特征取值, n 表示样本的特征数目, ϖ_0 是全局偏置, ϖ_i 是样本权重, ϖ_{ij} 是样本特征组合的权重.

后续许多个性化搜索和推荐算法都是基于因子分解机模型框架或者结合深度学习技术进行改进和扩展的. Song等人^[33]在已训练全局RankNet模型基础上, 通过信息丰富的实例连续训练适应用户特征的RankNet模型, 并利用Kullback-Leibler散度、点击熵或启发式评估适应实例的有效性, 提出了自适应深度RankNet模型, 进行个性化搜索. Miao等人^[34]通过局部平滑正则化探索无标签数据的多样结构, 采用最小化基于序列集成学习框架的正则化惩罚成对损失目标, 提出了半监督正则化推进排序算法. Zhuang等人^[35]提出成对约束表示学习的协同排序框架, 同时学习用户和项目的隐因子与成对排序损失. He等人^[16]提出了神经协同过滤算法, 构建双重神经网络模拟用户和项目间的双向交互模式, 捕捉嵌入维度之间的高阶关联关系, 应用于跨领域推荐. Fu等人^[36]预先理解用户与项目的特征, 提出了基于深度学习的协同过滤模型. Xue等人^[37]考虑项目之间的非线性高阶关系, 提出基于项目的深度协同过滤TopN推荐算法. 于亚新等人^[38]综合考虑用户行为发生时间、活动内容、活动区域等信息, 利用潜在狄利克雷配置(latent Dirichlet allocation, LDA)技术建立活动-服务主题模型, 提出基于耦合和距离的矩阵分解算法. Lian等人^[39]设计端到端的学习工作流, 采用多种精馏策略, 较好地保留了用户-项目的相关性得分和相对排序, 进一步提高表示质量, 提出轻量级推荐系统LightRec, 具备快速在线推理和经济性内存消耗. 田震等人^[40]在广义矩阵分解模型的基础上引入隐藏层, 利用深层神经网络学习用户和物品之间的高阶交互关系, 提出深度矩阵分解推荐算法. Sun等人^[41]结合双曲空间和图卷积神经

网络,通过边缘排序损失函数进行学习,提出双曲图卷积网络协同过滤. Sun等人^[42]提出了场矩阵因子分解机,建模领域信息,并支持修剪交叉项和嵌入向量的特定字段变量维度作为软剪枝,有效提升模型的预测性能和推荐能力.

这些个性化搜索和推荐算法计算框架简单,大量使用用户-评分数据,模型训练依赖这些用户生成数据,通常需要更多时间构建并训练模型.然而,在实际应用场景中,由于互联网用户和项目数量、规模很大,用户显式反馈数据量相对较少,有时甚至无法有效获取用户偏好信息.因而,考虑用户行为和用户评分的推荐算法面对高稀疏用户评分数据时,存在数据缺失、稀疏性、冷启动等问题,将严重影响模型的预测性能、搜索质量及推荐效果,导致个性化搜索和推荐算法的综合性能表现不佳.

3.1.2 考虑用户隐式反馈信息的推荐方法

复杂互联网环境下的用户生成内容,包含许多具有明确意图的用户显式评价(如:评分)和大量真实意思表示的用户隐式反馈(如:搜索关键词、浏览、点赞、收藏、分享、观看生活秀、使用优惠券、购买、评论等行为),这些数据从不同侧面显式或隐式表达了用户个性化兴趣偏好.其中,显式评分方式需要用户对于项目做出明确评价,实现简单、获取直接,明确表达了用户兴趣偏好的选择倾向,但该过程容易引起用户心理疲劳和评价负担,数据收集较为困难,因而其数据稀疏、包含的可用信息有限.隐式反馈数据隐含表达了用户的兴趣偏好,具备获取来源灵活、收集成本低、数据规模大,以及应用场景广泛等优点.若能够充分利用UGCs中的海量用户隐式偏好信息,无疑将对于用户显式偏好信息不充足、数据稀疏性等问题产生积极影响,有益于精准获取用户偏好,保障个性化搜索和推荐过程的顺利推进.

考虑用户隐式反馈数据,针对不同用户行为模式,通过辅助判定产生用户对于项目的偏好评定. Kassak等人^[43]利用显式反馈和隐式反馈(如:浏览时间),建立用户兴趣偏好模型. Qiu等人^[20]提出贝叶斯个性化排序算法,处理异构隐式反馈信息,增强推荐系统的性能. Zhou等人^[44]设计局部激活单元,提出了深度兴趣网络,能够根据历史行为数据自适应地学习用户兴趣表示,应用于Alibaba集团在线展示广告系统. Liu等人^[21]考虑隐式偏好数据的不确定性和推荐结果的多样性,提出了基于贝叶斯Mallows模型的个性化推荐算法. Lee等人^[45]采用用户对于未评分项目的预偏好概念,识别出用户未评分但可能不感兴趣的项目,选择性地归为低价值项目,并注入用户-项目矩阵中,提出 l -注入协同过滤框架,解决推荐系统稀疏性问题. 薛峰等人^[46]采用深度神经网络建模用户与物品之间的

关系,并利用注意力机制,计算在建模用户隐式反馈时历史交互物品的权重,提出基于深度神经网络和加权隐反馈的个性化推荐算法. 司亚利等人^[47]利用用户签到的活跃度,给出用户不活跃和活跃的隶属度计算方法,并结合时间因素幂律函数和高斯核密度估计,计算用户活跃特征的概率值,提出基于用户签到活跃度特征和时空概率模型的自适应兴趣点推荐方法. Askari等人^[22]集成两个变分自编码器,提出了联合变分自编码器,共同学习用户表示和项目表示,重构并预测用户偏好,进行基于隐式反馈的Top N 推荐. 这些研究成果提供了许多有价值的参考.然而,由于用户可能存在误操作或为赢得奖励而进行转发等行为,而这些隐式反馈信息不能准确反映实际用户偏好.因此,在实际应用过程中,个性化推荐算法对于用户隐式反馈数据质量有一定要求,需检验数据的可靠性.

3.1.3 基于上下文信息的推荐模型

网络中实体的上下文信息通常用于描述用户或项目的状态,用户兴趣偏好与上下文信息紧密相关.考虑上下文信息,利用深度学习技术面向用户开展个性化搜索和项目推荐. Kim等人^[48]整合CNN和概率矩阵分解,捕捉文档的上下文信息,利用积极和消极偏好,提出了鲁棒的文档上下文感知混合模型,称为卷积矩阵分解. Yang等人^[49]结合协同过滤和半监督学习,通过连接相邻用户和兴趣点联合学习用户偏好与上下文嵌入,提出通用基于深度神经网络的半监督学习框架,缓解数据稀疏问题. Du等人^[50]结合场景特定学习和模型无关的序列元学习,统一到场景特定的顺序元学习框架,通过聚合来自各种预测任务的上下文信息,生成元学习器通用初始模型,利用学习知识有效地适应特定任务,缓解在线推荐过程中的冷启动问题. 赖奕安等人^[51]建模用户参与活动记录和活动相关上下文信息,利用多关系贝叶斯个性化排序方法学习协同上下文关系,提出基于协同上下文关系学习的同城活动推荐算法. Yang等人^[52]基于剩余资源/时间和不同用户情境中奖励分布估计分配探索资源,充分利用上下文特征信息,提出了分层自适应上下文匪徒方法,搜寻最佳个性化推荐结果. Fu等人^[53]建立图神经网络,模拟社交关系和协同关系,提出面向社交推荐的双边深度上下文感知调制模型,在高阶关系基础上捕捉朋友信息与项目吸引力.

然而,这类方法在项目类别或领域层次上抽取用户偏好,粒度较大,还有进一步提升的空间,进而获得精准推荐结果.此外,在实际运行过程中,深度学习和矩阵分解的单独训练过程较耗时,需考虑合适的组合形式及训练方式,且其实际效果不易整体把握.

3.1.4 结合社交网络的推荐方法

结合社交网络信息的推荐方法具有可靠性高、转

化潜在需求为实际购买力强等优点, 将进一步提高个性化搜索和推荐算法的性能。Nguyen和Lauw^[54]通过建模社会化关系, 提出利用同质性整合社交网络和受限玻尔兹曼机(restricted Boltzmann machine, RBM)的偏好模型, 学习用户偏好的潜在隐表示, 预测未知评分。Deng等人^[55]利用深度学习, 确定MF中具有信任感知的社交推荐初始化权重, 区分用户信任关系的社区效应, 并结合用户兴趣和社交关系, 提出基于信任社交关系的深度学习推荐算法。Guo等人^[56]利用显式和隐式用户偏好信息建立用户之间的信任关系, 提出了基于信任和情感的协同过滤推荐方法。进一步利用图神经网络, 陈晋音等人^[57]提出基于文本生成式对抗网络的自动点评技术和基于图过滤的快速密度聚类双层网络推荐算法, 有效过滤数据中的虚假信息, 提高推荐效果。王大刚等人^[58]根据多种信息源, 设计混合隶属度随机块模型建模用户间交互关系, 结合主题模型和自编码器学习用户隐特征与物品特征, 并利用概率框架共同学习矩阵分解模型中的关系矩阵, 提出基于贝叶斯和自编码器的社会化推荐算法。杨洁等人^[59]利用服务提供者信息, 设计用户-候选服务信任值预测算法, 基于混杂社交网络的个性化Web服务推荐方法, 缓解冷启动和数据稀疏问题。Yu等人^[60]通过超图卷积网络编码描述高阶用户关系模式, 利用多渠道学习的聚合嵌入获得全面用户表示, 同时, 整合自监督学习, 重新获取与层级互信息最大化的连接信息, 提出多通道超图卷积神经网络增强的社交推荐。上述研究工作充分利用社交网络信息和各种建模方法, 改进已有个性化推荐算法的不足, 尽可能地贴合实际应用场景, 缓解信息不充分、数据稀疏等问题, 提高算法的预测性能及推荐效果。

在网络的海量用户生成数据中包含丰富的用户偏好信息, 这些多源异构数据对于建模用户兴趣偏好、抽取用户偏好特征以及引导用户个性化搜索过程十分有价值。因而, 需有效挖掘多源异构用户生成数据, 在整体框架中融合多源异构数据, 捕捉用户兴趣偏好及深层次的用户偏好特征, 制定高效的个性化搜索途径及推荐方案, 实施精准有效的个性化推荐。

3.1.5 融合多源异构数据的个性化推荐算法

大数据环境下的个性化搜索和推荐系统受到越来越多学者的广泛关注。网络中UGCs信息包含来源众多的结构化、非结构化数据, 具有多源、异构、异质等复杂特性, 其大量产生并持续增长。其中, 多源是指从不同角度描述某一相同主题, 且分布于不同数据源中; 异构是指这些描述主题信息来源于不同渠道, 并将以不同的数据形式呈现; 异质是指由于数据来源不同, 则数据相对于任务的贡献度不同, 所引起的数据质量参差不齐。这些海量多源、异构、异质、多模态数据,

如: 用户交互行为、用户评分、类别标签、属性信息描述文本、文本评论、社交知识、位置信息、图像、音频、视频等信息, 从不同角度反映了用户潜在需求、认知经验和兴趣偏好。

在实际个性化推荐过程中, 常会遇到用户历史交互数据较少、有用信息不充足等情况, 难以精确刻画用户兴趣偏好, 进而对于个性化搜索和推荐任务产生不利影响。为了缓解这些问题, 采集并获取多方面不同类型的数据, 尝试综合考虑并有效融合多源异构用户生成数据, 充分发挥各自优势、弥补不足。利用机器学习、深度学习等技术, 构建全面而精准的用户兴趣偏好模型, 深入挖掘用户个性化偏好特征, 从而提供更好个性化服务。另一方面, 这些数据存在噪声、缺失、不完备等复杂情况, 需对原始数据进行预处理, 如: 筛选整理、数值规范化、向量化表示等, 这些都是进行有效个性化推荐的重要推动因素。Wang等人^[61]利用项目文本辅助信息的深度表示和评分矩阵的协同滤波, 结合贝叶斯栈式降噪自编码器模型与概率矩阵分解, 提出协同深度学习混合推荐方法。Cheng等人^[62]综合用户特征、情境特征、项目特征等信息, 联合训练宽广线性模型和深度神经网络, 提出了宽广学习模型, 应用于移动APP推荐。Zheng等人^[63]设计包含两个平行网络的深度协同神经网络, 分别从用户评论和项目评论中学习用户与项目的隐特征表示, 并通过共享层预测用户对项目的评分, 进行项目推荐。Meng等人^[64]从全局和局部的角度分析用户评论中的积极和消极情绪, 提出基于用户评论情感挖掘的推荐算法。李琳和唐守廉^[65]利用度量学习从全局和细粒度层面挖掘用户偏好, 建立优化个性化排序的概率图模型, 设计监督学习策略, 学习内容语义特征提取模型, 提出融合内容表示的度量排序学习推荐模型。冀振燕等人^[66]融合用户评分、文本评论、社交关系等多源异构数据, 采用全连接神经网络处理评分数据, 依据基于段向量的分布式词袋模型处理文本评论, 通过用户好友信任度模型引入社交关系, 利用改进的贝叶斯个性化排序模型优化排序结果, 提出可扩展的融合多源异构数据的推荐模型。上述方法分析了用户文本评论、项目属性描述等信息与用户兴趣偏好之间的关联关系, 给出了许多优良的个性化搜索和推荐算法。

然而, 若存在交互操作行为较少、项目内容和用户评论较短或包含较少核心重点词汇等情况, 将严重影响获取用户偏好特征, 从而导致实际推荐效果较差。考虑进一步联合多种类型数据, 如: 图片、视频等。Covington等人^[67]针对YouTube系统所包含的丰富视频和图像信息, 提出利用深度学习构建深度候选解生成模型和深度排序模型, 提高个性化推荐的准确率。Wang等人^[68]采用CNN提取图像特征, 构建概率主题模型, 设计优化函数, 提出了基于CNN和概率矩阵因

子分解的视觉内容增强的推荐模型. 吴宾等人^[69]通过融合多关系数据和视觉信息, 缓解数据稀疏问题, 提出面向多源异构数据的协同过滤推荐算法. Wan等人^[70]考虑用户交互反馈和产品营销图像之间的相关性, 研究了协同过滤算法对用户交互数据中消费-商品细分市场分布的响应, 开发了个性化商品推荐框架, 缓解在代表性不足的细分市场上推荐系统潜在的营销偏差, 提高了不同细分市场的推荐公平性. 在实际应用中, 用户情感和兴趣偏好具有复杂性、主观性和多面性, 预测用户未来的选择行为、推荐用户满意的项目任务难度较大. 同时, 各种类型数据中有效信息的聚合模式不同, 各类方法抽取的用户偏好特征各异, 对于个性化推荐算法的实际效果也不易确定. 因而, 建立统一的推荐系统框架及其分析方法仍旧是需要深入探索的研究方向.

利用深度学习强大的特征提取能力和学习表示能力, 从特征宽广性的维度充分挖掘多源异构数据, 提取并整合碎片化隐含的用户偏好信息, 增强个性化搜索和推荐系统的综合性能. Wang等人^[71]设计基于异构信息网络的统一嵌入模型, 提高个性化推荐的性能. Ke等人^[72]整合稀疏的类别特征和稠密的数值特征, 提出集成梯度增强决策树的深度学习框架(deep learning framework distilled by gradient boosting decision tree, DeepGBM)算法, 进行在线预测任务. 包恒泽等人^[73]通过结合标签与资源内容之间的标注关系、资源之间的链接关系等多源异构信息, 挖掘潜在语义特征, 并对文本内容和资源网络拓扑结构进行建模, 提出融合多源异构网络的概率主题模型及标签推荐方法. Liu等人^[74]通过优化权重自动选择和组合元路径, 利用多样性测度增加元路径之间的多样性, 提出基于元路径和多样性正则化的异构信息网络用户偏好建模. Cen等人^[75]建立多兴趣模块, 从用户行为序列中捕捉多样兴趣, 同时探索大规模项目池中的候选项目, 输入聚合模块, 提出可控制多兴趣顺序推荐框架, 权衡整体推荐的准确性和多样性. 上述研究综合考虑多源异构用户生成数据及数据之间的耦合关系, 分析影响用户偏好的因素, 全面理解用户行为, 构建准确表示用户真实意图的兴趣偏好模型, 取得了良好的预测性能和个性化推荐效果. 然而, 这些复杂网络模型的参数规模和特征维度通常会非常巨大, 将消耗大量计算资源, 训练时间也将急剧增加, 在实际应用过程中需考虑个性化推荐算法的实现效率、运行成本等问题.

近几年, 针对目前个性化搜索和推荐系统中信息量不充足、用户评价不确定性等问题, 学术界和工业界研究了许多高效地创新性方法, 如: 知识图谱、注意力机制等, 并在个性化推荐研究领域引起了研究热潮. 下面将针对这些相关研究成果展开进一步论述:

1) 基于知识图谱的网络模型.

知识图谱利用多类型信息, 将包含各种实体关系的知识图谱嵌入连续向量空间, 精确挖掘用户偏好. Mao等人^[76]设计通用用户-项目-属性-上下文数据模型, 综合不同信息资源及高阶相互关系, 构建多部超图, 提出了基于超图排序的多目标电子商务推荐系统. 陈嘉颖等人^[77]根据非结构化文本评论, 利用知识图谱技术提取项目特征和实体关系, 并通过知识图谱表示学习方法进行用户和项目的细粒度特征向量表示, 设计知识感知的协同学习框架, 提出融合语义分析特征提取的推荐算法. Zhao等人^[78]利用网络模式采样方法生成子图, 采用多任务学习保留各模式实例的异构结构信息, 提出异构信息网络嵌入模型. Hu等人^[79]通过将高阶关系编码入用户和新闻表示, 建模用户-新闻交互的二部图, 提出无监督偏好分解图神经网络推荐模型. Lu等人^[80]面向用户及其查询, 执行个性化实体链接查询和表单, 进行意图表示, 并建立用户知识增强档案, 存储搜索历史中的预测搜索意图和链接实体, 提出了知识图增强的个性化搜索. Li等人^[81]结合当前用户和积极项目的中心度量, 保持较近积极项目到用户的距离, 同时, 推动消极项目远离积极项目, 提出自适应边际对称度量学习推荐方法. Jin等人^[82]通过元路径引导邻域, 捕获节点间的交互模式, 并以卷积方式定义交互模式, 提出了端到端基于社区的异构图交互模型, 用于基于异构信息网络的推荐. Liu等人^[83]设计无监督子图生成模块, 通过用户特征和图结构有效识别具有共同兴趣的用户并形成子图, 提出兴趣感知消息传递的图卷积网络推荐模型, 能够在子图内部执行高阶图卷积. Zheng等人^[84]利用图卷积网络, 联合生成候选解过程与多样化候选解生成, 并进行再平衡邻居发现、类别增强负采样和对抗学习, 提出了基于图卷积网络的多样化推荐, 缓解推荐的准确性与多样性困境. Pang等人^[85]设计异构图神经网络, 学习具有丰富语义的长期用户偏好和项目表示, 并给出个性化会话编码器, 结合用户一般偏好和当前会话的时间兴趣生成个性化会话表示, 提出异构全局图神经网络, 进行个性化会话推荐.

这些方法将知识图谱技术应用于个性化搜索和推荐领域, 对于获取用户偏好特征、进行有效的个性化推荐等内容具有很强的指导意义, 引起了学术界的广泛关注, 相关内容形成了研究热点. 但是, 实际真实的个性化推荐情景是十分复杂且动态演化的, 基于知识图谱推荐模型的综合效果、适应性和扩展性还有待进一步检验及验证.

2) 基于注意力机制的个性化推荐算法.

受到人类视觉机理的启发, 注意力机制(attention mechanism, AM)成为近几年的研究热点, 已成功应用于图像处理、自然语言理解、语音识别、模式生成等研究领域^[85-88]. 传统神经网络模型在处理数据时对

于所有输入单元采用相等的权重,以至于模型无法充分利用其中重要区域信息,因而其处理分类、预测任务是不可靠的.而基于AM的神经网络在模型训练过程中能够从众多信息中自适应地选择出更关键的区域信息,并用权重表示其重要性程度,从而使得模型将重点关注这些重要特征信息,同时也增强了模型的特征提取能力和可解释性.

结合注意力机制应用于个性化搜索和推荐算法,自适应调整信息权重,将较大权重分配给重要的信息单元,能够有效提高用户偏好建模能力和模型评分预测能力.Seo等人^[89]利用CNN在提取复杂特征方面的优势,提出基于局部和全局双注意力的CNN,建模用户偏好和项目属性特征,进行评分预测.Hu等人^[90]联合基于元路径的上下文信息,提出了协同AM的深度神经网络,进行TopN推荐.Xu等人^[91]整合异构信息网络中的异构特征,提出关系感知的协同注意力图卷积网络,应用于代理发起的社交电子商务推荐任务.Wu等人^[92]利用CNN网络,学习新闻文章的隐表示和基于用户点击新闻的用户表示,提出个性化注意力神经新闻推荐模型.张青博等人^[93]根据用户信任网络和评分记录,构建用户-项目异构网络,挖掘用户之间的相似关系,并引入注意力机制,分析用户对项目各属性特征不同的关注度,获取用户偏好,提出基于注意力机制的规范化矩阵分解推荐算法.冯兴杰和曾云泽^[94]结合双向门控循环单元和注意力机制,抽取用户和商品的深层非线性特征向量,并融合深层非线性特征和潜在隐特征,提出基于评分矩阵与评论文本的深度推荐模型.Tanjim等人^[95]通过自注意层从用户历史交互数据中学习项目的相似性,利用时态卷积网络层从用户对特定类别行为中获取用户意图的潜在表示,提出潜在意图的注意力序列模型,进行项目推荐.Shen等人^[96]利用个性化导向的用户特征、情感导向的用户特征和多面属性的音乐特征,建模用户长期品味(个性化)和短期偏好(情感),并利用分层注意区分重要因素,提出整合用户个性化和潜在情感的注意力模型,进行社交媒体平台的音乐推荐.Sun等人^[97]设计多模态图注意力技术,提出了多模态知识图谱注意力网络,并利用生成的聚合嵌入表示进行推荐,增强推荐系统性能.谡明等人^[98]在联邦蒸馏目标函数中加入Kullback-Leibler散度和正则项,引入多头注意力机制丰富编码信息,设计自适应学习率训练策略自动切换优化算法,提出基于注意力联邦蒸馏的推荐方法.Guo等人^[99]设计由残差连接和整体连接组成的深度图卷积网络,缓解过平滑问题,并给出混合归一化层和简化注意力网络,自适应融合不同归一化规则信息,建模邻居重要性,提出了混合归一化深度图卷积网络,进行精确和多样化推荐.Wu等人^[100]提出了归纳式协同过滤框架,包含两个模型:采用传统矩阵分解方法,

分解一组关键用户的评分矩阵,获得元潜在表示;利用基于注意力机制的结构学习方法,通过神经消息传递估计查询用户与关键用户之间的隐关系,归纳学习查询用户的嵌入表示.上述方法利用注意力机制实现个性化推荐,呈现了基于AM的神经网络模型能够更精细地抽取特征信息,加强重要特征对于个性化搜索和推荐任务的贡献,有效提高预测精度和推荐质量.

综上所述,融合多源异构数据的个性化搜索和推荐算法充分挖掘多源异构用户生成内容,利用机器学习、深度学习等技术,取得了比传统推荐系统更好地预测效果及推荐结果,展现了个性化推荐方法良好的全面性和可扩展性.然而,构建基于深度学习的网络模型复杂度较大,训练时间较长,更新模型耗时,且算力需求较高.同时,在实际应用过程中,需针对用户生成数据进行向量化表示,设计融合多源异构数据的一致化向量表达,这些内容均是个性化搜索和推荐研究领域的重要研究方向,尚未有成熟的研究成果可供参考.另一方面,挖掘和分析相关用户数据将涉及用户隐私保护问题,需考虑采用匿名脱敏数据友善获取用户偏好信息,应用于个性化搜索和推荐系统,这些内容也是值得深入研究的方向.

3.2 面向用户生成内容的动态个性化搜索和推荐算法

网络中的海量多源异构用户生成数据同时具有多模态、动态演化等特性.其中,多模态是由于数据来源和结构不同,所呈现出来表达事物或事件的描述角度、固有属性及特征表示不同;动态演化是由于多源渠道参与描述某一主题,在时间、空间上数据不断累积、更新和替换,从而发生动态变化.面向UGCs个性化搜索和推荐任务中,用户的兴趣和偏好是多种多样的,具有模糊性、不确定性等特性,同时,用户兴趣偏好可能会随着时间推移、环境迁移或信息量增加而发生动态演化,且伴随搜索空间不连续、可行域变更等,这些都将增加个性化推荐的难度.比如:在电子商务领域中的双11购物节、热点事物或新闻、一些促销力度较大的商品信息等,可能在短期内迅速成为热点,吸引大众注意力,聚焦客户购买欲望,用户可能会有不同于平常购物习惯的新兴趣爱好呈现.

因此,在现实生产和生活中,需充分挖掘多源异构且动态演化的用户生成内容,构建精准地用户兴趣偏好模型,获取用户动态偏好特征、及时更新用户偏好模型、动态跟踪用户偏好变化,满足用户真实潜在需求,适应实际个性化推荐任务,这些研究内容都是个性化搜索和推荐领域的重点及难点.从考虑动态个性化搜索过程角度,个性化搜索和推荐算法可分为考虑时间信息因素的建模方法和基于进化计算的个性化进化搜索方法.

3.2.1 考虑时间信息因素的建模方法

1) 基于循环神经网络的模型.

考虑划分时间窗口,利用RNN建立用户兴趣偏好模型,能够有效抽取用户长短期兴趣偏好特征. Liu等人^[101]采用RNN和Log双线性模型,分别建模用户行为间的长程依赖关系和短时情境信息,提出循环Log双线性模型. Cui等人^[102]利用RNN建模时间步长的联结因子,提出基于层级上下文注意力网络,建立近期因素之间的复杂相关性,进行个性化排序. 张宜浩等人^[103]结合长短期记忆网络(long short term memory, LSTM),实现从上下文语义层面对于用户评论的情感分析,并融合用户评分、情感倾向及物品内容,提出基于用户评论的深度情感分析和多视图协同融合的混合推荐算法. Ma等人^[104]设计时间感知的LSTM架构,建模连续时间中精细地用户兴趣演化,捕捉用户短时兴趣;同时,根据时间信息计算各历史问询和文档重新发现的可能性,捕获用户长时兴趣,提出细粒度时间信息增强的个性化搜索模型. Hu等人^[105]建模用户、新闻和潜在主题之间的交互信息,利用图神经网络传播异构图嵌入,学习用户与新闻表示,并构建基于注意力机制的LSTM模型,提出基于长短期兴趣建模的图神经网络推荐算法. 这些方法利用循环神经网络有效处理与时间信息相关的序列模式,取得了较好的个性化搜索和推荐效果,但建模时间与实际任务实时性需求是其面临的严峻挑战和亟待解决的难题.

2) 序列模型推荐算法.

整合时间信息因素,建立时间序列模型,进行个性化序列推荐. Li等人^[106]考虑用户的内在偏好(长期偏好)和序列模式(短期偏好),提出了评论驱动的神神经序列推荐模型. Li等人^[107]在序列模型框架下建模用户行为交互模式,探索不同时间间隔对于预测下一个项目的影响,提出基于时间间隔感知的自注意力序列推荐算法. Wu等人^[108]利用自注意机制动态调整相对输入,部署多参数化核函数学习各种时序动态,并使用上下文信息确定各调整权重,学习用户历史行为类别与发生时间的影响,提出上下文时序注意力序列推荐模型. Zhou等人^[109]设计了4个辅助自监督目标,依据互信息最大化原则学习属性、项目、子序列和序列之间的相关性,提出基于自注意力神经架构的自监督学习序列推荐. Xie等人^[23]在对抗变分贝叶斯框架下,利用对抗训练生成含高质量潜在变量的序列,同时采用循环和卷积结构,捕获序列中的全局和局部关系,提出了对抗和对比变分自编码器,进行序列推荐. Hsu和Li^[30]根据局部子图抽取用户-物品对,训练关联注意力图神经网络,并通过序列自注意力机制,编码用户偏好的长期和短期时间模式,提出了关系时序注意力图神经网络,进行整体序列推荐. Li等人^[110]

考虑了高阶异构协同信号和序列信息,通过添加属性信息丰富用户-物品二部图,构建异构信息网络,设计消息传递层学习用户和物品嵌入,提出了序列感知异构图神经协同过滤模型. 上述方法从序列推荐的角度处理个性化推荐任务,取得了良好效果,适用于实际个性化搜索和推荐系统的应用场景. 但是,关于序列推荐时间步长的设定,将在很大程度上影响推荐结果,这些理论内容与实际应用的深入研究还有待进一步讨论.

3) 基于交互模式建立模型.

考虑个性化搜索过程中的用户交互信息与交互模式,引导个性化推荐. Wei等人^[111]设计了多模态图卷积网络框架,根据用户与项目之间的交互信息,学习用户和微视频的特定模式表示,更好地捕获用户偏好,进行个性化微视频推荐. Ji等人^[112]提出时态异构交互图嵌入,模拟复杂历史交互数据的动态特性,学习用户与项目的嵌入表示,使得长期历史偏好能够引导短期需求的动态演化,进行项目推荐. 汤文兵等人^[113]提出了基于AM的协同卷积动态推荐网络,捕捉高阶特征交互,提升推荐效果. Qi等人^[114]利用知识图谱建模已点击新闻与候选新闻的语义相关性,交互式学习基于文本知识的新闻表示和用户兴趣表示,提出知识感知交互匹配框架,进行个性化新闻推荐. Wang等人^[115]在深度交叉网络(deep & cross network, DCN)的基础上,提出新的改进深度交叉网络模型(new deep & cross network model, DCN-V2),自动高效地学习边界度预测特征交互,应用于实际大规模工业环境中的网络规模学习排序系统. 这些模型和算法从交互模式角度考虑描述用户动态偏好,处理个性化搜索和推荐问题,均获得了较好的综合性能.

4) 其他动态推荐方法.

此外,个性化搜索和推荐研究领域涌现出一些其他类型的动态推荐方法,如:迁移学习、强化学习等技术. Zhang等人^[116]采用区域自适应调整重叠实体的特征空间,利用扩散核补全方法关联两个区域之间不重叠实体,提出基于核诱导知识转移的跨领域推荐系统(cross-domain recommender system based on kernel-induced knowledge transfer),称为KerKT,通过重叠实体有效转移知识,从而缓解数据稀疏问题. Chen等人^[117]利用生成对抗网络,模仿用户动态行为,学习奖励函数,同时,给出新型级联深度Q网络算法,设计能够高效处理大量候选项目的组合推荐策略,提出了生成对抗用户模型,用于基于强化学习的推荐系统. 燕彩蓉等人^[118]考虑时间动态性,利用时间窗口设置不同粒度的时间因子,进行动态建模,并设计样本数据生成和存取策略,提出基于时间动态性的场感知分解机模型. 刘真等人^[119]充分融合辅助领域和目标领域

的知识, 通过基于矩阵分解的矩阵拼接和矩阵填充, 获得在群集矩阵和评分矩阵中的共性知识表示, 同时, 利用知识迁移, 构建重叠和非重叠用户的个性知识表示, 提出基于知识聚合和迁移的跨领域推荐算法. Morik等人^[120]依据隐式反馈数据学习排名函数, 明确地对项目组执行基于价值的公平性衡量, 提出动态学习-排名方法. Harshvardhan等人^[121]根据评分时间信息, 探测用户评分数据中的潜在隐藏特征, 将评分和时间作为双输入, 通过蒙特卡罗马尔可夫链采样输出数据, 实现基于无监督受限玻尔兹曼机(restricted boltzmann machine, RBM)的时间感知推荐系统.

上述研究内容及方法的成功应用从多角度、多方面展示了考虑时间信息因素处理个性化搜索和推荐任务的有效性, 且对于用户长短期偏好的时间跨度考量不同, 推荐效果各异. 然而, 这些方法未考虑搜索区域范围的动态变化和如何增强待搜索项目多样性, 进而提升个性化搜索的高效性以及用户对于整体推荐过程与推荐结果的满意度.

3.2.2 基于进化计算的个性化进化搜索方法

1) 基于进化优化的个性化搜索和推荐算法.

在动态个性化搜索过程中, 利用智能进化优化算法建立个性化推荐模型. Dao等人^[122]提出基于遗传算法的上下文感知协同滤波推荐模型, 在传统协同过滤方法的基础上融入用户内容信息, 提升广告推荐精度. Dai等人^[123]联合RNN和多维点处理模型, 学习用户和项目的非线性特征表示, 并考虑用户与项目特征间的相互影响和特征演化过程, 提出了递归协同进化特征嵌入处理模型. Phangtrastu和Isa^[124]利用粒子群智能优化算法, 优化场感知分解机, 提高模型的预测精度和运行时间. Zhou等人^[125]设计本地激活单元自适应地学习用户兴趣表示, 提出深度兴趣进化网络, 处理广告点击率预测问题. Chen等人^[126]设计了几种附加噪声的网络态射变异算子和基于经典网络的宏观结构, 嵌入进化算法, 提出基于噪声网络形态变异的高效进化深度神经结构搜索方法. Zhang等人^[127]采用节点继承策略, 并在搜索空间中编码通道注意机制, 提出基于有向无环图的卷积网络进化搜索框架. 王永等人^[128]采用遗传算法处理用户隐因子和项目隐因子优化问题, 将增强指数机制融入个体选择策略, 并依据寻找重要隐因子的思想设计变异过程, 提出满足差分隐私保护的矩阵分解推荐算法. Zhao等人^[129]研究推荐过程中品味偏好的动态变化, 设计校准机制处理这些偏移或偏差, 提出基于演化兴趣的分布感知推荐算法. 上述算法从群体智能优化角度研究个性化搜索及推荐问题, 取得了较好的实际效果. 然而, 若进一步从利用用户知识导向和群体智能的角度研究个性化搜索和推荐任务, 充分探索并深入挖掘多源异构数据,

将提升推荐效果及用户满意度.

2) 基于交互式进化计算的个性化搜索和推荐算法.

近年来, 用户参与进化优化的交互式进化计算(interactive evolutionary computations, IECs)将用户主观认知经验、智能评价决策与传统进化优化算法相结合, 有效处理面向UGC的个性化搜索和推荐任务, 取得了丰硕的研究成果^[130-133]. 在IECs进化过程中, 用户通过主观意图方式对于具体优化问题进行显式主观评价, 给出相应的决策方案, 其借助真实用户评价替代数学模型表示的目标函数, 给出各候选解的个体适应值, 引导个性化进化搜索的前进方向, 逐渐搜索到用户满意解.

基于交互式进化计算的个性化搜索和推荐算法遵循“用户生成数据预处理—用户兴趣偏好模型构建—进化优化算子与策略设计—模型管理机制调控—用户评分预测和项目推荐”的分析处理过程, 其一般流程图如图4所示.

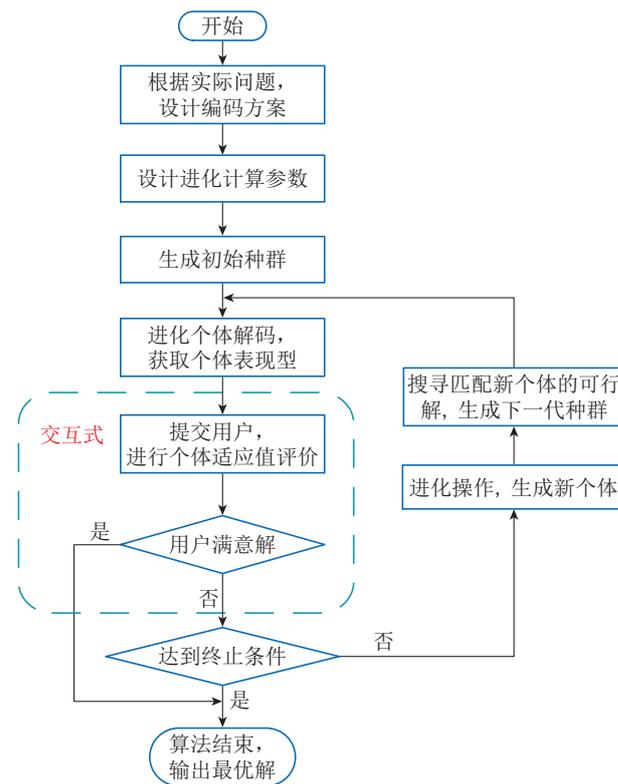


图4 交互式进化计算流程图

Fig. 4 Flowchart of interactive evolutionary computations

在交互式进化计算研究领域, 研究人员提出了诸多交互式进化优化算法, 处理复杂个性化搜索和推荐任务. Kant和Bharadwaj^[134]依据模糊理论, 利用隐式方法处理与项目表示相关的不确定性, 并结合交互式遗传算法与基于内容的推荐系统, 开发了面向用户的基于内容的推荐系统. 孙晓燕等人^[135]根据用户交互行为构建条件偏好网络, 拟合用户评价偏好, 提出基

于隐式评价模式的交互式遗传算法,指导用户个性化搜索。Sun等人^[136]考虑用户生成内容和用户偏好的动态演化特性,采用概率条件偏好网络作为代理模型,进行个性化图书搜索。Chen等人^[137]利用贝叶斯模型描述用户偏好分布,使用区间数值化表示用户偏好关系,构建基于径向基函数神经网络的代理模型,提出贝叶斯引导的交互式分布估计算法,实现个性化电脑搜索。Ashlock等人^[138]利用定位兴趣分形引入发育算法应用,改善人在回路IECs进化方法中的用户疲劳问题。上述研究内容均建立在用户进行一定量显式评价的基础上,通过联合用户兴趣偏好建模和基于用户知识导向的进化计算,丰富个性化推荐的项目多样性,提升个性化进化搜索的用户满意度。然而,早期关于用户兴趣偏好代理模型构建研究方面,多集中于通过多次重复评价获取环境变化信息,当环境变化时对进化种群中的所有个体或部分个体进行重置初始化操作,保障待搜索项目的多样性,防止陷入优化问题的局部最优。因而,个性化搜索算法中所构建的代理模型可靠性、精确性较低,严重时可能会影响进化搜索的前进方向,制约了在复杂环境下IECs算法处理实际个性化搜索和推荐问题的能力及其适应性。

因此,面向多源异构数据的个性化搜索和推荐任务,用户行为理解、基于多源异构数据的用户兴趣偏好代理模型构建、面向用户生成内容的个性化推荐等相关研究尚处于起步阶段,尚无令人满意的解决途径和求解方案。这些研究内容将主要从以下3个方面改进交互式个性化进化搜索算法:1) 用户生成内容和社交网络信息反映了普遍大众的兴趣偏好,这种关联关系具有客观性和可解释性,并将影响当前用户对于待搜索项目的选择倾向。需深入研究用户交互行为评价模式及其优化问题描述,融合用户行为要素之间依赖关系,理解用户潜在需求和兴趣偏好;2) 在交互式个性化搜索过程中蕴含着丰富的多源异构数据,利用机器学习或深度学习技术,挖掘用户兴趣偏好,建立用户偏好评价代理模型,减轻用户评价负担和心理疲劳,指导个性化进化搜索的前进方向;3) 随着时间推移、环境迁移或信息量增加,用户兴趣偏好将发生动态变化。需根据新增UGCs信息,利用动态定性指标优化模型管理机制及进化优化策略,更新用户兴趣偏好模型和用户评价代理模型,动态跟踪用户需求、偏好变化,引导个性化进化搜索,加速进化计算的寻优效率、收敛速度,顺利完成个性化搜索和推荐任务。

考虑用户偏好动态演化的关键性影响因素,联合交互式进化计算,深入挖掘多源异构数据,建立用户知识导向的动态定性指标优化模型,并设计行之有效的进化优化策略及其求解机制,引导并监控个性化进化搜索过程。Chen等人^[139]设计基于双概率模型的混合推荐算法,提出增强交互估计分布算法,处理个性

化搜索问题。Bao等人^[140]利用双RBM用户偏好模型有效抽取用户偏好特征,提出RBM辅助的交互式分布估计算法。Chen等人^[141]利用语言模型编码,结合基于Dirichlet多项式复合分布的用户偏好表示和贝叶斯推理机制,提出改进的交互式分布估计算法。Bao等人^[142]考虑用户评分、标签类别、文本评论、社交网络等信息,构建同时含有离散类别特征和连续语义特征的用户偏好模型,设计基于用户偏好和多相似用户社交关系的代理模型,提出面向多源异构数据的RBM偏好代理交互式分布估计算法。Bao等人^[143]进一步设计融合注意力机制的偏好认知代理模型和含用户生成内容的个性化进化搜索策略,提出融合注意力机制的增强RBM驱动的交互式分布估计算法,实现个性化搜索和推荐。这些方法利用用户生成内容构建用户兴趣偏好模型,设计高效的进化优化求解策略及实现机制,从而适应实时性要求较高、环境资源受限等移动设备或嵌入式系统场景下的实际个性化搜索和推荐任务。

4 常用数据集

在个性化搜索和推荐算法研究领域,通常需要收集、整理和处理,所涉及的数据集主要有通用公开数据集和内部私有数据集。其中,通用公开数据集包括由相关研究机构公开的通用数据集和由一些竞赛组织机构提供的比赛数据集;内部私有数据集包括相关工业企业提供的真实世界实际使用的内部数据集和由研究人员在互联网上抓取并整理的实验数据集。

通用公开数据集具备普遍适用性、数据权威性、注重保护隐私等优点,提供给个性化搜索和推荐算法研究领域的科研人员和技术开发人员使用。总结目前通常采用的通用公开数据集的描述和特点如表1所示。

此外,还有一些比赛、竞赛数据集,如:Kaggle竞赛、NeurIPS竞赛、WSDM竞赛、RecSys挑战赛、CIKM挑战赛、阿里云天池大赛等数据集,也常常用于个性化搜索和推荐系统的研究工作。

内部私有数据集主要是由于企业工作业务需要,通过企业内部相关部门收集并整理的商业内部私有数据。该类数据集具有内容充实、真实可靠、数据较新、可灵活调整等特点。然而,由于商业性、保密性等多种因素不便公开,只用于企业内部实验验证及调整。另外,若尚未存在满足实际研究需求的数据集,科研人员也可在互联网上自行抓取并整理所需数据,建立用于实际研究的实验数据集。

5 评价指标和评价体系

评价指标和评价体系用于衡量个性化搜索和推荐算法的综合性能,评价方式可分为离线测评、用户调查和在线实验。离线测评包括使用现有不同来源的数据集,运行多种个性化搜索和推荐算法,进行实验结

果测试, 评估相应算法的性能. 用户调查是指测试小组中的用户使用推荐系统完成一系列个性化搜索交互任务, 回答一些关于用户体验的问题, 观察、测试并记录用户行为, 检验推荐过程对用户行为的影响, 形成体验报告. 在线实验是指将个性化搜索和推荐算法

应用于已部署的实际系统中, 在不同用户测试组上运行各种算法, 进行大规模实验, 并通过对比分析用户对于系统应用过程中的实时反馈、下一步操作行为、实际体验等, 分析系统日志, 综合评价算法的性能及效果.

表1 通用公开数据集描述
Table 1 Description of common datasets

数据集	数据集描述
MovieLens ^[22-23, 36, 71, 74, 82]	由GroupLens研究组联合明尼苏达大学组织的电影评分数据集, 包含: 用户信息、电影名称、评分、类别属性、标签、时间戳等数据.
Delicious ^[71]	图书数据集, 含有: 项目、类别属性、标签、显式和隐式评分、社交网络关系等数据.
Jester ^[72]	由Ken Goldberg和他在加州大学伯克利分校发展的笑话数据集, 包含: 用户、笑话、评分和时间戳.
Book-Crossings ^[30, 58]	由Cai-Nicolas Ziegler根据Bookcrossing.com社区数据整理的图书评分数据集, 含有: 用户画像、图书信息、评分、隐式评分和时间戳.
Last.fm ^[60, 82, 109]	音乐推荐数据集, 包含: 用户、音乐、评分、应用标签、最受欢迎艺术家列表及播放次数、时间、社交网络等信息.
Wikipedia ^[53]	维基百科数据集, 含有隐性评分, 广泛用于社交网络分析、用户行为研究等.
Netflix ^[144]	根据电影租赁网址Netflix建立的电影评分数据集, 包含: 用户、电影、评分等数据.
Amazon ^[41, 75, 81-82, 94]	由加利福尼亚大学圣迭戈分校Julian McAuley教授研究团队收集整理的亚马逊数据集, 包含: 用户、项目、评分、类别标签、时间戳、用户文本评论、图像等数据.
Epinions ^[53, 145]	著名大众消费者点评网站Epinions, 含有: 用户、项目、评分、隐式反馈、用户评论、社交网络、信任关系等信息.
Yelp ^[22-23, 41, 53, 57, 71]	根据美国最大的点评网站Yelp, 收集整理的城市餐厅数据集, 包含: 用户、项目、评分、类别标签、文本评论、时间戳等数据.
Ciao ^[53, 93, 145]	著名Ciao电子社区, 含有: 用户、项目、评分、隐式反馈、社交关系、信任关系记录等信息.
Adressa ^[79, 105]	挪威科技大学和Adressavisen合作出版的来自挪威新闻门户网站Adressa数据集, 包含: 用户、新闻、标题、描述、时间戳、点击新闻日志、上下文信息、地理位置、阅读活动时间、会话边界等信息.
AOL search log ^[80, 104]	根据文档列表中的BM25排名, 收集的文件查询日志数据集, 包括: 用户、用户问询、问询时间、点击文件题目与URL、URL原始排名、会话过程等信息.
CiteULike ^[39, 73]	科技类文章CiteULike数据集, 包含: 作者、文章标题、摘要、标签、发表时间、用户评分、文章间引用关系等信息.

个性化搜索和推荐算法的评价指标体系测评各算法质量, 主要衡量算法的预测精度、推荐结果的效用排序、准确率、用户体验、时间复杂度、系统响应速度等方面^[146-147]. 同时也需要考虑算法的覆盖率、冷启动、置信度、健壮性、泛化能力、推荐的新颖性和惊喜度、项目的多样性、隐私保护、适应性及可扩展性等. 这些内容拓宽了个性化搜索和推荐算法的评估方式范围、推荐结果呈现以及用户推荐解释等. 这里对于部分有代表性的个性化搜索和推荐算法的性能评价指标进行说明与分析, 主要介绍度量评分预测精度、度量使用预测精度和衡量排序性能的指标.

1) 度量评分预测的精度.

采用均方根误差(root mean square error, RMSE)、

平均绝对误差(mean absolute error, MAE)等评价指标, 衡量个性化搜索和推荐算法的评分预测准确性, 计算公式如下:

$$\text{RMSE} = \sqrt{\frac{\sum_{u, \mathbf{x} \in R_{\text{test}}} (r_{u\mathbf{x}} - \hat{r}_{u\mathbf{x}})^2}{|R_{\text{test}}|}}, \quad (3)$$

$$\text{MAE} = \frac{1}{|R_{\text{test}}|} \sum_{u, \mathbf{x} \in R_{\text{test}}} |r_{u\mathbf{x}} - \hat{r}_{u\mathbf{x}}|. \quad (4)$$

其中: R_{test} 表示测试数据集, $|R_{\text{test}}|$ 是测试集中的数据数量; $r_{u\mathbf{x}}$ 表示用户 u 对项目 \mathbf{x} 的真实评分; $\hat{r}_{u\mathbf{x}}$ 表示算法估计的用户 u 对于项目 \mathbf{x} 的预测评分.

RMSE和MAE通过计算预测评分与实际评分之

间的偏差,度量算法的评分预测精度,其值越小,表示算法的评分预测准确性越高。

2) 度量使用预测的精度。

采用准确率(accuracy)、精确率(precision)、召回率(recall)、受试者工作特征曲线(receiver operating characteristic, ROC)、曲线下面积(area under curve, AUC)、F-measure等指标,进行预测准确性评价。

对于测试用户推荐一组项目列表,通常有4种可能的结果,用混淆矩阵(confuse matrix)表示,其中,行和列分别表示样本的预测分类和真实分类,如表2所示。

表2 混淆矩阵

Table 2 Confuse matrix

	预测为阳性	预测为阴性
实际为阳性	真阳性的数量(TP)	假阴性的数量(FP)
实际为阴性	假阳性的数量(FN)	真阴性的数量(TN)

统计上述表中各单元格中的项目数量,计算公式如下:

$$\text{Accuracy} = \frac{\#TP + \#TN}{\#TP + \#TN + \#FP + \#FN}, \quad (5)$$

$$\text{Precision} = \frac{\#TP}{\#TP + \#FP}, \quad (6)$$

$$\text{Recall} = \frac{\#TP}{\#TP + \#FN}. \quad (7)$$

通常可在这些评价指标之间做出选择权衡,也可计算项目推荐列表的TopN精确率(如:记为Precision@N等)。

根据真阳率和假阳率的比率曲线,计算ROC曲线,表示用户喜欢的项目占被推荐项目的百分比,并进一步计算ROC曲线下的面积AUC,表示算法将正样本排在负样本之前的概率。

综合ROC曲线的评价指标F-measure,具有等价权重精确率和召回率的调和平均值,计算如下:

$$F = 2 \times \frac{\text{Precision} \times \text{Recall}}{\text{Precision} + \text{Recall}}. \quad (8)$$

3) 衡量排序性能的指标。

在个性化搜索和推荐算法中,用户的使用体验及其反馈表示是评价算法真实、客观的重要指标。而评分预测准确性并不能保证用户获得满意的使用体验,这是因为用户更注重算法能否准确地推荐用户感兴趣的项目。因此,进一步采用命中率(hit ratio, HR)、平均准确率(average precision, AP)、平均准确率均值(mean average precision, MAP)和归一化折损累积增益(normalized discounted cumulative gain, NDCG)等指标验证个性化搜索和推荐算法的排序性能,衡量算法在多大程度上能够准确预测用户对于待搜索项目

的偏好程度,反映了用户满意度和使用体验。

i) 命中率。

HR是指个性化搜索和推荐算法推荐给用户的TopN项目列表中,用户偏好的项目数量占测试数据集中用户喜欢的项目总数的比例。对于当前用户进行一次TopN推荐,HR计算公式如下:

$$\text{HR@N} = \frac{\text{Hit}}{|\text{GT}|}, \quad (9)$$

其中:Hit表示在TopN项目推荐列表中用户偏好的项目数量;|GT|是测试数据集中用户喜欢的项目总数量。

HR衡量了算法进行排序推荐的有效性,HR@N值越高,说明算法推荐的有效性越好。

ii) 平均准确率。

关于推荐结果用户更注重排在推荐列表前面的项目,因此,推荐列表排序靠前的项目是否是用户喜欢的项目,对于提升用户满意度及用户体验至关重要。AP综合衡量了个性化搜索和推荐算法的排序性能、推荐准确性及用户满意度,其对于TopN项目推荐列表中用户喜欢的项目排列顺序或位置十分敏感。

在某次个性化搜索和推荐过程中,假设用户在TopN项目推荐列表 $\{L_1, L_2, \dots, L_n\}$ 中选择了c个项目,则AP值计算如下:

$$\text{AP@N} = \frac{1}{c} \sum_{i=1}^c \frac{i}{\text{position}(i)}, \quad (10)$$

其中position(i)表示用户喜欢的c个项目中第i个项目在TopN中的排序位置。

若算法生成的TopN列表中,用户喜欢的项目排名越高,则AP@N值越大,表示算法的排序性能和推荐效果越好,且用户的体验感及满意度也越高。若算法返回的TopN列表中,没有用户喜欢的项目,则AP@N值为0,表示此次个性化推荐任务失败。

iii) 平均准确率均值。

MAP是测试数据集中所有用户的平均AP值,衡量个性化搜索和推荐算法的综合排序性能和推荐准确性。MAP计算公式如下:

$$\text{MAP@N} = \frac{1}{Q} \sum_{q=1}^Q \text{AP@N}(q), \quad (11)$$

其中:AP@N(q)是测试数据集中第q个用户的AP@N值;Q是所有测试用户数量。

MAP@N值越大,表示算法的排序准确率和推荐精度越高,反映了测试用户获得了良好的使用体验及满意度。

iv) 归一化折损累积增益。

累积增益(cumulative gain, CG)表示将每个推荐结果的相关性分值累加后作为整个推荐列表的得分,

计算如下:

$$CG_N = \sum_{i=1}^N rel_i, \quad (12)$$

其中: rel_i 表示位置 i 的预测结果相关性, N 表示推荐列表的大小.

折损累积增益(discounted cumulative gain, DCG)在CG的基础上引入了位置影响因素, 计算如下:

$$DCG_N = \sum_{i=1}^N \frac{2^{rel_i} - 1}{\log_2(i + 1)}. \quad (13)$$

推荐结果的相关性越大, 且将相关性较好的项目排在推荐列表的前面, 则推荐效果越好, DCG越大.

将不同用户推荐列表的评估分数进行归一化, NDCG计算如下:

$$NDCG@N = \frac{DCG@N}{IDCG}, \quad (14)$$

其中IDCG表示某一用户返回的最好推荐结果列表.

个性化搜索和推荐系统研究领域中, 在使用传统推荐性能指标进行搜索效果和推荐结果综合评测的同时, 需尝试根据具体研究内容进行深入分析和探讨, 提出并扩充具有针对性的专用评价指标, 制定相应的评估方案, 构建适应于实际应用场景的个性化搜索和推荐系统的评估体系, 全面衡量各种算法的综合性能及实际应用效果.

6 实际应用场景及未来研究方向

在实际生产、生活中, 个性化搜索和推荐算法获取用户偏好, 为用户进行项目或内容推荐, 作为缓解信息过载问题的有效方法, 已经融入人们日常生活的各类个性化服务中, 更好地满足用户实际需求, 有着十分广泛的应用背景及可期的应用前景. 下面整理了一些典型的个性化搜索和推荐系统的实际应用场景.

1) 传统网络推荐应用.

通常根据网络平台收集的海量内容信息、用户交互数据等, 利用各类个性化搜索和推荐技术, 抽取用户偏好并及时进行动态追踪, 实现个性化服务及应用, 如: 书籍推荐、音乐推荐、微博、新闻推荐、大型商业购物平台等, 具备广泛的应用场景. 面向互联网的个性化推荐系统包含大量丰富的多源异构用户生成内容, 如: 文本评论信息、各类上下文辅助信息、社交知识等, 同时信息获取方式多样、数据整合方式灵活. 充分挖掘并有效利用这些海量、低质、碎片化的多源异构数据, 抽取有用信息并整理知识体系, 提高个性化搜索和推荐系统的综合性能和实际效果, 实现用户与平台互惠互利, 这些将面临着十分严峻的挑战.

2) 移动互联网服务推荐应用.

在当今大数据时代, 随着互联网移动服务的高速发展及移动客户的不断增长, 交互式个性化搜索和推荐服务为移动互联网商业注入了新兴活力. 传统网络推

荐应用利用个性化搜索和推荐算法将推荐结果提供给用户, 而面向移动互联服务推荐应用, 需考虑移动情景信息的动态性、多样性等, 如: 环境状态、地理位置、场景信息、行动轨迹、推荐时间等, 并结合本地资源信息, 适时地调整推荐内容或项目, 以期动态适应实际场景变化. 随着网络5G技术的飞速发展, 在提高数据传输效率和减缓时延方面将有较大改进. 而如何将新的内容或项目推荐给合适的用户群是移动互联推荐应用面临的关键问题, 同时增强有用信息的充分利用也将更加复杂且富有挑战, 而这些都是将拥有更加广阔的应用前景.

自从基于协同过滤的推荐系统提出以来, 引起了众多学者和研究人员的广泛关注, 近20多年个性化搜索和推荐系统蓬勃发展, 在理论研究和实际应用方面都取得了许多优秀的研究成果, 持续推进该领域的研究发展. 然而, 目前实际复杂环境下的个性化搜索和推荐任务中, 用户偏好信息的来源灵活、用户需求多样、实际应用场景丰富多彩等, 这些都给个性化搜索和推荐算法研究带来严峻挑战, 同时也将面临崭新机遇. 下面分析该领域存在的主要问题及未来研究方向.

1) 多源异构数据的充分利用.

近年来机器学习、深度学习等技术蓬勃发展, 可利用深度卷积神经网络对图片、视频等数据进行特征抽取和内容识别, 利用深度置信网络对音频信号进行特征提取, 利用深度循环神经网络处理时间序列数据等方法, 发现这些复杂多源异构数据中包含的有用信息. 而由于这些数据信息量巨大, 深度模型训练时间长、资源耗费巨大, 处理难度大. 此外, 当联合其他用户生成数据时, 需兼容不同类型训练样本及评价准则, 均衡考量并详细设计多源异构数据的融合方法、模型构建与学习训练方式, 以及用户偏好特征抽取的实际效果, 综合考虑是否能够在适当的资源消耗和时间花费下获得个性化搜索算法的性能提升.

另一方面, 在深度学习技术中, 数据噪声将影响模型参数的学习过程和获取用户偏好特征的效果. 当训练数据遭受到不确定性噪声信号的干扰时, 对于算法的预测效果和推荐结果将产生较大影响, 即模型鲁棒性较差, 需深入研究复杂噪声环境下个性化搜索和推荐方法的实际应用. 同时, 考虑由于用户兴趣偏好模型的过度拟合, 在个性化推荐过程中形成了知识偏好多样性受限及推荐项目的局限性. 上述研究内容对于扩展面向多源异构数据的个性化搜索和推荐任务具有十分重要的价值.

2) 冷启动问题.

冷启动问题是个性化搜索和推荐任务中重要的挑战, 其根源在于数据稀疏或缺失, 难以向新用户进行个性化推荐或处理新出现的项目. 目前已存在许多应

对冷启动问题的方法,主要利用相关辅助信息改进个性化搜索和推荐技术.通过引导用户注册登录、收集用户社交网络、挖掘新项目的内容属性(包括:项目主题、关键字、标注类别等)、扩充多维度相关信息等,尽可能地丰富用户画像和项目内容信息.此外,考虑向用户随机推荐不同类型的具有代表性、区分度、多样性的项目或内容,保证较高的项目覆盖率,广泛收集用户反馈信息,再进行预测、判断及推荐.

迁移学习是多领域推荐技术研究中的热点,通过其他领域的知识迁移改进当前领域的学习任务,为处理冷启动问题提供了新思路.利用迁移学习技术,借助与当前应用相关的其他领域数据,弥补本研究领域数据不足的问题.例如:用户对书籍的喜好和品味与对电影的偏好具有相似之处,可利用图书数据集训练模型,改善电影数据集不充足的情况,反之亦然.这些也将在一定程度上提高个性化推荐算法的泛化能力.

3) 时效性问题.

在真实应用场景中,用户的实际需求和兴趣偏好可能会随着时间推移或环境变更而发生动态变化.例如:近期上映了一部热门电影,符合当前用户的偏好和品味,平台向用户进行了推荐,用户接受并观看了该部电影.而后平台继续向该用户推荐这部热门电影,显然系统忽视了用户的实际需求或者没有足够能力动态跟踪用户潜在需求,进行了不符合实际的项目推荐,导致用户对于平台的使用体验及好感率降低.因而,动态个性化搜索和推荐问题的建模难度较大,至今没有成熟的方法指导建立这些实际复杂问题的数学模型.

关于个性化搜索和推荐算法的动态性和时效性问题,需从多方面进行综合考量.根据项目内容信息中的时间因素,考虑随着时间推移和环境变化,用户兴趣偏好与项目之间的关系.同时,深入挖掘用户交互行为与时间的关系,动态抽取用户偏好特征,并根据用户反馈信息和算法效用评价体系,及时跟踪用户的长期和短期兴趣偏好.因此,个性化搜索和推荐算法需同时考虑实际动态场景及用户偏好的动态演化,为用户提供满足其当前潜在需求和兴趣偏好的推荐结果,这也是未来个性化搜索和推荐算法研究领域的重点和难点.另一方面,在个性化搜索和推荐系统中动态获取用户偏好,需要耗费大量时间和计算资源,可考虑利用数据库存储技术和分布式计算方法,提高算法的数据处理能力及效率,进一步增强系统的实时性和可扩展性.

4) 用户隐私保护.

近期用户隐私保护引起社会广泛关注,个性化搜索和推荐系统的快速发展引起争议.目前大多数个性化搜索和推荐方法需要收集并分析用户信息(如:用户

画像、社交网络、地理位置、行动轨迹等)及其历史交互数据,而这些信息都包含了用户个人隐私.2021年8月,国家互联网信息办公室发布了关于《互联网信息服务算法推荐管理规定(征求意见稿)》.这意味着用户与平台能够双向选择、平等沟通,保护用户隐私有助于构建更加公正公平、公开透明、科学合理的互联网平台.

保护用户隐私将是今后个性化搜索和推荐系统领域的重点研究内容.对于包含用户个人隐私的相关数据进行等级评定、信息脱敏等技术处理,在一定合理范围内正确使用这些信息.一方面,可以考虑用户群组推荐,将用户按照兴趣爱好或者特定需求进行分组,弱化用户个性化的表现特征,对同一群组用户展示相同的项目或内容,保护用户个人隐私的同时又能获得较好的推荐结果.另一方面,利用基于用户隐私保护的联邦学习技术,充分挖掘移动设备中的用户生成内容,在本地机中构建并训练用户兴趣偏好模型,将模型或模型参数上传至服务器端,从而保障用户个人隐私.然而,这类方法的模型融合问题及实际推荐效果有待进一步深入探讨和研究.

综上所述,复杂大数据环境下的个性化搜索和推荐任务面临如何充分利用多源异构数据、数据稀疏和冷启动、动态性与时效性、用户隐私保护等问题的严峻挑战.研究人员提出了多种多样的解决思路和实施方案,如:个性化群组推荐、序列推荐、多任务个性化推荐等内容,开展了广泛研究.此外,有关迁移学习、强化学习等先进技术应用用于个性化搜索和推荐系统还需进一步深入探讨.这些研究内容都为个性化搜索和推荐算法研究领域注入了新鲜活力,将再次激励本领域的飞速发展,促进经济腾飞.

7 总结

本文针对复杂应用场景下面向多源异构数据的个性化搜索和推荐算法进行了综述,分析了利用多源异构数据、构建用户兴趣偏好模型、个性化搜索和推荐技术等内容,整理了常用数据集、系统评估指标及评估体系等,总结了个性化搜索和推荐系统的实际应用场景及未来研究方向.在阐述现有个性化搜索和推荐算法存在的问题与挑战的基础上,介绍关于面向多源异构数据的个性化搜索和推荐算法的研究现状及进展,并讨论了今后研究的发展方向,以期对相关领域的研究人员和工程技术人员提供有益帮助,更好地服务于国民经济与社会发展.

参考文献:

- [1] CHAI Tianyou. Development directions of industrial artificial intelligence. *Acta Automatica Sinica*, 2020, 46(10): 2005 – 2012. (柴天佑. 工业人工智能发展方向. 自动化学报, 2020, 46(10): 2005 – 2012.)

- [2] WU Xindong, SHENG Shaojing, JIANG Tingting, et al. Huapu-CP: From knowledge graphs to a data central-platform. *Acta Automatica Sinica*, 2020, 46(10): 2045 – 2059.
(吴信东, 盛绍静, 蒋婷婷, 等. 从知识图谱到数据中台: 华谱系统. 自动化学报, 2020, 46(10): 2045 – 2059.)
- [3] WANG Feiyue. Intelligent control in 50 years: From K. S. Fu's vision to G. N. Saridis' inspiration. *Acta Automatica Sinica*, 2021, 47(10): 2301 – 2320.
(王飞跃. 智能控制五十年回顾与展望: 傅京孙的初心与萨里迪斯的雄心. 自动化学报, 2021, 47(10): 2301 – 2320.)
- [4] WU Xindong, LI Jiao, ZHOU Peng, et al. Fusion technique for fragmented genealogy data. *Journal of Software*, 2021, 32(9): 2816 – 2836.
(吴信东, 李娇, 周鹏, 等. 碎片化家谱数据的融合技术. 软件学报, 2021, 32(9): 2816 – 2836.)
- [5] YU Hao, ZHANG Jie, WU Minghui, et al. A framework for rapid construction and application of domain knowledge graphs. *CAAI Transactions on Intelligent Systems*, 2021, 16(5): 871 – 884.
(于皓, 张杰, 吴明辉, 等. 领域知识图谱快速构建和应用框架. 智能系统学报, 2021, 16(5): 871 – 884.)
- [6] ADOMAVICIUS G, TUZHILIN A. Toward the next generation of recommender systems: A survey of the state-of-the-art and possible extensions. *IEEE Transactions on Knowledge and Data Engineering*, 2005, 17(6): 734 – 749.
- [7] LI Jinzhong, LIU Guanjuan, YAN Chungang, et al. Research advances and prospects of learning to rank. *Acta Automatica Sinica*, 2018, 44(8): 1345 – 1369.
(李金忠, 刘关俊, 闫春钢, 等. 排序学习研究进展与展望. 自动化学报, 2018, 44(8): 1345 – 1369.)
- [8] HUANG Jizhou, SUN Yanming, WANG Haifeng, et al. A survey of entity recommendation in Web search. *Chinese Journal of Computers*, 2019, 42(7): 1467 – 1494.
(黄际洲, 孙雅铭, 王海峰, 等. 面向搜索引擎的实体推荐综述. 计算机学报, 2019, 42(7): 1467 – 1494.)
- [9] ZHANG S, YAO L, SUN A, et al. Deep learning based recommender system: A survey and new perspectives. *ACM Computing Surveys (CSUR)*, 2019, 52(1): 1 – 38.
- [10] WU L, HE X, WANG X, et al. A survey on accuracy-oriented neural recommendation: From collaborative filtering to information-rich recommendation. *ArXiv Preprint*, 2021: arXiv:2104.13030.
- [11] CUNHA T, SOARES C, DE CARVALHO A C. Metalearning and recommender systems: A literature review and empirical study on the algorithm selection problem for collaborative filtering. *Information Sciences*, 2018, 423: 128 – 144.
- [12] BATMAZ Z, YUREKLI A, BILGE A, et al. A review on deep learning for recommender systems: Challenges and remedies. *Artificial Intelligence Review*, 2019, 52(1): 1 – 37.
- [13] ZHANG Yujie, DONG Zheng, MENG Xiangwu. Research on personalized advertising recommendation systems and their applications. *Chinese Journal of Computers*, 2021, 44(3): 531 – 563.
(张玉洁, 董政, 孟祥武. 个性化广告推荐系统及其应用研究. 计算机学报, 2021, 44(3): 531 – 563.)
- [14] WANG S, CAO L, WANG Y, et al. A survey on session-based recommender systems. *ACM Computing Surveys (CSUR)*, 2021, 54(7): 1 – 38.
- [15] GAO C, LEI W, HE X, et al. Advances and challenges in conversational recommender systems: A survey. *AI Open*, 2021, 2: 100 – 126.
- [16] HE X, LIAO L, ZHANG H, et al. Neural collaborative filtering. *Proceedings of the 26th International Conference on World Wide Web (WWW)*. Perth, Australia: ACM, 2017: 173 – 182.
- [17] KIM D, PARK C, OH J, et al. Deep hybrid recommender systems via exploiting document context and statistics of items. *Information Sciences*, 2017, 417: 72 – 87.
- [18] RENDLE S. Factorization machines with libFM. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2012, 3(3): 1 – 22.
- [19] PANG G, WANG X, HAO F, et al. ACNN-FM: A novel recommender with attention-based convolutional neural network and factorization machines. *Knowledge-Based Systems*, 2019, 181: 104786.
- [20] QIU H, LIU Y, GUO G, et al. BPRH: Bayesian personalized ranking for heterogeneous implicit feedback. *Information Sciences*, 2018, 453: 80 – 98.
- [21] LIU Q, REINER A H, FRIGESSI A, et al. Diverse personalized recommendations with uncertainty from implicit preference data with the bayesian mallows model. *Knowledge-Based Systems*, 2019, 186: 104960.
- [22] ASKARI B, SZLICHTA J, SALEHI-ABARI A. Joint variational autoencoders for recommendation with implicit feedback. *ArXiv Preprint*, 2020: arXiv: 2008.07577.
- [23] XIE Z, LIU C, ZHANG Y, et al. Adversarial and contrastive variational autoencoder for sequential recommendation. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 449 – 459.
- [24] CHEN L, LIU H, MOORE P. A semantic recommender algorithm for 3D model retrieval based on deep belief networks. *International Journal of Computational Science and Engineering*, 2019, 19(1): 93 – 103.
- [25] LI R, ZHU H, FAN L, et al. Hybrid deep framework for group event recommendation. *IEEE Access*, 2019, 8: 4775 – 4784.
- [26] MENG X, WANG S, LIU H, et al. Exploiting emotion on reviews for recommender systems. *Proceedings of the AAAI Conference on Artificial Intelligence*. New Orleans, LA: AAAI, 2018, 3788 – 3795.
- [27] WEI Y, WANG X, NIE L, et al. MMGCN: Multi-modal graph convolution network for personalized recommendation of micro-video. *Proceedings of the 27th ACM International Conference on Multimedia*. Nice, France: ACM, 2019: 1437 – 1445.
- [28] WU C Y, AHMED A, BEUTEL A, et al. Recurrent recommender networks. *Proceedings of the tenth ACM International Conference on Web Search and Data Mining*. Cambridge, United Kingdom: ACM, 2017: 495 – 503.
- [29] XU C, ZHAO P, LIU Y, et al. Recurrent convolutional neural network for sequential recommendation. *The World Wide Web Conference*. San Francisco, CA, USA: ACM, 2019: 3398 – 3404.
- [30] HSU C, LI C T. RetaGNN: Relational temporal attentive graph neural networks for holistic sequential recommendation. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 2968 – 2979.
- [31] PANG Y, WU L, SHEN Q, et al. Heterogeneous global graph neural networks for personalized session-based recommendation. *Proceedings of the 15th ACM International Conference on Web Search and Data Mining*. Tempe, AZ, USA: ACM, 2022: 775 – 783.
- [32] RENDLE S, FREUDENTHALER C, GANTNER Z, et al. BPR: Bayesian personalized ranking from implicit feedback. *ArXiv Preprint*, 2012: arXiv: 1205.2618.
- [33] SONG Y, WANG H, HE X. Adapting deep ranknet for personalized search. *Proceedings of the 7th ACM International Conference on Web Search and Data Mining*. New York, USA: ACM, 2014: 83 – 92.
- [34] MIAO Z, WANG J, ZHOU A, et al. Regularized boost for semi-supervised ranking. *Proceedings of the 18th Asia Pacific Symposium on Intelligent and Evolutionary Systems*. Cham: Springer, 2015: 643 – 651.

- [35] ZHUANG F, LUO D, YUAN N J, et al. Representation learning with pair-wise constraints for collaborative ranking. *Proceedings of the tenth ACM International Conference on Web Search and Data Mining*. Cambridge, United Kingdom: ACM, 2017: 567 – 575.
- [36] FU M, QU H, YI Z, et al. A novel deep learning-based collaborative filtering model for recommendation system. *IEEE Transactions on Cybernetics*, 2018, 49(3): 1084 – 1096.
- [37] XUE F, HE X, WANG X, et al. Deep item-based collaborative filtering for top-n recommendation. *ACM Transactions on Information Systems (TOIS)*, 2019, 37(3): 1 – 25.
- [38] YU Yaxin, LIU Meng, ZHANG Hongyu. Research on user behavior understanding and personalized service recommendation algorithm in Twitter social networks. *Journal of Computer Research and Development*, 2020, 57(7): 1369 – 1380.
(于亚新, 刘梦, 张宏宇. Twitter社交网络用户行为理解及个性化服务推荐算法研究. *计算机研究与发展*, 2020, 57(7): 1369 – 1380.)
- [39] LIAN D, WANG H, LIU Z, et al. Lightrec: A memory and search-efficient recommender system. *Proceedings of the Web Conference 2020*. Taipei, Taiwan: ACM, 2020: 695 – 705.
- [40] TIAN Zhen, PAN Lamei, YIN Pu, et al. Deep matrix factorization recommendation algorithm. *Journal of Software*, 2021, 32(12): 3917 – 3928.
(田震, 潘腊梅, 尹朴, 等. 深度矩阵分解推荐算法. *软件学报*, 2021, 32(12): 3917 – 3928.)
- [41] SUN J, CHENG Z, ZUBERI S, et al. HGCF: Hyperbolic graph convolution networks for collaborative filtering. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 593 – 601.
- [42] SUN Y, PAN J, ZHANG A, et al. FM2: Field-matrixed factorization machines for recommender systems. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 2828 – 2837.
- [43] KASSAK O, KOMPAN M, BIELIKOVA M. User preference modeling by global and individual weights for personalized recommendation. *Acta Polytechnica Hungarica*, 2015, 12(8): 27 – 41.
- [44] ZHOU G, ZHU X, SONG C, et al. Deep interest network for click-through rate prediction. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. London, United Kingdom: ACM, 2018: 1059 – 1068.
- [45] LEE J, HWANG W S, PARC J, et al. *l*-Injection: Toward effective collaborative filtering using uninteresting items. *IEEE Transactions on Knowledge and Data Engineering*, 2019, 31(1): 3 – 16.
- [46] XUE Feng, LIU Kai, WANG Dong, et al. Personalized recommendation algorithm based on deep neural network and weighted implicit feedback. *Pattern Recognition and Artificial Intelligence*, 2020, 33(4): 295 – 302.
(薛峰, 刘凯, 王东, 等. 基于深度神经网络和加权隐反馈的个性化推荐. *模式识别与人工智能*, 2020, 33(4): 295 – 302.)
- [47] SI Yali, ZHANG Fuzhi, LIU Wenyuan. An adaptive point-of-interest recommendation method based on check-in activity and temporal-spatial probabilistic models. *Journal of Electronics & Information Technology*, 2020, 42(3): 678 – 686.
(司亚利, 张付志, 刘文远. 基于签到活跃度和时空概率模型的自适应兴趣点推荐方法. *电子与信息学报*, 2020, 42(3): 678 – 686.)
- [48] KIM D, PARK C, OH J, et al. Convolutional matrix factorization for document context-aware recommendation. *Proceedings of the 10th ACM Conference on Recommender Systems*. Boston, MA, USA: ACM, 2016: 233 – 240.
- [49] YANG C, BAI L, ZHANG C, et al. Bridging collaborative filtering and semi-supervised learning: A neural approach for POI recommendation. *Proceedings of the 23rd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Halifax, NS, Canada: ACM, 2017: 1245 – 1254.
- [50] DU Z, WANG X, YANG H, et al. Sequential scenario-specific meta learner for online recommendation. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Anchorage, AK, USA: ACM, 2019: 2895 – 2904.
- [51] LAI Yian, ZHANG Yujie, DU Yulu, et al. Local event recommendation algorithm based on collective contextual relation learning. *Journal of Software*, 2020, 31(2): 421 – 438.
(赖奕安, 张玉洁, 杜雨露, 等. 一种基于协同上下文关系学习的同城活动推荐算法. *软件学报*, 2020, 31(2): 421 – 438.)
- [52] YANG M, LI Q, QIN Z, et al. Hierarchical adaptive contextual bandits for resource constraint based recommendation. *Proceedings of the Web Conference 2020*. Taipei, Taiwan: ACM, 2020: 292 – 302.
- [53] FU B, ZHANG W, HU G, et al. Dual side deep context-aware modulation for social recommendation. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 2524 – 2534.
- [54] NGUYEN T T, LAUW H W. Representation learning for homophilic preferences. *Proceedings of the 10th ACM Conference on Recommender Systems*. Boston, MA, USA: ACM, 2016: 317 – 324.
- [55] DENG S, HUANG L, XU G, et al. On deep learning for trust-aware recommendations in social networks. *IEEE Transactions on Neural Networks and Learning Systems*, 2017, 28(5): 1164 – 1177.
- [56] GUO L, LIANG J, ZHU Y, et al. Collaborative filtering recommendation based on trust and emotion. *Journal of Intelligent Information Systems*, 2019, 53(1): 113 – 135.
- [57] CHEN Jinyin, WU Yangyang, LIN Xiang. Double layered recommendation algorithm based on fast density clustering with graph-based filtering & applications. *Control Theory & Applications*, 2019, 36(4): 542 – 552.
(陈晋音, 吴洋洋, 林翔. 基于图过滤的快速密度聚类双层网络推荐算法. *控制理论与应用*, 2019, 36(4): 542 – 552.)
- [58] WANG Dagang, ZHONG Jin, WU Hao. Study on social recommendation algorithm based on Bayes and self-encoder. *Journal of Systems Science and Mathematical Sciences*, 2020, 40(4): 686 – 700.
(王大刚, 钟锦, 吴昊. 基于贝叶斯和自编码器的社会化推荐算法研究. *系统科学与数学*, 2020, 40(4): 686 – 700.)
- [59] YANG Jie, ZHU Xianjun, ZHOU Xianzhong, et al. Personalized web service recommendation based on heterogeneous social network. *Acta Electronica Sinica*, 2020, 48(2): 341 – 349.
(杨洁, 朱咸军, 周献中, 等. 基于混杂社会网络的个性化Web服务推荐方法. *电子学报*, 2020, 48(2): 341 – 349.)
- [60] YU J, YIN H, LI J, et al. Self-supervised multi-channel hypergraph convolutional network for social recommendation. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 413 – 424.
- [61] WANG H, WANG N, YEUNG D Y. Collaborative deep learning for recommender systems. *Proceedings of the 21th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*. Sydney, NSW, Australia: ACM, 2015: 1235 – 1244.
- [62] CHENG H T, KOC L, HARMSEN J, et al. Wide & deep learning for recommender systems. *ArXiv Preprint*, 2016: arXiv:1606.07792.
- [63] ZHENG L, NOROOZI V, YU P S. Joint deep modeling of users and items using reviews for recommendation. *Proceedings of the tenth ACM International Conference on Web Search and Data Mining*. Cambridge, United Kingdom: ACM, 2017: 425 – 434.
- [64] MENG X, WANG S, LIU H, et al. Exploiting emotion on reviews for recommender systems. *Proceedings of the AAAI Conference on Artificial Intelligence*. New Orleans, LA: AAAI, 2018: 3788 – 3795.
- [65] LI Lin, TANG Shoulian. Metric ranking learning recommendation model based on content representation. *Acta Electronica Sinica*, 2020, 48(8): 1615 – 1622.
(李琳, 唐守廉. 融合内容表示的度量排序学习推荐模型. *电子学报*, 2020, 48(8): 1615 – 1622.)
- [66] JI Zhenyan, WU Mengdan, YANG Chun, et al. Scalable recommendation models fusing multi-source heterogeneous data. *Journal of*

- Beijing University of Posts and Telecommunications*, 2021, 44(3): 106 – 111.
(冀振燕, 吴梦丹, 杨春, 等. 可扩展的融合多源异构数据的推荐模型. 北京邮电大学学报, 2021, 44(3): 106 – 111.)
- [67] COVINGTON P, ADAMS J, SARGIN E. Deep neural networks for youtube recommendations. *Proceedings of the 10th ACM Conference on Recommender Systems*. Boston, MA, USA: ACM, 2016: 191 – 198.
- [68] WANG S, WANG Y, TANG J, et al. What your images reveal: Exploiting visual contents for Point-of-Interest recommendation. *Proceedings of the 26th International Conference on World Wide Web*. Perth, Australia: ACM, 2017: 391 – 400.
- [69] WU Bin, LOU Zhengzheng, YE Yangdong. A collaborative filtering recommendation algorithm for multi-source heterogeneous data. *Journal of Computer Research and Development*, 2019, 56(5): 1034 – 1047.
(吴宾, 娄铮铮, 叶阳东. 一种面向多源异构数据的协同过滤推荐算法. 计算机研究与发展, 2019, 56(5): 1034 – 1047.)
- [70] WAN M, NI J, MISRA R, et al. Addressing marketing bias in product recommendations. *Proceedings of the 13th International Conference on Web Search and Data Mining*. Houston, TX, USA: ACM, 2020: 618 – 626.
- [71] WANG Z, LIU H, DU Y, et al. Unified embedding model over heterogeneous information network for personalized recommendation. *Proceedings of the 28th International Joint Conference on Artificial Intelligence*. Macao, China: International Joint Conference on Artificial Intelligence, 2019: 3813 – 3819.
- [72] KE G, XU Z, ZHANG J, et al. DeepGBM: A deep learning framework distilled by GBDT for online prediction tasks. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Anchorage, AK, USA: ACM, 2019: 384 – 394.
- [73] BAO Hengze, ZHONG Dong, WU Tan. Label recommendation method with multi-source heterogeneous network information. *Journal of Shandong University (Natural Science)*, 2019, 54(3): 56 – 66.
(包恒泽, 周栋, 吴谈. 融合多源异构网络信息的标签推荐方法. 山东大学学报(理学版), 2019, 54(3): 56 – 66.)
- [74] LIU H, JIANG Z, SONG Y, et al. User preference modeling based on meta paths and diversity regularization in heterogeneous information networks. *Knowledge-Based Systems*, 2019, 181: 104784.
- [75] CEN Y, ZHANG J, ZOU X, et al. Controllable multi-interest framework for recommendation. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Virtual Event, CA, USA: ACM, 2020: 2942 – 2951.
- [76] MAO M, LU J, HAN J, et al. Multiobjective e-commerce recommendations based on hypergraph ranking. *Information Sciences*, 2019, 471: 269 – 287.
- [77] CHEN Jiaying, YU Jiong, YANG Xingyao. A feature extraction based recommender algorithm fusing semantic analysis. *Journal of Computer Research and Development*, 2020, 57(3): 562 – 575.
(陈嘉颖, 于炯, 杨兴耀. 一种融合语义分析特征提取的推荐算法. 计算机研究与发展, 2020, 57(3): 562 – 575.)
- [78] ZHAO J, WANG X, SHI C, et al. Network schema preserving heterogeneous information network embedding. *International Joint Conference on Artificial Intelligence (IJCAI)*. Electr Network: Int Joint Conf Artificial Intelligence, 2020: 1366 – 1372.
- [79] HU L, XU S, LI C, et al. Graph neural news recommendation with unsupervised preference disentanglement. *Proceedings of the 58th Annual Meeting of the Association for Computational Linguistics*. Electr Network: Assoc Computat Linguist, 2020: 4255 – 4264.
- [80] LU S, DOU Z, XIONG C, et al. Knowledge enhanced personalized search. *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. Virtual Event, China: ACM, 2020: 709 – 718.
- [81] LI M, ZHANG S, ZHU F, et al. Symmetric metric learning with adaptive margin for recommendation. *The 34th AAAI Conference on Artificial Intelligence*. New York, USA: AAAI, 2020, 34(4): 4634 – 4641.
- [82] JIN J, QIN J, FANG Y, et al. An efficient neighborhood-based interaction model for recommendation on heterogeneous graph. *Proceedings of the 26th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Virtual Event, CA, USA: ACM, 2020: 75 – 84.
- [83] LIU F, CHENG Z, ZHU L, et al. Interest-aware message-passing GCN for recommendation. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 1296 – 1305.
- [84] ZHENG Y, GAO C, CHEN L, et al. DGCN: Diversified recommendation with graph convolutional networks. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 401 – 412.
- [85] MNIH V, HEES N, GRAVES A, et al. Recurrent models of visual attention. *The 28th Conference on Neural Information Processing Systems (NIPS)*. Montreal, Canada: NIPS, 2014, 27: 1 – 9.
- [86] XU K, BA J, KIROS R, et al. Show, attend and tell: Neural image caption generation with visual attention. *Proceedings of the International Conference on Machine Learning*. Lille, France: PMLR, 2015: 2048 – 2057.
- [87] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need. *The 31st Annual Conference on Neural Information Processing Systems (NIPS)*. Long Beach, CA, 2017, 30: 1 – 10.
- [88] CHAUDHARI S, MITHAL V, POLATKAN G, et al. An attentive survey of attention models. *ACM Transactions on Intelligent Systems and Technology (TIST)*, 2021, 12(5): 1 – 32.
- [89] SEO S, HUANG J, YANG H, et al. Interpretable convolutional neural networks with dual local and global attention for review rating prediction. *Proceedings of the 11th ACM Conference on Recommender Systems*. Como, Italy: ACM, 2017: 297 – 305.
- [90] HU B, SHI C, ZHAO W X, et al. Leveraging meta-path based context for top-n recommendation with a neural co-attention model. *Proceedings of the 24th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. London, United Kingdom: ACM, 2018: 1531 – 1540.
- [91] XU F, LIAN J, HAN Z, et al. Relation-aware graph convolutional networks for agent-initiated social e-commerce recommendation. *Proceedings of the 28th ACM International Conference on Information and Knowledge Management*. Beijing, China: ACM, 2019: 529 – 538.
- [92] WU C, WU F, AN M, et al. NPA: Neural news recommendation with personalized attention. *Proceedings of the 25th ACM SIGKDD International Conference on Knowledge Discovery & Data Mining*. Anchorage, AK, USA: ACM, 2019: 2576 – 2584.
- [93] ZHANG Qingbo, WANG Bin, CUI Ningning, et al. Attention-based regularized matrix factorization for recommendation. *Journal of Software*, 2020, 31(3): 778 – 793.
(张青博, 王斌, 崔宁宁, 等. 基于注意力机制的规范化矩阵分解推荐算法. 软件学报, 2020, 31(3): 778 – 793.)
- [94] FENG Xingjie, ZENG Yunze. Joint deep modeling of rating matrix and reviews for recommendation. *Chinese Journal of Computers*, 2020, 43(5): 884 – 900.
(冯兴杰, 曾云泽. 基于评分矩阵与评论文本的深度推荐模型. 计算机学报, 2020, 43(5): 884 – 900.)
- [95] TANJIM M M, SU C, BENJAMIN E, et al. Attentive sequential models of latent intent for next item recommendation. *Proceedings*

- of the Web Conference 2020. Taipei, Taiwan: ACM, 2020: 2528 – 2534.
- [96] SHEN T, JIA J, LI Y, et al. Peia: Personality and emotion integrated attentive model for music recommendation on social media platforms. *Proceedings of the AAAI Conference on Artificial Intelligence*. New York, USA: AAAI, 2020, 34(1): 206 – 213.
- [97] SUN R, CAO X, ZHAO Y, et al. Multi-modal knowledge graphs for recommender systems. *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*. Virtual Event, Ireland: ACM, 2020: 1405 – 1414.
- [98] CHEN Ming, ZHANG Lei, MA Tianyi. Recommendation approach based on attentive federated distillation. *Journal of Software*, 2021, 32(12): 3852 – 3868.
(谌明, 张蕾, 马天翼. 一种基于注意力联邦蒸馏的推荐方法. 软件学报, 2021, 32(12): 3852 – 3868.)
- [99] GUO W, YANG Y, HU Y, et al. Deep graph convolutional networks with hybrid normalization for accurate and diverse recommendation. *Proceedings of the 3rd Workshop on Deep Learning Practice for High-Dimensional Sparse Data with KDD*. Singapore: ACM, 2021: 1 – 9.
- [100] WU Q, ZHANG H, GAO X, et al. Towards open-world recommendation: An inductive model-based collaborative filtering approach. *International Conference on Machine Learning*. Electr Network: PMLR, 2021: 11329 – 11339.
- [101] LIU Q, WU S, WANG L. Multi-behavioral sequential prediction with recurrent log-bilinear model. *IEEE Transactions on Knowledge and Data Engineering*, 2017, 29(6): 1254 – 1267.
- [102] CUI Q, WU S, HUANG Y, et al. A hierarchical contextual attention-based network for sequential recommendation. *Neurocomputing*, 2019, 358: 141 – 149.
- [103] ZHANG Yihao, ZHU Xiaofei, XU Chuanyun, et al. Hybrid recommendation approach based on deep sentiment analysis of user reviews and multi-view collaborative fusion. *Chinese Journal of Computers*, 2019, 42(6): 1316 – 1333.
(张宜浩, 朱小飞, 徐传运, 等. 基于用户评论的深度情感分析和多视图协同融合的混合推荐方法. 计算机学报, 2019, 42(6): 1316 – 1333.)
- [104] MA Z, DOU Z, BIAN G, et al. PSTIE: Time information enhanced personalized search. *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*. Virtual Event, Ireland: ACM, 2020: 1075 – 1084.
- [105] HU L, LI C, SHI C, et al. Graph neural news recommendation with long-term and short-term interest modeling. *Information Processing & Management*, 2020, 57(2): 102142.
- [106] LI C, NIU X, LUO X, et al. A review-driven neural model for sequential recommendation. *ArXiv Preprint*, 2019: arXiv: 1907.00590.
- [107] LI J, WANG Y, MCAULEY J. Time interval aware self-attention for sequential recommendation. *Proceedings of the 13th International Conference on Web Search and Data Mining*. Houston, TX, USA: ACM, 2020: 322 – 330.
- [108] WU J, CAI R, WANG H. Déjàvu: A contextualized temporal attention mechanism for sequential recommendation. *Proceedings of the Web Conference 2020*. Taipei, Taiwan: ACM, 2020: 2199 – 2209.
- [109] ZHOU K, WANG H, ZHAO W X, et al. S3-rec: Self-supervised learning for sequential recommendation with mutual information maximization. *Proceedings of the 29th ACM International Conference on Information & Knowledge Management*. Virtual Event, Ireland: ACM, 2020: 1893 – 1902.
- [110] LI C, HU L, SHI C, et al. Sequence-aware heterogeneous graph neural collaborative filtering. *Proceedings of the 2021 SIAM International Conference on Data Mining (SDM)*, Virtual Event: Society for Industrial and Applied Mathematics, 2021: 64 – 72.
- [111] WEI Y, WANG X, NIE L, et al. MMGCN: Multi-modal graph convolution network for personalized recommendation of micro-video. *Proceedings of the 27th ACM International Conference on Multimedia*. Nice, France: ACM, 2019: 1437 – 1445.
- [112] JI Y, YIN M Y, FANG Y, et al. Temporal heterogeneous interaction graph embedding for next-item recommendation. *Joint European Conference on Machine Learning and Knowledge Discovery in Databases*. Ghent, Belgium: Springer, Cham, 2020: 314 – 329.
- [113] TANG Wenbing, REN Zhengyun, HAN Fang. Attention-based collaborative convolutional dynamic network for recommendation. *Acta Automatica Sinica*, 2021, 47(10): 2438 – 2448.
(汤文兵, 任正云, 韩芳. 基于注意力机制的协同卷积动态推荐网络. 自动化学报, 2021, 47(10): 2438 – 2448.)
- [114] QI T, WU F, WU C, et al. Personalized news recommendation with knowledge-aware interactive matching. *Proceedings of the 44th International ACM SIGIR Conference on Research and Development in Information Retrieval*. Electr Network: ACM, 2021: 61 – 70.
- [115] WANG R, SHIVANNA R, CHENG D, et al. Dcn v2: Improved deep & cross network and practical lessons for web-scale learning to rank systems. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 1785 – 1797.
- [116] ZHANG Q, LU J, WU D, et al. A cross-domain recommender system with kernel-induced knowledge transfer for overlapping entities. *IEEE Transactions on Neural Networks and Learning Systems*, 2018, 30(7): 1998 – 2012.
- [117] CHEN X, LI S, LI H, et al. Generative adversarial user model for reinforcement learning based recommendation system. *International Conference on Machine Learning*. Long Beach, California: PMLR, 2019: 1052 – 1061.
- [118] YAN Cairong, HUANG Yan, XU Guangwei, et al. Field-aware factorization machine model based on time dynamics. *Control and Decision*, 2020, 35(1): 169 – 173.
(燕彩蓉, 黄颜, 徐光伟, 等. 基于时间动态性的场感知分解机模型. 控制与决策, 2020, 35(1): 169 – 173.)
- [119] LIU Zhen, TIAN Jingyu, YUAN Baoxin, et al. Cross-domain recommendation algorithm based on knowledge aggregation and transfer. *Acta Electronica Sinica*, 2020, 48(10): 1928 – 1932.
(刘真, 田靖玉, 苑宝鑫, 等. 基于知识聚合和迁移的跨领域推荐算法. 电子学报, 2020, 48(10): 1928 – 1932.)
- [120] MORIK M, SINGH A, HONG J, et al. Controlling fairness and bias in dynamic learning-to-rank. *Proceedings of the 43rd International ACM SIGIR Conference on Research and Development in Information Retrieval*. Electr Network: ACM, 2020: 429 – 438.
- [121] HARSHVARDHAN G M, GOURISARIA M K, RAUTARAY S S, et al. UBMTR: Unsupervised boltzmann machine-based time-aware recommendation system. *Journal of King Saud University-Computer and Information Sciences*, 2021, 34(8): 6400 – 6413.
- [122] DAO T H, JEONG S R, AHN H. A novel recommendation model of location-based advertising: Context-aware collaborative filtering using GA approach. *Expert Systems with Applications*, 2012, 39(3): 3731 – 3739.
- [123] DAI H, WANG Y, TRIVEDI R, et al. Deep coevolutionary network: Embedding user and item features for recommendation. *ArXiv Preprint*, 2016: arXiv: 1609.03675.
- [124] PHANGTRIASTU M R, ISA S M. Optimizing field-aware factorization machine with particle swarm optimization on online Ads click-through rate prediction. *Proceedings of the 2018 3rd International Conference on Computer and Communication Systems (ICCCS)*. Kathmandu, Nepal: IEEE, 2018: 1 – 5.
- [125] ZHOU G, MOU N, FAN Y, et al. Deep interest evolution network for click-through rate prediction. *Proceedings of the AAAI Conference on Artificial Intelligence*. Honolulu, Hawaii, USA: AAAI, 2019, 33(1): 5941 – 5948.

- [126] CHEN Y, PAN T, HE C, et al. Efficient evolutionary deep neural architecture search (NAS) by noisy network morphism mutation. *International Conference on Bio-Inspired Computing: Theories and Applications*. Zhengzhou, China: Springer, Singapore, 2019: 497 – 508.
- [127] ZHANG H, JIN Y, CHENG R, et al. Efficient evolutionary search of attention convolutional networks via sampled training and node inheritance. *IEEE Transactions on Evolutionary Computation*, 2020, 25(2): 371 – 385.
- [128] WANG Yong, RAN Xun, YIN Enming, et al. Matrix factorization recommendation algorithm for differential privacy protection. *Journal of University of Electronic Science and Technology of China*, 2021, 50(3): 405 – 413.
(王永, 冉珣, 尹恩民, 等. 满足差分隐私保护的矩阵分解推荐算法. 电子科技大学学报, 2021, 50(3): 405 – 413.)
- [129] ZHAO X, ZHU Z, CAVERLEE J. Rabbit holes and taste distortion: Distribution-aware recommendation with evolving interests. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 888 – 899.
- [130] SUN X, GONG D, ZHANG W. Interactive genetic algorithms with large population and semi-supervised learning. *Applied Soft Computing*, 2012, 12(9): 3004 – 3013.
- [131] SUN X, GONG D, JIN Y, et al. A new surrogate-assisted interactive genetic algorithm with weighted semisupervised learning. *IEEE Transactions on Cybernetics*, 2013, 43(2): 685 – 698.
- [132] GONG D, JI X, SUN J, et al. Interactive evolutionary algorithms with decision-maker's preferences for solving interval multi-objective optimization problems. *Neurocomputing*, 2014, 137: 241 – 251.
- [133] FUNAKI R, SUGIMOTO K, MURATA J. Estimation of influence of each variable on user's evaluation in interactive evolutionary computation. *The 9th International Conference on Awareness Science and Technology (iCAST)*. Fukuoka, Japan: IEEE, 2018: 167 – 174.
- [134] KANT V, BHARADWAJ K K. A user-oriented content based recommender system based on reclusive methods and interactive genetic algorithm. *Proceedings of the 7th International Conference on Bio-Inspired Computing: Theories and Applications (BIC-TA 2012)*. Gwalior, India: Springer, 2013: 543 – 554.
- [135] SUN Xiaoyan, LU Yina, GONG Dunwei, et al. Interactive genetic algorithm with CP-nets preference surrogate and application in personalized search. *Control and Decision*, 2015, 30(7): 1153 – 1161.
(孙晓燕, 陆宜娜, 巩敦卫, 等. 基于CP-nets的偏好感知交互式遗传算法及其个性化搜索. 控制与决策, 2015, 30(7): 1153 – 1161.)
- [136] SUN X, CHEN Y, BAO L, et al. Interactive genetic algorithm with implicit uncertainty evaluation for application in personalized search. *Symposium Series on Computational Intelligence (SSCI)*. Honolulu, Hawaii, USA: IEEE, 2017: 1 – 8.
- [137] CHEN Y, SUN X, GONG D, et al. Personalized search inspired fast interactive estimation of distribution algorithm and its application. *IEEE Transactions on Evolutionary Computation*, 2017, 21(4): 588 – 600.
- [138] ASHLOCK D, BROWN J A, SULTANAIEVA L. Exploiting fertility to enable automatic content generation to ameliorate user fatigue in interactive evolutionary computation. *Congress on Evolutionary Computation (CEC)*. Rio de Janeiro, Brazil: IEEE, 2018: 1 – 7.
- [139] CHEN Y, SUN X, GONG D, et al. DPM-IEDA: Dual probabilistic model assisted interactive estimation of distribution algorithm for personalized search. *IEEE Access*, 2019, 7: 41006 – 41016.
- [140] BAO L, SUN X, CHEN Y, et al. Restricted boltzmann machine-driven interactive estimation of distribution algorithm for personalized search. *Knowledge-Based Systems*, 2020, 200: 106030.
- [141] CHEN Y, JIN Y, SUN X. Language model based interactive estimation of distribution algorithm. *Knowledge-Based Systems*, 2020, 200: 105980.
- [142] BAO L, SUN X, GONG D, et al. Multisource heterogeneous user generated contents-driven interactive estimation of distribution algorithms for personalized search. *IEEE Transactions on Evolutionary Computation*, 2021, 26(5): 844 – 858.
- [143] BAO Lin, SUN Xiaoyan, GONG Dunwei, et al. Enhanced restricted boltzmann machine-driven interactive estimation of distribution algorithms with attention mechanism. *Acta Automatica Sinica*, 2023, 49(10): 2188 – 2200.
(暴琳, 孙晓燕, 巩敦卫, 等. 融合注意力机制的增强受限玻尔兹曼机驱动交互式分布估计算法. 自动化学报, 2023, 49(10): 2188 – 2200.)
- [144] VAN BALEN J, GOETHALS B. High-dimensional sparse embeddings for collaborative filtering. *Proceedings of the Web Conference 2021*. Ljubljana, Slovenia: ACM, 2021: 575 – 581.
- [145] ZHANG Xuefeng, CHEN Xiuli, SENG Dewen. Top-N recommendation algorithm combining user trust and influence. *Journal of Zhejiang University (Engineering Science)*, 2020, 54(2): 311 – 319.
(张雪峰, 陈秀莉, 僧德文. 融合用户信任和影响力的top-N推荐算法. 浙江大学学报(工学版), 2020, 54(2): 311 – 319.)
- [146] RICCI F, ROKACH L, SHAPIRA B. Introduction to recommender syBoston, MA, stems handbook. *Recommender Systems Handbook*. Boston, MA: Springer, 2011: 1 – 35.
- [147] PARRA D, SAHEBI S. Recommender systems: Sources of knowledge and evaluation metrics. *Advanced Techniques in Web Intelligence-2*. Berlin, Heidelberg: Springer, 2013: 149 – 175.

作者简介:

暴琳 副教授, 博士, 目前研究方向为进化计算与机器学习, E-mail: baolin_zj@163.com;

朱志宇 教授, 博士, 目前研究方向为智能控制理论和船舶系统控制, E-mail: zzydzz@163.com;

孙晓燕 教授, 博士, 目前研究方向为进化计算和机器学习, E-mail: xysun78@126.com;

徐标 讲师, 博士, 目前研究方向为智能控制与优化, E-mail: xubiao@stu.edu.cn.