

文章编号: 1000-5862(2020)01-0020-08

# 基于认知诊断的自适应学习材料智能推送算法研究

涂冬波, 张咏\*

(江西师范大学心理学院, 江西 南昌 330022)

**摘要:** 将认知诊断和自适应学习相结合, 利用认知诊断方法先诊断学习者对知识的掌握情况, 然后依据遗传算法和多岛遗传算法为每个学习者智能化提供合适的学习材料, 提出了基于认知诊断框架下的自适应学习材料智能推送算法. 通过 Monte Carlo 模拟实验考察了新算法的科学性及其效果, 研究表明: (i) 基于认知诊断框架下的自适应学习材料智能推送算法具有较理想的效果; (ii) 遗传算法和多岛遗传算法选取的学习材料具有低惩罚函数值和高学习材料匹配的正确率; (iii) 遗传算法和多岛遗传算法选取的材料比随机算法更加适合学习者.

**关键词:** 认知诊断; 自适应学习; 材料推送; 遗传算法; 多岛遗传算法

**中图分类号:** B 841 **文献标志码:** A **DOI:** 10.16357/j.cnki.issn1000-5862.2020.01.05

## 0 引言

在测量学中, 人们把对个体认知过程、加工技能或者知识结构的诊断评估称为认知诊断(cognitive diagnosis, CD)<sup>[1]</sup>. 传统的测量往往只报告一个测验总分, 但认知诊断可以提供更加详细的诊断结果, 这更加有利于教师对学生进行有针对性地教学补救.

当前教育模式主要是班级教学, 班级教学可以大规模地向全体学生进行教学, 这在很大程度上节省了教学资源 and 提高了教学效率. 但是, 由于每个学习者是不同的个体, 千篇一律的教学方法可能会造成学生对学习失去动力<sup>[2]</sup>. 随着教育需求和互联网技术的发展, 依据学生个体差异提供不同的学习资源的自适应学习(Adaptive Learning)已成为国内外学者研究的重点<sup>[3]</sup>. 自适应学习的原始雏形是适应性超媒系统. 在该系统中, 电脑会记录每个学习者的学习特征, 随着学习的进行, 系统会根据每个学习者的特征推送合适的学习材料. 随着科技的发展, 自适应学习技术也越来越丰富. Cheng Nianshing 等<sup>[4]</sup>以在线学习领域的会议论文和期刊论文为数据源, 运用文本挖掘技术来自动构建概念图, 为教师设计自适应课程和学习者理解领域知识的全貌提供帮助. 杨现民等<sup>[5]</sup>应用本体和推理技术, 构建了包含本体

层、标注层、语义层和推理层的学习元平台语义框架, 并研究了学习资源的有序进化控制、动态语义关联、语义检索等, 从而实现了从资源的语义化组织到具有更强智能性和个性化的高级应用服务. 尽管这些自适应学习系统的构建方式不同, 但其核心思想是相同的, 即以学习者的特征为基础, 在相关理论的指导下, 为每个学习者推送适合其个性特征的学习资源. 然而, 当前关于自适应学习技术存在 2 个不足: (i) 当前推送算法没有充分考虑学习者当前的知识状态(knowledge state, KS)和认知结构. 因此有可能让学生去学习他们已经掌握的知识, 这显然不能有效地节省资源并降低了学习的效率. (ii) 这些自适应学习技术都是学生对学习资源的自适应, 而对于知识、技能、能力等相关学生个体知识结构及认知结构的自适应, 这些自适应技术并不能有效地解决. 所以有必要将教育测量中的认知诊断技术和自适应学习技术有机地结合起来, 利用认知诊断理论诊断学习者知识结构及认知结构, 然后依据自适应推送算法为每个学习者提供其合适的学习材料. 这也是本研究拟重点解决的问题.

## 1 基于认知诊断的自适应学习材料推送算法开发

自适应学习系统一般包括 3 个模型: 材料模型、

收稿日期: 2019-09-28

基金项目: 国家自然科学基金(31660278, 31760288, 31960186)和江西省教育厅人文社科重点(重大)课题(JD17077)资助项目.

作者简介: 涂冬波(1978-), 男, 江西南昌人, 教授, 博士, 博士生导师, 主要从事心理统计与测量的研究. E-mail: tudongbo@aliyun.com

通信作者: 张咏(1993-), 男, 安徽芜湖人, 硕士研究生, 主要从事心理测量与评价方面的研究. E-mail: 799349507@qq.com

学习者模型和自适应模型<sup>[6-8]</sup>,这些模型是自适应材料推送算法的依据.在本研究中,为了充分利用认知诊断的分析结果,开发了基于认知诊断的自适应学习系统的4个模型:材料模型、属性模型、学习者模型和自适应模型.与传统的3个模型相比较,本研究新增加了基于认知诊断的属性模型,该模型可以充分考察不同学习属性的难易程度以及属性间的关系,从而为属性学习的选择及其学习顺序提供了支持;同时还补充了学习者对当前相关属性的掌握情况以及学习者当前的知识状态与认知结构,这为真正实现自适应学习提供了坚实的基础.

### 1.1 学习者模型

在面向学习者的推送中,学习者的特征影响学习资源的推送.因此,学习者建模是推送的基础.学习者模型的建立应重点考察非认知部分.根据现有的研究结果和认知诊断理论<sup>[9]</sup>,本文拟重点考虑学习者的5个特征:(i)属性掌握概率;(ii)学习者的学习时间;(iii)学习者的媒体类型偏爱(媒体偏爱类型分成4类:音频偏爱、视频偏爱、文本偏爱、图像偏爱);(iv)学习者的内容呈现偏爱(内容呈现偏爱分成4类:例子偏爱、理论偏爱、解释偏爱、试题偏爱);(v)背景信息偏爱(背景信息偏爱类型分成3类:娱乐偏爱、生活偏爱、科学偏爱).

### 1.2 材料模型

在自适应系统中,材料模型与学习者模型同样重要.在材料模型中,每个学习材料包含4个基本特征:(i)材料的学习时间;(ii)材料的媒体类型,与学习者模型中的媒体类型偏爱相对应,材料的媒体类型可以分成4类(音频、视频、文本、图像);(iii)材料的内容呈现,与学习者模型中内容呈现偏爱相对应,每个学习材料的内容呈现分成4类(例子、理论、解释、试题);(iv)材料的背景信息,与学习者模型中背景信息偏爱相对应,每个学习材料的背景信息分成3类(娱乐、生活、科学).

### 1.3 属性模型

属性模型是基于认知诊断框架下的模型,在属性模型中,考虑了3个因素:(i)属性间层级关系;(ii)属性个数;(iii)属性难度.仿照经典测量理论<sup>[10]</sup>,将所有被试者在属性上的掌握率(即通过率)定义为属性难度(attribute difficulty, AD),计算公式为

$$A_{D_k} = \sum_{k=1}^N A/N, A = \begin{cases} 0, P_j(\alpha_c) < 0.5, \\ 1, P_j(\alpha_c) \geq 0.5, \end{cases}$$

$A_{D_k}$ 表示属性 $k$ 的难度参数, $P_j(\alpha_c)$ 表示知识状态为 $\alpha_c$ 的被试者在题目 $j$ 上的正确作答概率, $P_j(\alpha_c)$ 可以由认知诊断模型的项目反应函数计算. $A_{D_k}$ 值越小,则属性 $k$ 越难掌握.

### 1.4 推送模型

推送模型是自适应学习系统中最关键的组成部分.一个合理的推送模型才能给学习者提供更加合适的学习材料.基于材料模型、属性模型和学习者模型,将本次研究的9条推送规则设置如下:(i)学习者已经掌握的属性不再进行学习;(ii)所选的材料序列要包含学习者全部的未掌握属性;(iii)在未掌握的属性中优先学习难度低的属性;(iv)在未掌握的属性中优先学习掌握概率高的属性;(v)属性的学习顺序要符合属性层级关系(attribute hierarchy);(vi)学习材料的媒体类型要符合学习者的媒体类型偏爱;(vii)学习材料的内容呈现要符合学习者的内容呈现类型偏爱;(viii)学习材料的背景信息要符合学习者的背景信息偏爱;(ix)学习材料的学习时间要小于或者等于学习者预先设定的学习时间.

理论上,每个规则均可挑选出一组完全满足该规则的一组学习材料,但这组学习材料可能不会满足其他规则.因此,希望挑选出一组尽可能满足所有规则的学习材料.在统计学中,这类问题通常被称为约束满足问题(Constraint Satisfaction Problem)<sup>[11]</sup>.对于约束满足问题,构建惩罚函数(Penalty function)<sup>[12]</sup>的方法是一种比较常用的解决方法.

### 1.5 惩罚函数的建立

设在材料库中有 $M$ 个材料,每个材料包含单个属性(即每个材料涉及的属性数仅为1),则 $M$ 个材料包含 $M$ 个属性.首先,经过认知诊断测验诊断出学习者 $X_i$ 没掌握 $m$ 个属性,则需要学习的属性为 $m$ 个和需要挑选的学习材料也为 $m$ 个(规则1).在本研究中,学习者 $X_i$ 和挑选的 $m$ 个学习材料之间的匹配性可以用惩罚函数来表示,惩罚函数的定义如下:

$$F = \sum_{e=1}^h w_e P_e, \quad (1)$$

其中 $F$ 是惩罚函数值,惩罚函数值越小,学习者 $X_i$ 和 $m$ 个学习材料之间的匹配性越高. $h$ 表示约束条件个数,由推送规则可知 $h = 8$ . $w_e$ 为每个约束条件的权重,可由专家建议和学习者偏好优先级来设置, $P_e$ 为约束条件,根据8个推送规则, $P_1 \sim P_8$ 的计算公式依次介绍如下:

$$P_1 = |(K \cap K') / m|,$$

$P_1$  函数的建立依赖于规则 2.  $K$  为学习者待学习属性的序列,  $K = \{K_1, K_2, \dots, K_m\}$ .  $K'$  为推送材料的属性序列,  $K' = \{K'_1, K'_2, \dots, K'_m\}$ .  $|\cdot|$  表示集合中元素个数.  $P_1$  的取值范围为  $[0, 1]$ . 若推送的学习材料序列中包含学习者未掌握的属性越少, 则  $P_1$  越大.

$$P_2 = \sum_{j=1}^m P_{X_2} / m, P_{X_2} = \begin{cases} 0, A_{D_j} = A'_{D_j}, \\ 1, A_{D_j} \neq A'_{D_j}, \end{cases}$$

$A_D$  为  $m$  个属性难度值从大到小的序列,  $A_D = \{A_{D_1}, A_{D_2}, \dots, A_{D_m}\}$ .  $A'_D$  表示推送学习材料的难度序列值,  $A'_D = \{A'_{D_1}, A'_{D_2}, \dots, A'_{D_m}\}$ . 如果推送学习材料的难度值与相应位置的未掌握属性难度值不一致就会被惩罚.  $P_2$  的取值范围为  $[0, 1]$ .  $P_2$  函数的建立依赖于规则 3.

$$P_3 = \sum_{j=1}^m P_{X_3} / m, P_{X_3} = \begin{cases} 0, M_{P_j} = M'_{P_j}, \\ 1, M_{P_j} \neq M'_{P_j}, \end{cases}$$

其中  $M_p$  为  $m$  个属性掌握从大到小的序列,  $M_p = \{M_{P_1}, M_{P_2}, \dots, M_{P_m}\}$ .  $M'_p$  表示推送学习材料的掌握概率序列值,  $M'_p = \{M'_{P_1}, M'_{P_2}, \dots, M'_{P_m}\}$ . 如果推送属性的掌握概率与相应位置的掌握概率值不一致则会被惩罚.  $P_3$  的取值范围为  $[0, 1]$ .  $P_3$  函数的建立依赖于规则 4.

$$P_4 = 2 \sum_{j=1}^{m-1} \left( \sum_{v=j+1}^m P_{iv} \right) / (m(m-1)),$$

$$P_{iv} = \begin{cases} 0, iv \in A_H, \\ 1, iv \notin A_H, \end{cases}$$

其中  $A_H$  表示蕴含属性层级关系的集合. 如果先后选取的属性符合属性层级关系, 则不会惩罚, 否则会惩罚.  $P_4$  的取值范围为  $[0, 1]$ . 如果先后选取的属性不符合层级关系的越多, 则  $P_4$  越大.  $P_4$  函数的建立依赖于规则 5.

$$P_5 = \sum_{j=1}^m P_{X_5} / m, P_{X_5} = \begin{cases} 0, P_{X_5} \in D_6, \\ 1, P_{X_5} \notin D_6. \end{cases}$$

$D_6 = \{((M_{T_j} = 1) \wedge (U_{MT_i} = 1)) \vee ((M_{T_j} = 2) \wedge (U_{MT_i} = 2)) \vee ((M_{T_j} = 3) \wedge (U_{MT_i} = 3)) \vee ((M_{T_j} = 4) \wedge (U_{MT_i} = 4))\}$ .

$D_6$  中的 1 ~ 4 分别代表音频、视频、文本和图像.  $M_{T_j}$  表示第  $j$  个材料的媒体类型;  $U_{MT_i}$  表示第  $i$  个学习者的媒体类型偏爱.  $P_5$  的取值范围为  $[0, 1]$ . 如果学习材料的媒体类型和学习者的偏好信息一致的情况越多, 则  $P_5$  越小.  $P_5$  函数的建立依赖于规则 6.

$$P_6 = \sum_{j=1}^m P_{X_6} / m, P_{X_6} = \begin{cases} 0, P_{X_6} \in D_7, \\ 1, P_{X_6} \notin D_7. \end{cases}$$

$D_7 = \{((C_{P_j} = 1) \wedge (U_{CP_i} = 1)) \vee ((C_{P_j} = 2) \wedge$

$(U_{CP_i} = 2)) \vee ((C_{P_j} = 3) \wedge (U_{CP_i} = 3)) \vee ((C_{P_j} = 4) \wedge (U_{CP_i} = 4))\}$ .

$D_7$  中的 1 ~ 4 分别代表例子、理论、解释和考试.  $C_{P_j}$  表示第  $j$  个材料的内容呈现;  $U_{CP_i}$  表示第  $i$  个学习者的内容呈现偏爱.  $P_6$  的取值范围为  $[0, 1]$ . 如果学习材料的内容呈现方式和学习者的偏好信息一致的情况越多, 则  $P_6$  越小.  $P_6$  函数的建立依赖于规则 7.

$$P_7 = \sum_{j=1}^m P_{X_7} / m, P_{X_7} = \begin{cases} 0, P_{X_7} \in D_8, \\ 1, P_{X_7} \notin D_8. \end{cases}$$

$D_8 = \{((B_{X_j} = 1) \wedge (U_{BX_i} = 1)) \vee ((B_{X_j} = 2) \wedge (U_{BX_i} = 2)) \vee ((B_{X_j} = 3) \wedge (U_{BX_i} = 3))\}$ .

$D_8$  中的 1 ~ 3 分别代表娱乐、生活和科学.  $B_{X_j}$  表示第  $j$  个材料的背景信息;  $U_{BX_i}$  表示第  $i$  个学习者的背景信息偏爱.  $P_7$  的取值范围为  $[0, 1]$ . 如果学习材料的背景信息和学习者的偏好信息一致的情况越多, 则惩罚的可能性越小.  $P_7 = 1$  表示推送的学习材料的背景信息和学习者的背景偏爱完全不匹配.  $P_7 = 0$  表示推送的学习材料的背景信息和学习者的背景偏爱完全匹配.  $P_7$  函数的建立依赖于规则 8.

$$P_8 = \begin{cases} \left( \sum_{j=1}^m L_{T_j} - U_{LT_i} \right) / \sum_{j=1}^m L_{T_j}, \sum_{j=1}^m L_{T_j} - U_{LT_i} > 0, \\ 0, \sum_{j=1}^m L_{T_j} - U_{LT_i} \leq 0. \end{cases}$$

$L_{T_j}$  表示学习第  $j$  个材料的时间;  $U_{LT_i}$  表示第  $i$  个学习者的学习时间(单位为 min).  $P_8$  的取值范围为  $[0, 1]$ . 如果学习材料的总学习时间小于学习者的学习时间, 则不会惩罚.

## 1.6 基于认知诊断的自适应学习材料推送算法

遗传算法由 J. Holland 等于 1975 年创立, 是一类借鉴生物界的进化规律(适者生存、优胜劣汰遗传机制)演化而来的随机搜索算法, 也是计算机科学、人工智能领域中用于解决最优问题的一种搜索启发式算法<sup>[13]</sup>. 在本研究中, 材料的选取方案可能有上亿种, 人工计算惩罚函数显然不合适. 遗传算法作为一种搜索启发式算法, 能够生成有效的解决方案来优化搜索问题. 在本研究中, 遗传算法的思路是: 首先, 随机选取一定数量的初始学习材料, 这些学习材料的惩罚值均较大, 说明这些学习材料不匹配学习者的特征; 然后, 通过遗传算子(选择、交叉、变异)对初始学习材料进行操作, 使这些学习材料的适应度值慢慢降低; 最后, 当达到指定的收敛精度或迭代次数后, 输出当前迭代中惩罚值最小的学习材料序列<sup>[14]</sup>, 这个学习材料序列就是学习者的学习序列. 遗传算法从本质上讲是一个群体迭代过程. 多

岛遗传算法的提出是为了增加样本的多样性,防止遗传算法过早收敛,它并没有额外增加种群的数量,而只是把种群再分成几个岛,在各个岛上分别进行传统遗传算法的计算,一个岛相当于一个“小生境”,对保持群体多样性有作用,但其主要目的是增加算法的多峰搜索能力<sup>[15]</sup>。

## 2 基于认知诊断的自适应学习材料智能推送算法的效果验证

为了验证开发的基于认知诊断自适应学习自动推送算法的科学性和有效性,采用 Monte Carlo 模拟研究的方法来验证的。

### 2.1 实验设计

研究模拟 1 000 个被试者,30 道题目,共测量 5 个属性,记为  $A_1$ 、 $A_2$ 、 $A_3$ 、 $A_4$  和  $A_5$ 。认知诊断模型采用 G-DINA 模型<sup>[16]</sup>。实验研究采用  $3 \times 2 \times 3$  的 3 因素实验设计。3 个自变量分别为材料推送算法、属性关系和每种属性的材料数。材料推送算法有 3 个水平,分别为遗传算法、多岛遗传算法和随机算法。随机算法是指随机选取一定数量的材料给学习者。属性关系有 2 个水平,分别为属性独立和属性不独立,有如图 1 所示的分支型属性关系。

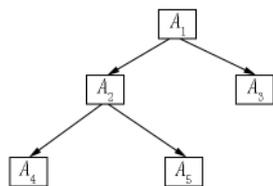


图 1 属性间的分支型关系

为了方便模拟研究,本次模拟研究将每个材料的学习时间分成 4 类水平,分别为 3、6、9 和 12 min。为了研究材料库的完备性对选取材料的影响,将每个属性下的材料数分为 3 种:64、128 和 192 个。64 和 128 个学习材料都是从 192 个学习材料中随机选取的。每个学习材料的特征和个人的偏好类型特征都是随机产生的。

### 2.2 诊断数据的生成

诊断数据的生成包括 2 个步骤:(i) 模拟学习者作答。本次模拟研究共有 30 道题目,采用的  $Q$  矩阵来自 R 语言中的 G-DINA 包<sup>[17]</sup>。模拟方法参考 Ma Wenchao 等<sup>[18]</sup>的做法, $P(0) = 0.2$ , $P(1) = 0.8$ , $P(1)$  表示掌握题目考察的所有属性的答对概率是 0.8, $P(0)$  表示被试没有掌握题目考察的任意属性而猜对的概率,而其他可能的属性模式答对概率从

均匀分布  $U(0.2, 0.8)$  中随机生成。基于以上的结果,可以模拟出所有学习者在 30 道题目上的作答情况。作答情况分 2 种:0(答错)和 1(答对)。(ii) 基于模拟作答、 $Q$  矩阵和 G-DINA 模型可以估计每个学习者的知识状态(KS)和 5 个属性的掌握概率。模拟结果如表 1 所示。

表 1 模拟研究的  $Q$  矩阵

题目序号	$A_1$	$A_2$	$A_3$	$A_4$	$A_5$
1	1	0	0	0	0
2	0	1	0	0	0
3	0	0	1	0	0
4	0	0	0	1	0
5	0	0	0	0	1
6	1	0	0	0	0
7	0	1	0	0	0
8	0	0	1	0	0
9	0	0	0	1	0
10	0	0	0	0	1
11	1	1	0	0	0
12	1	0	1	0	0
13	1	0	0	1	0
14	1	0	0	0	1
15	0	1	1	0	0
16	0	1	0	1	0
17	0	1	0	0	1
18	0	0	1	1	0
19	0	0	1	0	1
20	0	0	0	1	1
21	1	1	1	0	0
22	1	1	0	1	0
23	1	1	0	0	1
24	1	0	1	1	0
25	1	0	1	0	1
26	1	0	0	1	1
27	0	1	1	1	0
28	0	1	1	0	1
29	0	1	0	1	1
30	0	0	1	1	1

### 2.3 算法的参数设置

基于 Bian Cunling 等<sup>[19]</sup>和 L. Scrucca<sup>[20]</sup>的研究成果,本研究遗传算法的参数设置如下:(i) 个体编码方式采取 2 进制编码;(ii) 初始种群的数量设置为 100;(iii) 选择方法为精英策略,即每代中惩罚函数值最小的 5% 个体会直接复制到下一代;(iv) 交叉概率设置为 0.7;变异概率设置为 0.1;(v) 迭

代次数设置为 100; (vi) 多岛遗传算法的岛屿个数为 10 个,其余设置同遗传算法. 为了研究方便,在模拟研究中,将所有约束条件的权重设置为相等,即  $w_e = 1$ .

2.4 评价指标

在本次研究中采用了 4 个评价指标: 平均惩罚函数值、平均学习材料匹配的正确率、平均运行时间、平均惩罚函数值和迭代次数的关系图.

(i) 平均惩罚函数值( $M_F$ ):

$$M_F = \sum_{i=1}^N F_i / N,$$

其中  $N$  为总学习人数,  $F_i$  为第  $i$  个学习者的惩罚函数值(详见(1)式).  $M_F$  越小越好, 越小表示学习者和学习材料之间越匹配.

(ii) 平均学习材料匹配的正确率( $M_Z$ ):

$$M_Z = \sum_{i=1}^N m_i / (NM_i),$$

其中  $N$  为总学习人数,  $m_i$  为第  $i$  个学习者某项特征与材料之间正确匹配的次数,  $M_i$  表示第  $i$  个学习者某项特征与材料或者属性之间总的判断次数.  $M_Z$  越大越好, 越大表示学习者和学习材料之间越匹配.

(iii) 平均运行时间( $M_T$ ):

$$M_T = \sum_{i=1}^N t_i / N,$$

其中  $N$  为总学习人数,  $t_i$  为第  $i$  个学习者在使用某种算法选择学习材料时所花费的时间.  $M_T$  越小越好, 越小表示使用某种算法选择学习材料的时间越短. 程序的运行时间一般与正确率相结合使用.

2.5 实验结果

由表 2 可知: (i)  $M_F$  受到算法类型、属性间层级关系和每个属性下的材料数的影响. 多岛遗传算法得到的  $M_F$  最小, 遗传算法得到的  $M_F$  次之, 随机算法得到的  $M_F$  最大. 存在属性关系的认知诊断测验比不存在属性关系的认知诊断测验得到的  $M_F$  值小, 这说明属性之间存在一定的关系有助于学习者挑选合适的学习材料.  $M_F$  会随着每个属性下的材料

数增加而降低. (ii) 尽管随机算法比遗传算法和多岛遗传算法的运行时间要短得多, 但是遗传算法和多岛遗传算法挑选的材料序列比随机算法要更匹配学习者的特征, 且挑选时间均在 30 s 以下. 这说明在没有耗费大量时间的情况下, 遗传算法和多岛遗传算法可以较好地为每个学习者选择合适的学习材料.

表 2 6 组样本在 3 种算法情况下的平均惩罚函数值和算法使用时间

算法	层级关系	每个属性的材料数	$M_F$	$T/s$
遗传算法	独立	64	0.969 5	10.318 4
遗传算法	独立	128	0.787 5	12.874 0
遗传算法	独立	192	0.642 5	15.792 5
遗传算法	层级关系	64	0.846 9	10.322 7
遗传算法	层级关系	128	0.636 2	12.851 0
遗传算法	层级关系	192	0.501 1	15.640 0
多岛遗传算法	独立	64	0.741 3	21.930 1
多岛遗传算法	独立	128	0.595 8	26.701 4
多岛遗传算法	独立	192	0.498 6	30.834 1
多岛遗传算法	层级关系	64	0.638 9	19.331 4
多岛遗传算法	层级关系	128	0.435 4	25.462 0
多岛遗传算法	层级关系	192	0.377 0	29.443 6
随机算法	独立	64	4.472 9	0.000 7
随机算法	独立	128	4.478 4	0.000 7
随机算法	独立	192	4.437 7	0.000 7
随机算法	层级关系	64	4.687 1	0.000 6
随机算法	层级关系	128	4.705 4	0.000 6
随机算法	层级关系	192	4.758 8	0.000 6

由表 3 可知: (i) 用随机算法选择学习材料具有较大的盲目性, 无论认知特征(属性、难度、掌握概率和层级关系)还是非认知属性(媒体、内容、背景和时间)的正确率均远低于使用遗传算法和多岛遗传算法选择的材料. 与遗传算法相比, 多岛遗传算法能提高所选材料特征的正确率, 但是提高的幅度不高. (ii) 难度和掌握概率特征的正确率要低于其他特征, 这可能是因为难度和掌握概率是相互制约的关系. 当确定一组材料序列时, 这组材料的序列很难做到既满足难度的排序关系, 又满足掌握概率的排序关系.

表 3 3 种算法下的 6 组样本的学习材料正确率

属性	每个属性的材料数	项目	$A_1$	$A_2$	$A_3$
独立	64	属性	0.978 1	0.982 3	0.412 2
		难度	0.768 8	0.767 4	0.193 6
		掌握概率	0.756 3	0.767 7	0.197 9
		媒体	0.850 1	0.917 1	0.245 3
		内容	0.837 7	0.913 6	0.263 3
		背景	0.896 3	0.943 7	0.323 7
		时间	0.841 1	0.845 2	0.265 8

表 3(续)

属性	每个属性的材料数	项目	$A_1$	$A_2$	$A_3$
独立	128	属性	0.979 5	0.989 2	0.416 2
		难度	0.748 7	0.783 8	0.188 7
		掌握概率	0.743 9	0.787 3	0.200 0
		媒体	0.899 1	0.975 9	0.251 2
		内容	0.911 3	0.978 3	0.230 7
		背景	0.944 3	0.984 0	0.334 2
		时间	0.868 6	0.873 7	0.259 7
独立	192	属性	0.984 0	0.995 8	0.408 8
		难度	0.740 0	0.795 7	0.200 2
		掌握概率	0.743 7	0.788 5	0.196 9
		媒体	0.954 5	0.994 7	0.245 9
		内容	0.957 9	0.995 2	0.257 6
		背景	0.972 6	0.996 8	0.352 6
		时间	0.869 7	0.918 5	0.253 6
层级关系	64	属性	0.995 3	0.998 6	0.393 5
		难度	0.821 0	0.834 1	0.226 4
		掌握概率	0.802 4	0.831 8	0.224 5
		媒体	0.846 5	0.914 9	0.255 9
		内容	0.828 5	0.887 8	0.262 7
		背景	0.900 1	0.932 4	0.306 6
		时间	0.862 5	0.870 2	0.217 8
		层级关系	0.997 4	0.999 3	0.725 1
层级关系	128	属性	0.998 2	0.999 6	0.392 6
		难度	0.837 2	0.856 5	0.226 8
		掌握概率	0.799 1	0.811 5	0.223 4
		媒体	0.912 0	0.976 3	0.243 5
		内容	0.913 8	0.971 9	0.253 7
		背景	0.933 3	0.981 4	0.311 8
		时间	0.887 8	0.908 7	0.204 6
		层级关系	0.999 0	0.999 8	0.723 8
层级关系	192	属性	0.999 0	0.999 3	0.374 0
		难度	0.807 4	0.846 6	0.213 1
		掌握概率	0.808 1	0.844 0	0.203 1
		媒体	0.955 4	0.992 4	0.249 0
		内容	0.955 6	0.991 8	0.229 7
		背景	0.976 9	0.996 5	0.346 7
		时间	0.893 3	0.938 4	0.211 2
		层级关系	0.999 7	0.999 7	0.706 6

注:  $A_1$ 、 $A_2$  和  $A_3$  分别表示使用遗传算法、多岛遗传算法和随机算法下的平均学习材料正确率。

在图 2 ~ 图 7 中,横轴是迭代的次数,纵轴是平均惩罚函数值. 由图 2 ~ 图 7 可知: (i) 在设置迭代次数最高为 100 时,遗传算法和多岛遗传算法在 6 种情况下均会收敛,这说明 2 种算法是可行的. (ii) 无论在迭代次数为多少时,随机算法的平均惩罚函数值均高于遗传算法和多岛遗传算法. 这说明使用遗传算法最终选取出来的材料远比随机算法选出来的材料更符合学习者的特征. (iii) 在迭代前期,

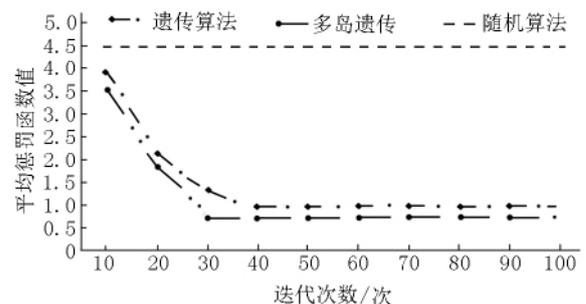


图 2 第 1 组的平均惩罚函数值的变化曲线

多岛遗传算法的  $M_F$  要高于遗传算法. 但是随着迭代次数的增加, 这 2 种算法的惩罚函数值差异越来越小. 多岛遗传算法达到稳定所需的迭代次数比遗传算法要少.

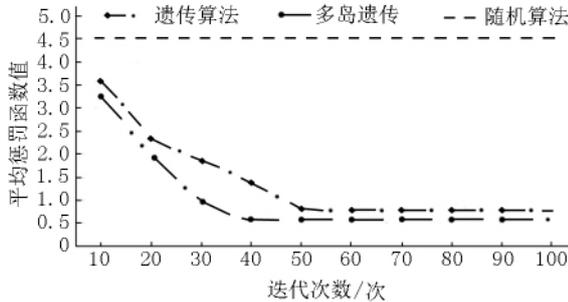


图3 第2组的平均惩罚函数值的变化曲线

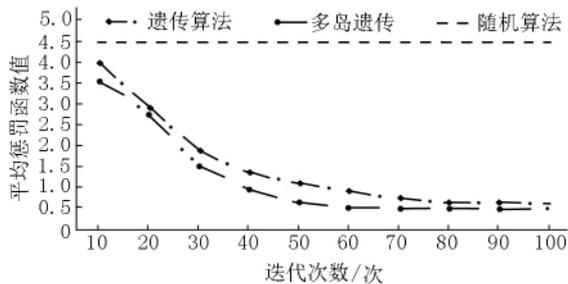


图4 第3组的平均惩罚函数值的变化曲线

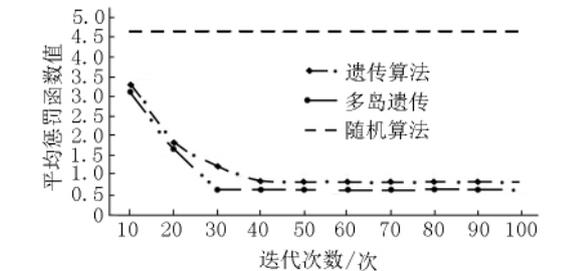


图5 第4组的平均惩罚函数值的变化曲线

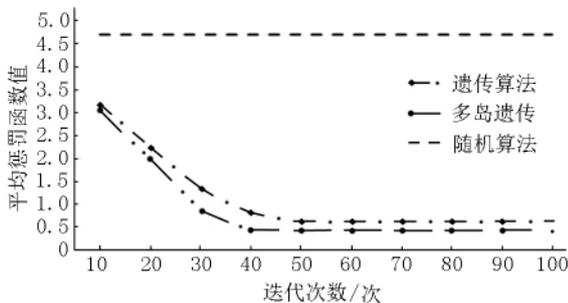


图6 第5组的平均惩罚函数值的变化曲线

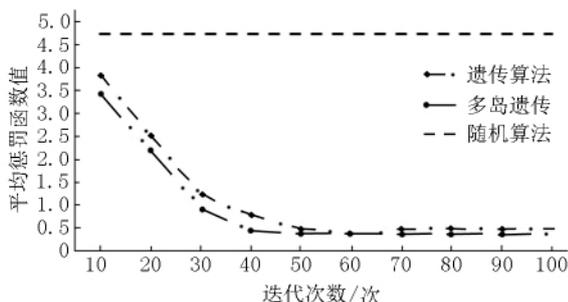


图7 第6组的平均惩罚函数值的变化曲线

### 3 结论与讨论

本文在认知诊断理论的基础上, 提出了自适应学习材料推送的思路与算法, 并使用了遗传算法和多岛遗传算法给每个学习者选择合适的学习材料. 研究表明: 基于认知诊断的自适应学习材料智能推送算法具有较理想的效果. 同随机算法相比较, 遗传算法和多岛遗传算法在学习材料匹配正确率和惩罚函数值等方面的表现均优于随机算法, 新提出的算法基本可行. 这一研究不仅丰富了认知诊断理论研究, 而且为自适应学习的发展提供了相关的技术与算法支持. 因时间、精力及文章篇幅所限, 基于认知诊断的自适应学习材料智能推送算法研究存在一些不足和需要改进的地方, 未来还需在以下几方面进一步探讨及深入:

1) 在本研究中使用的是遗传算法为每个学习者选择合适的学习材料. 虽然遗传算法是一种常用的搜索启发式算法, 但是在人工智能领域, 也存在很多其他更优秀的搜索启发式算法, 比如粒子群优化算法<sup>[21]</sup>和模拟退火搜索法<sup>[22]</sup>等. 在未来研究中, 可考虑使用其他的搜索算法来推送学习材料.

2) 在本研究中考虑的属性层级关系有 2 种: 独立型和分支型. 未来研究可以考虑其他类型的属性层级关系.

3) 遗传算法的参数设置关系到其精度、可靠性和计算时间等诸多因素, 并且影响到遗传结果的质量和系统的性能. 尽管本研究在前人研究的基础上将遗传算法的参数设置为: 初始种群有 100; 选择的方法为精英策略; 交叉概率设置为 0.7; 变异概率设置为 0.1; 迭代次数设置为 100. 但是在本文研究的基础上, 未来研究可以考虑探索更加合理的参数设置.

4) 在本研究中主要考察了 2 种特征: 认知特征和非认知特征. 认知特征包括属性、难度、掌握概率和层级关系. 非认知特征包括媒体、内容、背景和时间. 未来研究可以考虑加入其他的认知特征或者非认知特征.

5) 本研究使用模拟研究的方法来说明基于认知诊断的自适应学习材料智能推送算法的正确性. 为了研究更加严谨, 未来研究可考虑使用实证的方法. 在实证研究中, 可以将学习者随机分成 2 个组, 一组进行正常的教学, 另一组使用遗传算法提供学习材料. 学习完之后再进行测试, 通过测验分数来看基于遗传算法提供的学习材料是否比正常学习的效果更好.

## 4 参考文献

- [1] Yang Xiangdong, Embretson S E. Construct validity and cognitive diagnostic assessment [EB/OL]. [2019-06-16]. <https://smartech.gatech.edu/handle/1853/34250>.
- [2] 廖轶. 面向基础教育的自适应学习服务系统研究与应用 [D]. 北京: 北京交通大学, 2017.
- [3] 汪文义, 张华华. 统计测量视角下考试公平推动教育公平的对策 [J]. 江西师范大学学报: 自然科学版, 2017, 41(4): 383-393.
- [4] Chen Nianshing, Kinshuk, Wei Chunwan, et al. Mining e-learning domain concept map from academic articles [J]. Computers and Education, 2008, 50(3): 1000-1021.
- [5] 杨现民, 余胜泉. 学习元平台的语义技术架构及其应用 [J]. 现代远程教育研究, 2014(1): 89-99.
- [6] Peter Brusilovsky. Methods and techniques of adaptive hypermedia [J]. User Modeling and User-Adapted Interaction, 1996, 6(2/3): 87-129.
- [7] Zuo Xingquan, Zhang Guoxiang, Tan Wei. Self-adaptive learning PSO-based deadline constrained task scheduling for hybrid IaaS cloud [J]. IEEE Transactions on Automation Science and Engineering, 2014, 11(2): 564-573.
- [8] Ritz H, Nassar M R, Frank M J, et al. A control theoretic model of adaptive learning in dynamic environments [J]. Journal of Cognitive Neuroscience, 2018, 30(10): 1-17.
- [9] Wan Shanshan, Niu Zhendong. A learner oriented learning recommendation approach based on mixed concept mapping and immune algorithm [J]. Knowledge-Based Systems, 2016, 103: 28-40.
- [10] 涂冬波, 蔡艳, 戴海崎, 等. 现代测量理论下4大认知诊断模型述评 [J]. 心理学探新, 2008, 28(2): 64-68.
- [11] 原志强, 赵春艳. 2种改进的模拟退火算法求解大值域约束满足问题 [J]. 计算机应用研究, 2017, 34(12): 3611-3616.
- [12] 王兴华. 惩罚函数法的改进算法及应用研究 [D]. 秦皇岛: 燕山大学, 2009.
- [13] 李邈. 基于遗传规划和遗传算法的跨单元调度方法 [D]. 北京: 北京理工大学, 2016.
- [14] 张芳. 基于改进GA的模糊神经网络参数学习算法及其应用的研究 [D]. 长沙: 中南大学, 2007.
- [15] 潘福成, 郝博, 梁英, 等. 基于动态岛屿群体模型的并行遗传算法 [J]. 计算机工程, 2002, 28(10): 72-73.
- [16] Jimmy de la Torre. The generalized DINA model framework [J]. Psychometrika, 2011, 76(2): 179-199.
- [17] Torre J D L. The generalized DINA model framework [J]. Psychometrika, 2011, 76(2): 179-199.
- [18] Ma Wenchao, Jimmy Torre. A sequential cognitive diagnosis model for polytomous responses [J]. British Journal of Mathematical and Statistical Psychology, 2016, 69(3): 253-275.
- [19] Bian Cunling, Dong Shijun, Li Chunrong, et al. Generation of adaptive learning path based on concept map and immune algorithm [EB/OL]. [2019-06-16]. 10.1109/ICCSE.2017.8085526.
- [20] Scrucca L. GA: a package for genetic algorithms in R [J]. Journal of Statistical Software, 2013, 53(4): 1-37.
- [21] 韩红桂, 卢薇, 乔俊飞. 一种基于种群多样性的粒子群优化算法设计及应用 [J]. 信息与控制, 2017, 46(6): 677-684.
- [22] 汤伟, 胡祥满. 基于模拟退火算法的PID参数优化研究 [J]. 组合机床与自动化加工技术, 2018(4): 92-96, 101.

## The Material Recommendation System for Adaptive Learning Based on Cognitive Diagnosis

TU Dongbo, ZHANG Yong\*

(College of Psychology, Jiangxi Normal University, Nanchang Jiangxi 330022, China)

**Abstract:** Cognitive diagnosis and adaptive learning are combined, cognitive diagnosis method is used to diagnose learners' knowledge mastery, and then genetic algorithm or multi-island genetic algorithm is used to provide appropriate learning materials for each learner. The material recommendation system for adaptive learning based on cognitive diagnosis is built. In this paper, the Monte Carlo simulation experiment is used to investigate the effect of adaptive algorithm based on cognitive diagnosis. The research results show that the adaptive material recommendation algorithm based on cognitive diagnosis has an ideal effect. Learning materials selected by genetic algorithm and multi-island genetic algorithm have low penalty function value and high success rate. The selected materials based on genetic algorithm and multi-island genetic algorithm are more suitable for learners than the random algorithm.

**Key words:** cognitive diagnosis; adaptive learning; material recommendation; genetic algorithms; multi-island genetic algorithm

(责任编辑: 冉小晓)