

基于三维特征协同支配的个性化学习资源推荐方法

李浩君 张 征 张鹏威

(浙江工业大学教育科学与技术学院 杭州 310023)

摘 要 个性化推荐正成为信息服务时代的重要形式,是缓解学习者知识迷航、提升学习效率的有效途径。为了满足学习者对在线学习资源的个性化需求,提出一种基于三维特征协同支配的个性化学习资源推荐方法(TPLRM)。首先通过完善学习者与在线学习资源特征的匹配关系,建立了三维特征协同支配的个性化学习资源推荐模型,并进行参数化描述;其次设计了一种基于高斯隶属函数模糊控制的二进制粒子群优化算法(FCBPSO)来对推荐模型目标函数进行求解;最后在多个评价指标下,通过 5 组对比实验验证了 TPLRM 推荐方法有较好的推荐性能。

关键词 个性化学习资源推荐,二进制粒子群优化算法,模糊控制,隶属函数

中图法分类号 TP311 **文献标识码** A

Personalized Learning Resource Recommendation Method Based on Three-dimensional Feature Cooperative Domination

LI Hao-jun ZHANG Zheng ZHANG Peng-wei

(College of Education Science and Technology, Zhejiang University of Technology, Hangzhou 310023, China)

Abstract Personalized recommendation is becoming an important form of information service era, and it is an effective way to alleviate knowledge disorientation and improve learning efficiency. In order to meeting learners' personalized needs for online learning resources, personalized recommendation technology is increasingly important. Therefore, this paper proposed a personalized learning resource recommendation method based on three-dimensional feature cooperative domination (TPLRM). Firstly, a personalized learning resource recommendation model based on three-dimensional feature cooperative domination is constructed, resource recommendation feature parameters are improved, and fitness function is built. Secondly, the binary particle swarm optimization algorithm based on fuzzy control of Gauss's membership function (FCBPSO) is used to solve the model. Finally, the evaluation target system is established. Five groups of comparative experiments verifies that TPLRM recommendation method has better recommendation performance.

Keywords Personalized learning resource recommendation, Binary particle swarm optimization algorithm, Fuzzy control, Membership function

1 引言

信息技术与教育应用的深度融合催生了大量在线学习平台,在线学习方式具有资源更新快、资源丰富等特点,然而海量的在线学习资源在给学习者带来便捷的同时,也造成了知识迷航、资源过载等问题,因此引入个性化推荐技术是有一种有效途径^[1-4]。为实现学习者对在线学习资源的个性化需求,即能够根据学习者的特征提供合适的学习资源,因此融合智能计算的在线学习资源推荐方法^[5-7]应运而生。

目前,很多学者为解决学习资源与学习者需求的匹配度问题,提出了多种在线学习资源推荐方法。DeMarcos 等^[8]将学习资源推荐问题看作是一个约束满足问题,并运用粒子群算法进行优化求解。Wang 等^[9]提出了基于离散粒子群算法的课程复习系统,用 DBPSO 算法寻找与主题相关的更加合适的材料,最后采用贪婪方法实现对课程的排序,从而实现了个性化的复习课程组成。许多的个性化在线学习系统往往忽视了学习者属性和学习对象属性之间的关系, Yang 等^[10]提

出了一种基于蚁群算法的自适应学习资源推荐方法,将学习资源按类型分为不同属性,并与学习者属性匹配以提供合适的资源给学习者。Sarath 等^[11]通过构建学习者、学习资源以及相应的匹配模型,运行结合信息素的粒子群优化算法,提出了个性化电子课程的组成方式。

Chu 等^[12]提出了一种基于粒子群优化算法的个性化在线课程组成方法,在一定程度上解决了在线课程的个性化问题;但该二进制粒子群优化算法采用了无惯性权重的方案,实验表明算法很快收敛到局部最优,影响了推荐的质量。因此, Dheeban 等^[13]提出使用带有惯性权重参数调整方法的改进二进制粒子群算法,用于改进个性化在线学习资源组成方法,该方法的推荐速度并没有得到明显提高。Sharma 等^[14]通过人工蚁群算法生成了在线学习内容,根据学习者的学习水平,推荐适应的学习内容。Tan 等^[15]提出了一种基于遗传算法的在线课程生成和优化方法。Gao 等^[16]提出了无速度全局粒子群优化算法应用于个性化电子课程组成,但该方法没有与其他进化算法进行比较,推荐速度方面有待验证。丁继红

本文受国家自然科学基金项目(61503340),国家社会科学基金项目(16BTQ084)资助。

李浩君(1977—),男,博士,副教授,主要研究方向为智能计算、智能学习, E-mail: zgdlhj@zjut.edu.cn(通信作者);张 征(1995—),男,硕士生,主要研究方向为智能计算、智能学习;张鹏威(1992—),男,硕士生,主要研究方向为智能计算、智能学习。

等^[17]通过对大数据环境下的多维关联分析,引入张量理论,构建了学习资源推荐方法,得到了较好的推荐性能。

面对大数据环境下个性化推荐常见的冷启动问题,Xie等^[18]根据学习资源的标签信息,提出了一种带学习者反馈的资源标签交互框架,为学习者提供了个性化资源推荐服务,并且在推荐过程中自适应调整候选资源。为了给用户动态、多样化的推荐服务需求,Zhang等^[19]提取了用户需求隐式因子,通过二部图建模与一种随机游走算法对用户需求的短期变化进行预测,其在精度、效率等方面表现良好。学习者往往在有限时间内需要对多个资源开展学习,Zhu等^[20]提出了一种基于知识映射的多约束推荐模型,针对不同的4种学习场景,采用问卷法对学习者的行为特征进行提取,并根据推荐模型设计了一种多约束推荐算法,推荐结果与学习者自行选择的较为相似。Zhou等^[21]将挖掘的学习资源的特征(如媒介类型、内容类型、离线状态等)与学习者的偏好进行匹配,在大数据环境下利用深度神经网络训练推荐模型,为学习提供符合需求的个性化学习资源。

将智能优化算法应用于学习资源推荐领域可以发现:首先学习资源推荐模型还不够明确,将学习资源推荐与课程或路径生成混淆;其次多数模型的特征参数表示还不够精确,导致学习者推荐的学习资源序列差异小,不符合个性化发展趋势;最后采用二进制粒子群算法求解学习资源推荐问题的效果较好,但随着学习资源数量增加,推荐复杂度增加、学习资源推荐精度降低。

针对以上问题,本文提出基于三维特征协同支配的个性化学习资源推荐方法(TPLRM),加入代表单个学习者的强化特征,使得 TPLRM 方法的资源推荐序列更符合个性化学习需求;针对标准二进制粒子群算法易早熟、容易陷入局部最优,从而不能准确获取学习资源序列的问题,采用融入模糊控制策略的优化二进制粒子群算法,更加契合个性化学习资源推荐服务需求,还能提高学习资源序列的推荐速度和匹配度。

2 个性化学习资源推荐模型规划

2.1 问题描述与模型构建

个性化学习资源推荐的本质是将学习资源特征与学习者特征进行匹配以求得最优解,进而得到个性化学习资源推荐序列的过程。目前,学习资源推荐模型旨在向多学习者推荐,考虑的因素主要是:学习资源的难度是否匹配学习者的能力水平、资源的学习时间是否符合学习者预期学习该资源的时间、学习资源对应的学习概念是否匹配学习者期望的学习目标等。还需考虑单一学习者的因素:学习者对学习资源内容类型的偏好是否匹配学习资源的内容类型、学习资源媒介类型是否符合学习者对学习资源媒介类型喜爱的偏好等。

如图1所示,根据问题的描述,提出基于三维特征协同支配的个性化学习资源推荐模型。三维特征中多学习者特征代表针对多个学习者存在时提取的学习者特征;学习资源特征是与多学习者相匹配的学习资源特征;强化特征是指考虑多学习者特征时往往会导致最后推荐的个性化学习资源序列差异小、精确度不高等问题。因此,加入针对单个学习者的个性化强化特征,即内容偏好和媒介偏好。三维特征协同支配使得推荐资源更加精准和个性化。




图1 基于三维特征协同支配的个性化学习资源推荐模型

2.2 模型三维特征描述

2.2.1 多学习者特征描述

基于上述模型,多学习者特征 LF 可描述为:

$$\begin{cases} L = \{L_1, L_2, \dots, L_K\} \\ A = \{A_1, A_2, \dots, A_K\} \\ H = \{H_1, H_2, \dots, H_K\} \\ t_{uk} \\ t_{lk} \end{cases}$$

其中, t_{uk} 代表学习者 L_k 的学习资源的期望学习时间上限, t_{lk} 代表学习者 L_k 的学习资源的期望学习时间下限。 L 代表 K 个学习者 $1 \leq k \leq K$; A 代表 K 个学习者的能力水平, A_k 代表学习者 L_k 的能力水平; H 代表 K 个学习者的期望学习目标,每个 H_k 有 M 个二进制值,得到矩阵表达式为:

$$H_{k \times m} = \begin{bmatrix} H_{11} & H_{21} & \dots & H_{K1} \\ H_{12} & H_{22} & \dots & H_{K2} \\ \vdots & \vdots & \dots & \vdots \\ H_{1M} & H_{2M} & \dots & H_{KM} \end{bmatrix}$$

H_{km} 用来判断学习概念 C_m 是否符合期望学习目标,其中 $1 \leq m \leq M$,即

$$H_{km} = \begin{cases} 1, & \text{match} \\ 0, & \text{unmatch} \end{cases}$$

2.2.2 学习资源特征描述

学习资源特征 RF 可描述为:

$$\begin{cases} C = \{C_1, C_2, \dots, C_M\} \\ LM = \{LM_1, LM_2, \dots, LM_N\} \\ D = \{D_1, D_2, \dots, D_N\} \\ R = \{R_1, R_2, \dots, R_M\} \\ t = \{t_1, t_2, \dots, t_N\} \end{cases}$$

其中, C 代表学习者期望从学习资源中学习的 M 个概念; LM 代表匹配学习概念的 N 个候选学习资源; D 代表 N 个候选学习资源的难度水平, D_n 代表学习资源 LM_n 的难度水平; t 代表完成学习资源所需要的时间, t_n 表示完成学习资源 LM_n 需要的时间。 R 代表匹配所有学习概念的候选资源,每一个 R_m 有 N 个二进制值,矩阵表达式为:

$$R_{m \times n} = \begin{bmatrix} R_{11} & R_{21} & \dots & R_{M1} \\ R_{12} & R_{22} & \dots & R_{M2} \\ \vdots & \vdots & \dots & \vdots \\ R_{1N} & R_{2N} & \dots & R_{MN} \end{bmatrix}$$

R_{mn} 用来判断学习资源 LM_n 是否匹配学习概念 C_m ,其中 $1 \leq n \leq N$,即

$$R_{mn} = \begin{cases} 1, & \text{match} \\ 0, & \text{unmatch} \end{cases}$$

2.2.3 强化特征描述

单一学习者个性化特征(PF)作为强化特征对学习资源

推荐的准确性起决定作用,可描述为:

$$\begin{cases} MP = \{MP_1, MP_2, \dots, MP_M\} \\ CP = \{CP_1, CP_2, \dots, CP_M\} \\ MK = \{CK_1, CK_2, \dots, CK_M\} \\ CK = \{CK_1, CK_2, \dots, CK_M\} \end{cases}$$

其中, MP 代表学习者对知识点媒介偏好, 每个 MP_m 包含 G 个一维向量, 即

$$MP_{m \times g} = \begin{bmatrix} MP_{11} & MP_{21} & \dots & MP_{M1} \\ MP_{12} & MP_{22} & \dots & MP_{M2} \\ \vdots & \vdots & \dots & \vdots \\ MP_{1G} & MP_{2G} & \dots & MP_{MG} \end{bmatrix}$$

其中, G 的数值代表学习资源所含有的媒介类型数量, $1 \leq g \leq G$ 。 MP_m 的值为实数, 代表学习者对第 m 个概念的第 g 个媒介类型的偏好数值。

CP 代表学习者对知识点内容偏好, 每个 CP_m 包含 G 个一维向量, 即

$$CP_{m \times g} = \begin{bmatrix} CP_{11} & CP_{21} & \dots & CP_{M1} \\ CP_{12} & CP_{22} & \dots & CP_{M2} \\ \vdots & \vdots & \dots & \vdots \\ CP_{1G} & CP_{2G} & \dots & CP_{MG} \end{bmatrix}$$

其中, G 的个数为学习资源包含的内容类型个数。 CP_m 的值为实数, 表示学习者对第 m 个知识点的第 g 个内容类型的偏好值。

MK 代表匹配概念的学习资源媒介类型, 即图片、幻灯片、文档、音频和视频。 每个 MK_m 包含 N 个一维向量, 即

$$MK_{m \times n} = \begin{bmatrix} MK_{11} & MK_{21} & \dots & MK_{M1} \\ MK_{12} & MK_{22} & \dots & MK_{M2} \\ \vdots & \vdots & \dots & \vdots \\ MK_{1N} & MK_{2N} & \dots & MK_{MN} \end{bmatrix}$$

其中, MK_{mn} 的值为整数, 代表第 m 个知识点对应的第 n 个学习资源的媒介类型, 即:

$$MK_{mn} = \begin{cases} 1, & \text{picture} \\ 2, & \text{slide} \\ 3, & \text{document} \\ 4, & \text{audio frequency} \\ 5, & \text{video} \end{cases}$$

CK 为知识点对应的学习资源的内容类型, 即导论、概念详解、理论知识和案例。 每个 CK_m 包含 N 个一维向量, 即

$$CK_{m \times n} = \begin{bmatrix} CK_{11} & CK_{21} & \dots & CK_{C1} \\ CK_{12} & CK_{22} & \dots & CK_{C2} \\ \vdots & \vdots & \dots & \vdots \\ CK_{1N} & CK_{2N} & \dots & CK_{CN} \end{bmatrix}$$

其中, CK_{mn} 的值为整数, 表示第 m 个知识点对应的第 n 个学习资源的内容类型, 即:

$$CK_{mn} = \begin{cases} 1, & \text{introduction} \\ 2, & \text{concept explanation} \\ 3, & \text{theory} \\ 4, & \text{examples} \end{cases}$$

2.3 基于三维特征协同支配的目标函数构建

个性化推荐问题可以被建构为适应度函数, 这有利于促进启发式算法在学习领域的应用, TPLRM 方法基于三维特征参数来构建适应度函数, 下列目标函数使学习资源满足学习者需求。

学习资源与学习者期望的学习目标之间的差值可表示为:

$$|R_{nm} - H_{km}|$$

实际应用时存在多个概念和资源, $1 \leq n \leq N, 1 \leq m \leq M$, 加入决策变量则有:

$$\sum_{m=1}^M \sum_{n=1}^N X_{nk} |R_{nm} - H_{km}|$$

目标函数 F_1 描述哪一个学习资源对应着学习者需要的学习概念, 由上式可求得满足 F_1 的差值, 即

$$F_1 = \frac{\sum_{m=1}^M \sum_{n=1}^N X_{nk} |r_{nm} - h_{km}|}{\sum_{n=1}^N X_{nk}}, 1 \leq k \leq K \quad (1)$$

学习者能力水平与学习资源难度水平的差异可表示为: $|D_n - A_k|$ 。 随着学习资源的增多, $1 \leq n \leq N, 1 \leq k \leq K$, 该差异则为 $\sum_{n=1}^N X_{nk} |D_n - A_k|$ 。

因此 F_2 作为目标函数可用来描述哪一个学习资源难度适合学习者能力, 可得:

$$F_2 = \frac{\sum_{m=1}^M \sum_{n=1}^N X_{nk} |r_{nm} - h_{km}|}{\sum_{n=1}^N X_{nk}}, 1 \leq k \leq K \quad (2)$$

为了保证期望时间内能完成资源学习, 可得目标函数 F_3 :

$$F_3 = (\max(t_{lk} - \sum_{n=1}^N t_n X_{nk}, 0)) + (\max(0, \sum_{n=1}^N t_n X_{nk} - t_{lk})) \quad (3)$$

乘以相应的权重之后, 组推荐阶段的适应度函数应为:

$$\min f_1(x) = \sum_{j=1}^3 \omega_j F_j \quad (4)$$

继续考虑个性化特征, 媒介偏好的计算公式如下:

$$MKP_{mg} = \frac{Num4_{mg}}{\sum_{g=1}^G Num4_{mg}} \quad (5)$$

由式(5)计算得到目标函数 F_4 :

$$F_4 = \frac{\sum_{g=1}^G |MP_{mg} - MKP_{mg}|}{G}, 1 \leq m \leq M \quad (6)$$

其中, MKP_{mg} 表示该学习资源的媒介类型与全部知识点数的百分比, F_4 为学习者对某知识点的媒介类型偏好与知识点的媒介类型间的平均差异值。 若 $X_{mm}MK_{mm}$ 为 $g=1, 2, 3, 4, 5$, 则类型值 $Num4_{mg}$ 增加 1, 否则为 0。 $X_{mm}MK_{mm}$ 表示涵盖某知识点的资源媒介类型。

同样地, 内容类型偏好的计算公式如式(7)所示:

$$CKP_{mg} = (Num5_{mg}) / (\sum_{g=1}^G Num5_{mg}) \quad (7)$$

再由式(8)可得 F_5 :

$$F_5 = \frac{\sum_{g=1}^G |CP_{mg}CKP_{mg}|}{G}, 1 \leq m \leq M \quad (8)$$

其中, CKP_{mg} 表示该学习资源的内容类型与全部知识点的百分比, F_5 表示学习者对知识点的资源内容类型偏好与内容类型间的平均差异值, 若 $X_{mm}CK_{mm}$ 为 $g=1, 2, 3, 4$, 则类型值 $Num5_{mg}$ 增加 1, 否则为 0。 $X_{mm}CK_{mm}$ 表示涵盖某知识点的资源内容类型。

因此在加入单一学习者个性化特征后, 根据重要程度设置相应的权重值后获得最终的适应度函数, 如式(9)所示:

$$\min f_2(x) = \sum_{j=1}^3 \omega_j F_j + \omega_4 F_4 + \omega_5 F_5 \quad (9)$$

2.4 决策变量

初始化推荐的学习资源为: $X = \{X_1, X_2, \dots, X_N\}$, 每个 X_n

含有 K 个向量,使用 X_{nk} 二进制编码,若 $X_{nk}=1$,则推荐该学习资源;若 $X_{nk}=0$,则不推荐该学习资源。

3 推荐方法流程

将求解个性化学习资源推荐模型作为一个组合优化问题^[7],此类实际问题采用粒子群算法解决时易陷入局部最优^[22-24],造成学习资源推荐速度慢、推荐匹配度不高的问题,本文提出融入模糊控制策略的二进制粒子群优化算法(FCBPSO)来解决最优序列推荐问题,该算法采用高斯隶属函数对种群进化过程进行模糊控制,有效平衡了全局开发和局部探索的能力,优化上述定义的个性化推荐问题的适应度函数,保证学习资源推荐的速度和准确度,该方法的操作流程如图 2 所示。




图 2 TPLRM 方法流程

Step1 初始化操作。在 FCBPSO 算法中,每一个粒子相当于一个学习资源组合,不同的学习者需要推荐的学习资源数量也不同,为了加强算法的搜索能力,使用混沌函数进行混沌初始化,过滤掉一些不必要的粒子,提高算法效率。式(10)为初始化函数。

$$y_{t+1} = \mu y_t (1 - y_t), t = 0, 1, 2, \dots$$
 (10)

其中, t 表示的是迭代次数, μ 表示的是控制系统混沌行为的参数,设置值为 4,使映射处于完全混沌状态。 y_0 为 0 到 1 的随机数,当 μ 取值为 4 时, y_t 随着迭代次数的增加而具有更明显的无规律性,其取值也在 0 至 1 之间,此时的安全性与混沌程度都较好,再将每一代的 y_t 值进行二进制处理,若 y_t 大于 0.5,则将其记为 1,反之记为 0。

Step 2 根据模型特征信息构建适应度函数(见式(9)),再进行粒子适应度的计算。

Step 3 使用融入模糊控制策略的二进制粒子群算法对适应度函数进行求解。将优化算法与实际问题相结合的优化策略如下:

1)定义控制因子:融入模糊控制策略的二进制粒子群算法,涉及个体适应度值和种群信息的分布,而随着迭代次数增加,种群的多样性快速下降,根据这一特征和海明距离均值与迭代次数之间的线性关系,在迭代过程中定义控制因子每一代的进化状态通过进化因子 f 来控制:

$$f = (1 - e^{-\frac{HD}{k}}) * (1 - \frac{t}{T}) \in [0, 1]$$
 (11)

其中, HD 表示海明距离均值, k 用来调节指数函数对海明距离均值的敏感程度, t 和 T 分别表示种群的当前迭代次数与最大迭代次数。当 $t = T$ 时, $f = 1$ 。

粒子群算法在进化过程往往容易产生收敛速度慢和陷入

局部最优的问题。文献[25]研究了收敛模糊粒子群算法及其性能,在多方面比较了多个隶属函数的优劣,确定采用高斯隶属函数控制因子进行模糊分类,如式(12)所示:

$$gaussian = ae^{-\frac{(x-b)^2}{c^2}}$$
 (12)

隶属值随控制因子增大的变化情况如图 3 所示。




图 3 基于高斯隶属函数的控制因子

2)根据模糊控制因子实施惯性权重自适应调整策略, a 为控制系数,如式(13)所示:

$$\omega = a * (\omega_{max} - \omega_{min}) * e^{-\frac{HD}{k}} * t/T + \omega_{min}$$
 (13)

3)粒子速度更新:使用与实数 PSO 相同的速度更新公式来计算粒子的速度值,其粒子速度更新公式如下:

$$v_{ij}^{t+1} = \omega v_{ij}^t + c_1 r_1 (p_{ij} - x_{ij}^t) + c_2 r_2 (g_{ij} - x_{ij}^t)$$
 (14)

4)粒子位置更新: $f \geq 0.5$ 时,种群处于进化前期,通过比较 S-shaped 映射函数值与 rand 值得到概率值,此时能够具有稳定的收敛状态; $f < 0.5$ 时,种群进入进化后期,采用 V-shaped 型映射函数求得概率值,当概率值大于随机数 rand 时,粒子位置向量取自身补集,否则处于原来的位置,该时期具有加速收敛行为,可防止过早陷入局部最优。更新公式如下:

$$\begin{cases} X_i = 1, & r < S(v_{ij}) \\ X_i = 0, & r > S(v_{ij}), & f \geq 0.5 \\ X_i = C(X_i), & r < S(v_{ij}) \\ X_i = X_i, & r > S(v_{ij}), & f < 0.5 \end{cases}$$
 (15)

Step 4 确定粒子最优解和种群最优解位置,即找到最匹配的学习资源。

Step 5 回到 Step 2 重复执行,直到达到终止条件,算法结束运行。

Step 6 输出全局最优解和相应的目标函数值,学习资源序列结果以二进制 0 或 1 表示,其数量是所有学习资源的数量,根据显示结果,1 代表向学习者推荐该学习资源,而 0 代表不向学习者推荐该学习资源。

4 仿真实验结果与分析

4.1 实验设计

4.1.1 评价指标

为了验证本文所提方法推荐的学习资源序列的有效性,拟将 BPSO^[12]、基于随机系数的粒子群优化算法 RPSO^[13]、基于线性系数的粒子群优化算法 LPSO^[13] 和采用 V 型映射函数的二进制粒子群优化算法 VBPSO^[26] 应用于在线学习资源推荐领域,并与本文方法所采用的推荐模型进行对比分析。

根据各算法的运行结果,具体的评价指标可分为:1)收敛性指标:可通过各算法迭代 t 次后的收敛曲线等判断。2)准确性指标:可通过各算法运行 n 次后的适应度均值、方差和收敛至全局最优成功的次数等判断。3)时间性能指标:可通过各算法运行 n 次后收敛至全局最优的执行时间均值等判断。4)数值算例:可通过仿真实验向学习者推荐学习资源序列来

进一步分析方法的可行性。

4.1.2 实验参数设置

为使实验更加全面有效,模型参数的设置如表 1 所列,其

中各目标适应度函数的权重依据重要程度设置^[12]。为了更好地贴近实际应用的学习场景,实验分为 5 组进行,分组实验参数如表 2 所列。

表 1 模型参数

参数分类	参数名称	下标范围	初始化参数值
学习者特征参数	L_k	$1 \leq k \leq 40$	学习者数
	A_k	$1 \leq k \leq 40$	学习者能力划分为 5 个等级并随机初始化
	H_k	$1 \leq k \leq 40$	学习者期望学习目标随机确定
	T_{uk}	$1 \leq k \leq 40$	学习者期望学习时间上限随机确定
	T_{lk}	$1 \leq k \leq 40$	学习者期望学习时间下限随机确定
学习资源特征参数	LM_n	$1 \leq n \leq 150$	匹配学习概念的候选学习资源数
	C_m	$1 \leq m \leq 10$	学习概念数
	D_n	$1 \leq n \leq 150$	学习资源难度水平划分为 5 个等级并随机初始化
	R_m	$1 \leq m \leq 10$	学习概念所对应的难度不同的学习资源
强化特征参数	T_n	$1 \leq m \leq 10$	学习资源需要学习时间随机设定
	MP_{mg}	$1 \leq m \leq 10, 1 \leq g \leq 5$	学习者对学习资源媒介偏好随机确定
	CP_{mg}	$1 \leq m \leq 10, 1 \leq g \leq 4$	学习者对学习资源内容偏好随机确定
	MK_{mm}	$1 \leq m \leq 10, 1 \leq n \leq 150$	知识点对应的学习资源媒介类型随机确定
	CK_{mm}	$1 \leq m \leq 10, 1 \leq n \leq 150$	知识点对应的学习资源内容类型随机确定
适应度函数	$\omega_1, \omega_2, \omega_3$	$\omega_1=0.3, \omega_2=\omega_3=0.2$	根据重要程度设置各目标函数的权重值
	ω_4, ω_5	$\omega_4=\omega_5=0.15$	

表 2 分组实验参数

	实验组 1	实验组 2	实验组 3	实验组 4	实验组 5
学习资源数量	40	80	120	120	120
学习者数量	30	30	30	40	50

4.1.3 实验环境

仿真实验环境是 windows7 操作系统,实验平台为 MATLAB R2012a。硬件环境是 Intel 处理器 i5-4570,内存是 4 GB。

4.2 收敛性对比分析

图 4 是 TPLRM 方法与其他对比方法采用不同算法的收敛曲线,其中 TPLRM 采用的是 FCBPSO,从收敛曲线可以看出 5 种算法都有收敛的趋势,这说明粒子群算法求解学习资源推荐模型是可行的。




图 4 算法收敛曲线

通过观察实验组 1、实验组 2 和实验组 3 的收敛曲线,3 组实验中 FCBPSO 都表现出最好的收敛速度,这说明随着学习资源增多,FCBPSO 具有最优的适应能力;再观察实验组 3、实验组 4 和实验组 5 的收敛曲线,随着学习者的增多,FCBPSO 仍具有最好的收敛速度和最佳适应能力。TPLRM 方法在学习资源和学习者增多时能够准确、快速地推荐满足学习者需求的学习资源序列,达到个性化学习资源推荐目的。

4.3 准确性对比分析

图 5 是最优解均值变化曲线,图 6 是算法收敛至全局最优的成功率变化曲线,随着学习资源和学习者增加,FCBPSO 的求解精度和成功率明显好于其他算法。因此 TPLRM 推荐的学习资源序列比其他方法具有较好的准确性和可靠性。




图 5 最优解均值变化曲线




图 6 成功率变化曲线图

表 3 是 TPLRM 方法与其他方法采用的算法执行 100 次独立实验的仿真数据,实验最优解均值和方差列于表中,最好值用粗体表示。对比实验组 1、实验组 2 和实验组 3,随着学习资源的增加 FCBPSO 都具有最好的收敛精度和稳定性,再观察实验组 3、实验组 4 和实验组 5,FCBPSO 在学习者增多时仍有最好的收敛精度和稳定性。

表 3 实验仿真数据

采用算法		实验 1	实验 2	实验 3	实验 4	实验 5
BPSO	avg	2.5486×10^3	2.8994×10^4	9.2882×10^4	2.5192×10^5	4.9583×10^5
	var	1.3569×10^3	7.8340×10^3	2.0874×10^4	5.6325×10^4	8.8112×10^4
RPSO	avg	1.6623×10^4	7.6777×10^4	1.8909×10^5	4.2712×10^5	7.6934×10^5
	var	4.7188×10^3	1.6052×10^4	3.9772×10^4	9.1760×10^4	1.2752×10^5
LPSO	avg	8.5552×10^3	5.0832×10^4	1.3834×10^5	3.3036×10^5	6.2232×10^5
	var	2.8441×10^3	1.2227×10^4	2.9556×10^4	7.0037×10^4	1.0641×10^5
VBPSO	avg	1.2771×10^4	6.5780×10^4	1.6928×10^5	3.8698×10^5	7.0964×10^5
	var	4.1700×10^3	1.4348×10^4	3.5485×10^4	8.2399×10^4	1.1444×10^5
FCBPSO	avg	1.1738×10^3	2.5740×10^2	7.7225×10^2	2.7525×10^3	6.3295×10^3
	var	1.7465×10^3	1.4894×10^2	5.3446×10^2	1.4340×10^3	2.2588×10^3

4.4 时间性能对比分析

图 7 给出了每组实验各算法收敛至全局最优执行时间的均值,随着学习资源和学习者的增多,问题复杂程度和规模变大,5 种算法的执行时间都明显增加。在同一组实验中,FCBPSO 算法的执行时间略低于其他算法,原因是 FCBPSO 算法融入了模糊控制优化策略,在其他算法陷入局部最优难以收敛时,FCBPSO 能够快速收敛至最优值,尤其是控制因子小于 0.5 时,快速的收敛优势更得以展现,另外 FCBPSO 成功率较高,平均执行时间也会少于其他算法,因此在时间性能方面,TPLRM 也优于另几种方法。




图 7 执行时间的变化曲线

4.5 数值实例分析

本案例选取了 Java 课程的部分知识点,该课程的部分知识点图谱如图 8 所示。假设现在有一名学习者 A 有意向学习该课程,根据三维特征的描述与 5 个目标函数的构建规则,且保证案例能够具体地推荐出最佳学习资源,因此实验设置初始化参数为随机初始化,如表 4 所列。




图 8 部分知识图谱

表 4 初始化参数条件

学习者代号	目标函数 1 期望的 学习目标	目标函数 2 适宜的 难度水平	目标函数 3 期望的 学习时间	目标函数 4 期望的 媒介类型	目标函数 5 期望的 内容类型
A	Java 基础语法	等级三	7~10 min	视频	概念详解

根据本文方法,通过构建的目标函数,将学习资源与实验初始化的参数条件进行计算,并对适应度函数用改进算法寻优得出推荐资源序列结果,如表 5 所列,1 表示向 A 学习者推

荐该序号学习资源,0 则不推荐,可观察到资源序号为 2,5,70,94,98 的学习资源为推荐资源,说明这些资源符合表 5 所述。

表 5 推荐结果

资源序号	1	2	3	4	5	...	...	70	...	...	94	...	98	99	100
输出结果	0	1	0	0	1	0	0	0	1	0	0	1	0	1	0

进一步地,为了验证本文方法推荐的学习资源序列具有差异性优势,结合表 4 与表 5 的推荐示例,向 A,B,C 3 位学习者推荐学习资源,3 位学习者的初始化参数是不同的,对 20 个学习资源进行 1—20 的编号,因此每位学习可以得到一个资源推荐序列,如图 9 所示。




图 9 学习资源推荐序列示意图

针对推荐问题,本文所构建的目标函数将资源特征与学习者特征进行匹配计算,在此前的实验中,已经验证了 FCBPSO 求解的最优值远远小于其他对比算法,在此前提下,从图 9 可以看出,FCBPSO 所推荐的资源序列差异性明显,选择对比的 BPSO 推荐的序列则较为相似,这说明 FCBPSO 对该问题的适应性较强,挖掘符合学习者需求资源的能力更好,针对不同特征的学习者可以推荐匹配度更高的资源。

结束语 根据多学习者的特征和学习资源特征进行个性化推荐求解差异化太小,不符合个性化学习需求,本文加入针对单一学习者的个性化强化特征以形成三维特征协同支配的状态,并提出基于三维特征协同支配的个性化学习资源推荐方法(TPLRM),解决了推荐速度慢、匹配度不高等问题。对比方法仿真实验结果表明,采用 FCBPSO 算法的本文方法可推荐最匹配个性化学习资源序列,验证了该方法的可行性和高效性。如何精确规划学习者与学习资源间的个性化特征是推荐工作的关键,随着资源与数据的快速增长,未来需要学习和研究更多智能技术应用于智能学习领域,从而更好地满足个性化学习需求。

参 考 文 献

[1] 叶晓庆,刘盾,梁德翠. 基于协同过滤的三支粒推荐算法研究[J]. 计算机科学,2018,45(1):90-96.
[2] 赵兴旺,梁吉业,郭兰杰. 一种基于空间变换的协同过滤推荐算

法[J]. 计算机科学,2018,45(7):16-21.

[3] 文俊浩,孙光辉,李顺. 基于用户聚类 and 移动上下文的矩阵分解推荐算法研究[J]. 计算机科学,2018,45(4):215-219,251.

[4] 尹伟,冯丹,施展. 一种基于效用的个性化文章推荐方法[J]. 计算机学报,2017,40(12):2797-2811.

[5] SARATH C A P,DHEEBAN S G,Deepak V,et al. Personalized e-course composition approach using digital pheromones in improved particle swarm optimization[C]// International Conference on Natural Computation. IEEE,2010:2677-2681.

[6] KURILOVAS E , ZILINSKIENE I,DAGIENE V. Recommending suitable learning scenarios according to learners’ preferences:An improved swarm based approach[J]. Computers in Human Behavior,2014,30(1):550-557.

[7] DEMARCOS L,GARCIA-CABOT A,GARCIA-LOPEZ E,et al. Parliamentary optimization to build personalized learning paths:Case study in web engineering curriculum[J]. International Journal of Engineering Education, 2015, 31 (4): 1092-1105.

[8] DEMARCOS L,BARCHINO R,MARTNEZ J J,et al. Competency-Based Intelligent Curriculum Sequencing Using Particle Swarms[C]// Eighth IEEE International Conference on Advanced Learning Technologies. IEEE Computer Society, 2008: 295-297.

[9] WANG T I, TSAI K H. Interactive and dynamic review course composition system utilizing contextual semantic expansion and discrete particle swarm optimization[J]. Expert Systems with Applications,2009,36(6):9663-9673.

[10] YANG Y J, WU C. An attribute-based ant colony system for adaptive learning object recommendation [J]. Expert Systems with Applications,2009,36(2):3034-3047.

[11] SARATH C A P,DHEEBAN S G,DEEPAK V,et al. Personalized e-course composition approach using digital pheromones in improved particle swarm optimization[C]// International Conference on Natural Computation. IEEE,2010:2677-2681.

[12] CHU C P,CHANG Y C, TSAI C C. PC 2 PSO:personalized e-course composition based on Particle Swarm Optimization[J]. Applied Intelligence,2011,34(1):141-154.

[13] DHEEBAN S G,DEEPAK V,DHAMODHARAN L,et al. Improved personalized e-course composition approach using modified particle swarm optimization with inertia-coefficient[J]. International Journal of Computer Applications,2011,1(6):109-115.

[14] SHARMA R,BANATI H,BEDI P. Adaptive Content Sequencing for e-Learning Courses Using Ant Colony Optimization[C]// International Conference on Soft Computing for Problem Solving (SocProS 2011). 2011:579-590.

[15] TAN X H,SHEN R M,WANG Y. Personalized course generation and evolution based on genetic algorithms[J]. Journal of Zhejiang University-Science C,2012,13(12):909-917.

[16] GAO Y,PENG L,Li F,et al. A Multi-objective PSO with Pareto Archive for Personalized E-Course Composition in Moodle Learning System[C]// International Symposium on Computational Intelligence and Design. 2016:21-24.

[17] 丁继红,刘华中. 大数据环境下基于多维关联分析的学习资源精准推荐[J]. 电化教育研究,2018(2):53-59.

[18] XIE Q,XIONG F,HAN T,et al. Interactive resource recommendation algorithm based on tag information[J/OL]. World Wide Web-internet & Web Information Systems, <https://doi.org/10.1007/s11280-018-0532-y>.

[19] ZHANG Y,LEI T,QIN Z,et al. A Service Recommendation Algorithm Based on Modeling of Dynamic and Diverse Demands [J]. International Journal of Web Services Research, 2018, 15(1):47-70.

[20] ZHU H,TIAN F,WU K,et al. A Multi-Constraint Learning Path Recommendation Algorithm Based on Knowledge Map[J]. Knowledge-Based Systems,2018,143(3):102-114

[21] ZHOU Y,HUANG C,HU Q,et al. Personalized learning full-path recommendation model based on LSTM neural networks [J]. Information Sciences,2018,444(5):135-152.

[22] 吴雷,方卿. 基于改进粒子群算法的学习路径优化方法[J]. 系统科学与数学,2016,36(12):2272-2281.

[23] 张爱玲,李鹏,刘晟. 基于粒子群算法的图像椒盐噪声去除算法[J]. 计算机科学,2017,44(8):301-305.

[24] 张燕平,荆紫慧,张以文,等. 基于离散粒子群算法的动态 Web 服务组合[J]. 计算机科学,2015,42(6):71-75.

[25] MENG X,JIA L. A New Kind of PSO-Convergent Fuzzy Particle Swarm Optimization and Performance Analysis[C]// Fourth International Conference on Networked Computing and Advanced Information Management. IEEE Computer Society, 2008:102-107.

[26] MIRJALILI S M,LEWIS A. S-shaped versus V-shaped transfer functions for binary Particle Swarm Optimization[J]. Swarm & Evolutionary Computation,2013,9:1-14.

(上接第 445 页)

[8] 姜建武,李景文,陆妍玲,等. 基于用户画像的信息智能推送方法[J]. 微型机与应用,2016,35(23):86-89.

[9] 赵曙光. 高转化率的社交媒体用户画像:基于 500 用户的深访研究[J]. 现代传播-中国传媒大学学报,2014,36(6):115-120.

[10] 胡媛,毛宁. 基于用户画像的数字图书馆知识社区用户模型构建[J]. 图书馆理论与实践,2017(4):82-85.

[11] 牛温佳. 用户网络行为画像:大数据中的用户网络行为画像分析与内容推荐应用[M]. 北京:电子工业出版社,2016.

[12] 刘速. 浅议数字图书馆知识发现系统中的用户画像——以天津图书馆为例[J]. 图书馆理论与实践,2017(6):103-106.

[13] 陈晓康,刘竹松. 基于改进 Kd-Tree 构建算法的 k 近邻查询[J]. 广东工业大学学报,2014(3):119-123.

[14] ABUDALFA S. A Dynamic Linkage Clustering using KD-Tree [J]. International Arab Journal of Information Technology, 2011,10(3):283-289.