

一种矩形邻域结构的教学优化算法

何杰光, 彭志平, 林伟豪, 崔得龙
(广东石油化工学院计算机学院, 广东茂名 525000)

摘 要: 为了克服原始教学优化算法在求解复杂多峰函数时全局寻优精度不高和过早收敛的缺点, 提出一种矩形邻域结构和个体扰动的教学优化算法. 算法将种群空间设计为矩形结构, 个体的矩形邻域由矩形厚度和围绕其的矩形区域个体决定, 教和学两个阶段都使用邻域最优个体引导搜索, 加强了算法勘探新解和开发局部最优解的能力; 为了防止算法过早陷入局部最优, 增加了基于搜索边界信息引导的个体扰动阶段, 使得种群即使在进化的后期仍能保持较好的多样性. 对带有偏移和旋转的复杂函数进行仿真测试, 结果表明新算法在求解精度和稳定性方面, 在绝大多数情况下优于原始教学算法和其他一些近来的优秀改进教学算法.

关键词: 教学优化算法; 矩形邻域结构; 邻域层数; 边界信息; 个体扰动; 种群多样性

中图分类号: TP 391 **文献标识码:** A **文章编号:** 0372-2112 (2019)08-1768-08

电子学报 URL: <http://www.ejournal.org.cn> **DOI:** 10.3969/j.issn.0372-2112.2019.08.022

A Teaching-Learning-Based Optimization Algorithm with Rectangle Neighborhood Structure

HE Jie-guang, PENG Zhi-ping, LIN Wei-hao, CUI De-long

(College of Computer, Guangdong University of Petrochemical Technology, Maoming, Guangdong 525000, China)

Abstract: A teaching-learning-based optimization algorithm with rectangle neighborhood structure (RNTLBO) is proposed to overcome the shortcomings of low global search precision and premature convergence of the original teaching-learning-based optimization algorithm (TLBO) while handling complex multimodal functions. In the algorithm, the population space is designed as a rectangular structure, and the individual rectangular neighborhood is determined by the rectangle thickness and the individual rectangular region surrounding it. In both teaching and learning stages, the optimal individual in the neighborhood is used to guide the search, which strengthens the ability of the algorithm to explore new solutions and exploit local optimal solutions. In order to prevent the algorithm from falling into the local optimum prematurely, the individual perturbation stage guided by search boundary information is added, so that the population can maintain good diversity even in the later evolution stage. The simulation results of complex functions with shift and rotation show that the new algorithm is superior to the original TLBO and some other recently improved variants in terms of accuracy and stability in most cases.

Key words: teaching-learning-based optimization (TLBO); rectangle neighborhood structure; layer number of neighborhood; boundary information; individual disturbance; population diversity

1 引言

Rao 等^[1]于 2011 年提出的教学优化算法 (Teaching-Learning-Based Optimization, TLBO) 通过模拟教师的教学和学员相互之间的学习实现种群的进化, 与传统的群智能优化算法相比, TLBO 具有参数少、结构简单、易于实现、求解速度快等优点, 因此该算法一经提出, 便

吸引了众多学者的关注. 随着学者们不断地深入研究, 该算法在冷热器优化^[2]、函数优化^[3,4]、机械设计优化^[5]、二次指派问题^[6]、图像检索^[7]等领域取得了广泛的应用.

与其他的群智能优化算法一样, TLBO 在求解高维多峰复杂问题时, 往往容易陷入局部最优, 算法的收敛速度和求解精度都不理想. 为了克服这些缺点, Rao 等

收稿日期: 2018-07-10; 修回日期: 2019-02-22; 责任编辑: 蓝红杰

基金项目: 国家自然科学基金 (No. 61772145, No. 61672174); 茂名市科技计划项目 (No. 2017287); 广东石油化工学院人才引进项目 (No. 2016rc02); 广东石油化工学院大学生创新创业训练计划项目 (No. 201811656057)

人^[8]提出基于精英替换策略的 ETLBO 算法,增强了算法的寻优能力. Zhang 等^[9]将单纯形算法的局部优化思想融入 TLBO,通过反射、扩展、收缩和缩减运算来迭代寻优,提高了算法的收敛精度. Patel^[10]提出一种用于求解 UF 和 CF 系列多目标优化问题的改进多目标教与学算法,该算法具有较强的竞争力. Chen 等^[11]将发现-搜索(PS)模型与 TLBO 相结合,有效降低了原始 TLBO 的计算成本,且取得了较好的求解效果. 毕晓君等人^[12]提出一种基于混合策略的自适应教学优化算法,该算法采用多方面因素综合交叉的学习策略和扰动策略,防止算法过早地陷入局部最优. Wang 等^[13]提出具有小世界邻域结构的教学优化算法,该算法采用小世界网络作为种群的空间结构关系,并基于反向学习算法来增强算法的开发能力,提高了算法的求解精度和全局收敛性. 童楠^[14]提出了一种基于反思的教学优化算法,即在教学和学习阶段都加入个体的反思机制,提高了算法的寻优性能. 毕晓君等^[15]在 TLBO 的学习阶段融合了差分进化算法的变异策略,并在进化后期加入了个体扰动,提高了算法的优化性能. Zou 等^[16]提出了一种基于局部学习和排斥学是习的教学优化算法,并在算法中加入结合历史信息的自学习方法和一定代数后的再分组操作.

基于上述文献可知:求解精度低、后期收敛速度慢、进化过程中极易陷入局部最优,仍然是 TLBO 以及大量改进 TLBO 存在的主要问题,即 TLBO 仍然存在较大的改进空间^[15]. 因此,本文提出一种具有矩形邻域结构的教学优化算法(TLBO with Rectangle Neighborhood, RN-TLBO). 在改进算法中,种群的个体随机分布在一个矩形内,个体的矩形邻域由围绕其的矩形区域个体组成. 在教学和学习阶段使用了邻域最优学习策略和多层矩形邻域结构,加强了算法勘探新解和开发局部最优解的能力. 此外,在教与学的基础上,还增加了基于搜索边界信息的个体扰动阶段,提高了算法在进化后期跳出局部最优的能力. 仿真实验表明, RNTLBO 算法在求解精度和稳定性方面,在绝大多数情况下优于原始 TLBO 和其他一些近来的优秀改进 TLBO 算法,但新算法由于利用多层邻域结构来提高求解精度,增加了算法的空间复杂性,所以运行时间有所增加.

2 教学优化算法

原始教学优化算法以班级为单位,模拟传统课堂教学中教师教学和学生学习的两个阶段来搜索问题的最优解.

2.1 教学阶段

在任意第 t 次迭代中,教师通过教学提高全班的平均成绩,使全班的平均成绩接近于教师的水平,从而向

最优解方向搜索. 教师即为种群中的最优个体,教师采用如下公式实现教学过程.

$$\mathbf{X}_i^{\text{New}} = \mathbf{X}_i + r_i \cdot (\mathbf{X}_{\text{Teacher}} - T_F \cdot \mathbf{X}_{\text{Mean}}) \quad (1)$$

$$T_F = \text{round}(1 + \text{rand}(0, 1)) \quad (2)$$

$$\mathbf{X}_{\text{Mean}} = \frac{1}{N} \sum_{i=1}^N \mathbf{X}_i \quad (3)$$

式中, $\mathbf{X}_i = (x_{i1}, x_{i2}, \dots, x_{iD})$ 表示班级中的任一学生 (D 为决策变量的维度), r_i 为 $[0, 1]$ 之间的随机数, N 为种群规模, $\mathbf{X}_{\text{Teacher}}$ 表示教师个体, $\mathbf{X}_{\text{Mean}}$ 表示班级的均值个体, T_F 为教学因子, round 表示四舍五入取整. 若 $\mathbf{X}_i^{\text{New}}$ 优于 $\mathbf{X}_i$, 则更新 $\mathbf{X}_i$, 即 $\mathbf{X}_i = \mathbf{X}_i^{\text{New}}$.

2.2 学习阶段

学习阶段即为学生相互学习的过程,学生 $\mathbf{X}_i$ 随机向班级中的一个学生 $\mathbf{X}_j$ 学习,学习方式如式(4)所示.

$$\mathbf{X}_i^{\text{New}} = \begin{cases} \mathbf{X}_i + r_i \cdot (\mathbf{X}_i - \mathbf{X}_j), & f(\mathbf{X}_i) < f(\mathbf{X}_j) \\ \mathbf{X}_i + r_i \cdot (\mathbf{X}_j - \mathbf{X}_i), & f(\mathbf{X}_i) > f(\mathbf{X}_j) \end{cases} \quad (4)$$

式中, $f(\mathbf{X}_i)$ 为优化问题的目标函数值,学习步长 r_i 为 $[0, 1]$ 之间的随机数. 若 $\mathbf{X}_i^{\text{New}}$ 优于 $\mathbf{X}_i$, 则更新 $\mathbf{X}_i$, 即 $\mathbf{X}_i = \mathbf{X}_i^{\text{New}}$.

3 具有矩形邻域结构的教学优化算法

为了提高 TLBO 算法的寻优能力,除了要保持种群的多样性外,还应增强个体对邻域的搜索能力. 在实际的学习环境中,学生通常会优先向其座位周围的同学学习,并向其中的优秀者请教问题,然后在问题解决不了的情况下,才向其他同学或者教师请教. 基于此启发,本文提出一种基于矩形邻域的种群空间结构,种群中的个体被随机置于矩形的任一位置,个体的矩形邻域由邻域厚度和围绕其的矩形区域个体决定,个体邻域的最优个体是其教学阶段的教师和学习阶段的学习对象,从而保证种群向局部最优解方向进化,但又避免过早向全局最优解趋同. 此外,在算法每次迭代后或个体有更优解产生时,都对矩形结构进行更新,这使得优秀的个体能在种群中扩散,最终实现整个种群向全局最优解收敛.

图 1 是一个种群规模为 50 的矩形邻域结构示意图. 矩形的长 Length 为 10, 宽 Width 为 5, 编号为 45 的个体的矩形邻域为个体 32、11、4; 编号为 23 的个体的矩形

45	32	10	46	21	14	5	9	12	22
11	4	29	36	47	43	40	26	17	3
15	37	27	16	35	20	34	23	1	2
30	38	24	13	0	42	6	41	49	31
44	48	18	7	25	28	39	33	8	19

图1 矩形邻域结构

邻域为 40、26、17、1、49、41、6、34、40。

3.1 多层矩形邻域结构设计

对于单层的邻域结构,虽然可以很好地保持种群在整个进化过程中的多样性,增加个体跳出局部最优的概率,但过大的多样性,却又会破坏个体的局部搜索能力,在算法迭代次数有限的情况下,最终反而会降低算法的求解精度。因此,为了使种群的全局信息能够有效地传递,提高算法的收敛速度,保持矩形邻域之间的搜索性能,在 RNTLBO 算法中加入多层矩形邻域结构,通过设置合适的邻域厚度(层数),平衡算法的全局搜索和局部开发能力。这是因为合适的邻域层数可有效地控制不同邻域间的重叠范围(相同个体的数量),从而控制种群的多样性(邻域重叠范围越小,种群多样性越好,越有利于全局搜索,但不利于局部搜索),最终有效平衡算法的全局搜索和局部开发能力。大量的仿真实验结果表明,矩形邻域层数 Level = 3 时, RNTLBO 能很好地平衡算法的全局搜索能力和局部开发能力、算法的收敛精度和收敛速度,因此,本文的所有实验测试中,矩形邻域层数 Level 的值设置为 3。

一个多层矩形邻域结构的示例如图 2 所示。

45	32	10	46	21	14	5	9	12	22
11	4	29	36	47	43	40	26	17	3
15	37	27	16	35	20	34	23	1	2
30	38	24	13	0	42	6	41	49	31
44	48	18	7	25	28	39	33	8	19

图2 多层矩形邻域结构

在图 2 所示的多层矩形邻域结构中,编号 45 的个体的一层邻域为 32、11、4;两层邻域为 32、10、11、4、29、15、37、27。此外,对于编号为 35 和 23 的个体来说,当 Level = 1 时,两者的邻域不会重叠,但当 Level = 2 时,则出现了第 6、7 列的个体重叠(图中的斜线阴影部分,35 号个体和 45 号个体的邻域也有类似情况),这样会大大增加两个邻域中最优个体相同的概率。

3.2 基于矩形邻域结构的教学阶段

基于矩形邻域结构,提出一种基于邻域最优的教学阶段,该过程由如下公式实现。

$$X_i^{\text{New}} = X_i + r_i \cdot (X_{\text{Teacher}}^{\text{NB}} - T_F \cdot X_{\text{Mean}}^{\text{NB}}) \quad (5)$$

$$X_{\text{Mean}}^{\text{NB}} = \frac{1}{\text{Size} + 1} \sum_{j=1}^{\text{Size}+1} X_j \quad (6)$$

式中, $X_{\text{Teacher}}^{\text{NB}}$ 表示 X_i 的邻域最优个体,即教师, $X_{\text{Mean}}^{\text{NB}}$ 表示 X_i 的邻域均值个体, Size 为 X_i 的邻域个体数量, X_j 表示邻域内的个体,包括 X_i 。若 X_i^{New} 优于 X_i , 则更新 X_i , 即 $X_i = X_i^{\text{New}}$ 。

在原始 TLBO 算法中,教师 X_{Teacher} 为全局最优个体,侧重于提高全班的整体成绩,即一次迭代中仅有一个教师,这极大地限制了教师个体所形成的搜索空间。而在 RNTLBO 算法中,每个个体的教师可能均不相同(因为每个个体的矩形邻域都不同),且非当前种群的最优解,因此基于邻域最优的教学阶段保证了算法的全局搜索的性能。另外,在更新 X_i 的同时,对矩形进行更新,从而更新种群中每个个体的邻域,这使得更新后的优秀个体能够随机地分布,进而保证种群的多样性,且有利于增强个体的局部开发能力,找到更多的局部最优解。

3.3 基于矩形邻域结构的学习阶段

基于矩形邻域结构,提出一种基于邻域最优的混合学习策略,即矩形邻域中的学生不仅相互学习,也向邻域中最优秀的学生学习,该过程由如下公式实现。

$$X_i^{\text{New_R}} = \begin{cases} X_i + r_i \cdot (X_i - X_j), f(X_i) < f(X_j) \\ X_i + r_i \cdot (X_j - X_i), f(X_i) > f(X_j) \end{cases} \quad (7)$$

$$X_i^{\text{New_NB}} = \begin{cases} X_i^{\text{New_R}} + r_i \cdot (X_i^{\text{New_R}} - X_{\text{Best}}^{\text{NB}}), \\ f(X_i^{\text{New_R}}) < f(X_{\text{Best}}^{\text{NB}}) \\ X_i^{\text{New_R}} + r_i \cdot (X_{\text{Best}}^{\text{NB}} - X_i^{\text{New_R}}), \\ f(X_i^{\text{New_R}}) > f(X_{\text{Best}}^{\text{NB}}) \end{cases} \quad (8)$$

式中, X_j 表示 X_i 邻域中的随机个体, $X_i^{\text{New_R}}$ 表示经过随机学习后的新个体, $X_{\text{Best}}^{\text{NB}}$ 表示 X_i 邻域中的最优个体, $X_i^{\text{New_NB}}$ 表示经过邻域最优学习后的新个体。若 $X_i^{\text{New_NB}}$ 优于 X_i , 则更新 X_i , 即 $X_i = X_i^{\text{New_NB}}$ 。

3.4 个体扰动阶段

为了增加种群的多样性,跳出局部最优,本文提出一种基于搜索边界信息的个体扰动方式,可由式(10)实现。

$$X_i^{\text{New}} = \begin{cases} X_i + r \cdot (X_i - L), r < 0 \\ X_i + r \cdot (U - X_i), r > 0 \end{cases} \quad (9)$$

式中, r 为 $[-1, 1]$ 的随机数, L 为各维变量下界构成的向量, $L = (l_1, l_2, \dots, l_D)$, U 为各维变量上界构成的向量, $U = (u_1, u_2, \dots, u_D)$ 。

3.5 RNTLBO 算法实现流程

RNTLBO 算法的实现流程如图 3 所示。

4 仿真结果及其分析

4.1 测试环境与参数设置

RNTLBO 使用 Java 编程实现,测试机 CPU 主频为 3.1GHz,内存为 8GB,操作系统为 Windows 7。为了验证算法的有效性,本文选择较为复杂的函数(经过偏移和旋转后的函数,选至 CEC2005 Benchmark 函数)进行测试。




图3 RNTLBO算法流程图

试^[17], 如表 1 所示. 这 10 个函数可分为四类: (1) 偏移函数 (shifted) $f_1 \sim f_3$; (2) 偏移和旋转函数 (shifted rotated) $f_4 \sim f_7$; (3) 扩展函数 (expanded) f_8 ; (4) 混合组合函数 (hybrid composition) $f_9 \sim f_{10}$. 此外, 除了 f_1 是单峰函数外, 其余函数都是多峰函数. 因此, 这 10 个函数可以全面地测试各个算法的优化性能.

表 1 测试函数

函数	范围	最优函数值
f_1 (偏移 Sphere 函数)	$[-100, 100]$	-450
f_2 (偏移 Rosenbrock)	$[-100, 100]$	390
f_3 (偏移 Rastrigin 函数)	$[-5, 5]$	-330
f_4 (无边界偏移旋转 Griewank 函数)	$[0, 600]$	-180
f_5 (偏移旋转 Rastrigin 函数)	$[-5, 5]$	-330
f_6 (偏移旋转 Weierstrass 函数)	$[-0.5, 0.5]$	90
f_7 (最优解在边界的偏移旋转 Ackley 函数)	$[-500, 500]$	-140
f_8 (偏移旋转的扩展 Scaffe F6 函数)	$[-100, 100]$	-300
f_9 (函数值带噪音的旋转混合组合函数)	$[-5, 5]$	120
f_{10} (旋转混合组合函数)	$[-5, 5]$	260

选择原始 TLBO 算法、RTLBO 算法^[14]、DSTLBO 算法^[15]和 DRLTLBO 算法^[16]进行比较分析. 在所有的函数测试中, 算法的种群大小 N 均设置为 50, 本文的 RNTLBO 算法的参数 $\text{Length} = 10$, $\text{Width} = 5$, $\text{Level} = 3$, 其他所有对比算法的参数设置均与文献中的相同. 各个算法采用函数评价次数^[16] (Function Evaluations, FEs) 作为其终止条件, 即最大 FEs (maxFEs) 设置为 100000, 对于 RNTLBO, 则相当于最大迭代次数 $T_{\max} = 666$.

4.2 RNTLBO 算法性能验证

使用上述的 RNTLBO 算法、TLBO 算法、RTLBO 算法、DSTLBO 算法、DRLTLBO 算法分别对每个测试函数独立运行 20 次, 将求得平均值 (为所求的函数值与最优值的偏差 $f(\mathbf{X}) - f(\mathbf{X}^*)$ 的均值, 标准差也按该偏差计算), 标准差和平均运行时间列于表 2 ($D = 50$)、表 3 ($D = 100$) 中, 并绘制出算法的平均收敛曲线图 $D = 50$), 如图 4 所示.

为了更加便于对比 RNTLBO 与其他算法的求解性能优劣, 根据表 2 和表 3 统计 RNTLBO 相对其他算法在收敛精度和运行时间上的平均改变量, 如表 4 所示 (+ 表示增加, - 表示减少).

表 2 收敛精度结果对比 ($D = 50$)

函数	算法	均值	标准差	运行时间 (s)	函数	算法	均值	标准差	运行时间 (s)
f_1	TLBO	0.01	0.02	6.037	f_6	TLBO	72.07	2.76	150.568
	RTLBO	0.00	0.00	6.674		RTLBO	74.20	0.94	151.820
	DSTLBO	3.57	10.65	6.281		DSTLBO	65.72	7.33	151.050
	DRLTLBO	7.08E-19	9.80E-19	6.637		DRLTLBO	56.31	16.10	152.208
	RNTLBO	1.35E-24	2.28E-24	7.715		RNTLBO	39.55	11.33	153.258
f_2	TLBO	2617.54	4380.33	5.224	f_7	TLBO	21.19	0.02	114.406
	RTLBO	4434.84	4718.34	6.116		RTLBO	21.19	0.02	115.525
	DSTLBO	6152.21	11184.59	5.765		DSTLBO	21.19	0.04	114.805
	DRLTLBO	153.70	108.57	5.910		DRLTLBO	21.18	0.04	121.063
	RNTLBO	102.12	49.84	7.895		RNTLBO	21.18	0.04	118.360

续表

函数	算法	均值	标准差	运行时间(s)	函数	算法	均值	标准差	运行时间(s)
f_3	TLBO	222.98	23.20	6.082	f_8	TLBO	22.78	0.20	113.835
	RTLBO	224.96	19.85	6.370		RTLBO	23.16	0.17	118.524
	DSTLBO	234.37	27.37	6.008		DSTLBO	22.87	0.26	118.092
	DRLTLBO	239.38	126.22	6.139		DRLTLBO	22.79	0.19	123.327
	RNTLBO	145.36	79.83	7.555		RNTLBO	22.54	0.23	122.997
f_4	TLBO	6195.32	0.00	118.522	f_9	TLBO	352.61	96.78	1259.755
	RTLBO	6203.24	8.84	119.991		RTLBO	344.81	73.22	1261.722
	DSTLBO	6195.62	0.62	122.743		DSTLBO	290.89	80.33	1278.592
	DRLTLBO	6195.32	0.00	124.184		DRLTLBO	306.23	20.89	1272.070
	RNTLBO	6195.32	0.00	120.344		RNTLBO	258.32	61.26	1269.458
f_5	TLBO	284.82	44.60	120.046	f_{10}	TLBO	1246.35	16.50	1160.991
	RTLBO	358.15	39.32	122.505		RTLBO	1281.40	16.17	1179.652
	DSTLBO	335.47	80.27	121.699		DSTLBO	1274.95	21.21	1169.648
	DRLTLBO	386.52	77.60	126.850		DRLTLBO	756.89	479.16	1190.723
	RNTLBO	237.01	113.78	122.215		RNTLBO	592.48	480.95	1185.257

表 3 收敛精度结果对比 ($D=100$)

函数	算法	均值	标准差	运行时间(s)	函数	算法	均值	标准差	运行时间(s)
f_1	TLBO	2449.47	1871.96	6.758	f_6	TLBO	161.22	1.13	212.241
	RTLBO	267.02	112.40	7.280		RTLBO	163.62	1.66	212.814
	DSTLBO	3594.31	1878.46	6.982		DSTLBO	144.79	11.23	212.668
	DRLTLBO	4.80E-04	6.80E-04	7.226		DRLTLBO	141.59	25.88	219.552
	RNTLBO	3.16E-06	2.80E-06	8.534		RNTLBO	105.22	8.38	213.143
f_2	TLBO	9.95E+07	1.26E+08	6.446	f_7	TLBO	21.36	0.02	145.142
	RTLBO	5.99E+07	3.35E+07	6.811		RTLBO	21.36	0.04	145.309
	DSTLBO	4.10E+08	3.46E+08	6.617		DSTLBO	21.36	0.03	149.625
	DRLTLBO	421.14	123.75	6.983		DRLTLBO	21.36	0.03	148.394
	RNTLBO	343.80	53.72	7.943		RNTLBO	21.36	0.02	148.212
f_3	TLBO	588.40	33.60	7.030	f_8	TLBO	47.58	0.16	142.127
	RTLBO	556.32	36.60	7.122		RTLBO	47.93	0.16	142.325
	DSTLBO	586.31	45.80	7.219		DSTLBO	47.43	0.19	150.686
	DRLTLBO	327.65	89.83	7.076		DRLTLBO	47.28	0.28	147.659
	RNTLBO	296.35	75.84	8.403		RNTLBO	47.27	0.13	147.061
f_4	TLBO	11640.80	11.57	141.336	f_9	TLBO	358.52	29.55	1568.143
	RTLBO	11673.45	11.21	141.627		RTLBO	388.24	42.63	1587.997
	DSTLBO	11652.04	7.60	145.677		DSTLBO	352.79	35.78	1706.493
	DRLTLBO	11638.76	4.47	145.509		DRLTLBO	332.92	20.05	1804.929
	RNTLBO	11636.71	1.26	144.775		RNTLBO	295.84	50.79	1667.443

续表

函数	算法	均值	标准差	运行时间(s)	函数	算法	均值	标准差	运行时间(s)
f_5	TLBO	795.19	144.77	140.779	f_{10}	TLBO	1356.78	16.74	1460.842
	RTLBO	1042.97	102.35	141.162		RTLBO	1361.27	17.30	1468.084
	DSTLBO	1085.20	164.46	145.231		DSTLBO	1337.94	21.97	1699.972
	DRLTLBO	479.21	177.95	146.324		DRLTLBO	1294.02	17.79	1676.050
	RNTLBO	450.72	72.28	146.064		RNTLBO	1286.32	7.98	1539.672




图4 各算法的收敛曲线 (D=50)

表 4 RNTLBO 相对其他算法在收敛精度和运行时间上的平均改变量

	VS. TLBO		VS. RTLBO		VS. DSTLBO		VS. DRLTLBO	
	精度(%)	时间(s)	精度(%)	时间(s)	精度(%)	时间(s)	精度(%)	时间(s)
$D = 50$	+37.32%	+5.96	+39.53%	+2.62	+37.17%	+2.04	+27.98%	-1.41
$D = 100$	+35.11%	+20.04	+37.02%	+17.07	+35.57%	-19.20	+17.07%	-27.85

从以上的测试结果可以看出,不管是中维度($D = 50$)还是高维度($D = 100$)的复杂测试函数,RNTLBO 都表现出很好的竞争性,其收敛精度不劣于(绝大多数情况下都优于)其他 4 种算法,且大部分情况下稳定性也更好,但收敛速度在 $FEs < 50000$ 时较慢(有时劣于其他 4 种算法),在 $FEs > 50000$ 时,则优于其他 4 种算法。而在算法的运行时间方面(表 4),测试函数为 50 维时,RNTLBO 的运行时间比 TLBO、RTLBO 和 DSTLBO 平均稍有增加,而比 DRLTLBO 则有所减少;测试函数为 100 维时,RNTLBO 的运行时间比 TLBO 和 RTLBO 都增加较多,但相对 DSTLBO 和 DRLTLBO 则减少较多。具体变现为(表 2 和表 3),在求解 $f_4 \sim f_{10}$ 函数时,RNTLBO 的运行时间少于 DRLTLBO,在求解 $f_7 \sim f_{10}$ 函数时,RNTLBO 的运行时间也少于 DSTLBO。

5 结束语

本文提出了具有矩形邻域结构的教师优化算法(RNTLBO)。算法将多层矩形作为种群的空间结构关系,种群中的个体选择其矩形邻域的最优个体作为教师和学习对象,通过不断地更新矩形,平衡算法的全局搜索能力和局部开发能力。此外,为了有效地增加种群的多样性,使算法在后期仍有机会找到更好的解,在算法中加入了基于搜索边界信息的个体扰动操作。仿真实验表明,RNTLBO 在求解精度和稳定性方面,在绝大多数情况下优于原始 TLBO 和其他一些近来的优秀改进 TLBO 算法。但多层邻域结构的使用却增加了算法的空间复杂性,所以 RNTLBO 的运行时间有所增加。因此,RNTLBO 更适用于对求解精度要求高,而对运行时间要求并不苛刻的情况。下一步的工作将研究 RNTLBO 矩形邻域结构元素的其他选择方法。

参考文献

- [1] RAO R V, SAVSANI V J, VAKHARIA D P. Teaching-learning-based optimization: a novel method for constrained mechanical design optimization problem[J]. Computer-aided Design, 2011, 43(3): 303-315.
- [2] RAO R V, PATEL V. Multi-objective optimization of two stage thermoelectric cooler using a modified teaching-learning-based optimization algorithm[J]. Engineering Applications of Artificial Intelligence, 2013, 26(1): 430-445.
- [3] RAO R V, SAVSANI V J, VAKHARIA D P. Teaching-learning-based optimization: an optimization method for continuous non-linear large scale problems[J]. Information Sciences, 2012, 183(1): 1-15.
- [4] RAO R V, SAVSANI V J, VAKHARIA D P. Teaching-learning-based optimization algorithm for unconstrained and constrained real-parameter optimization problems[J]. Engineering Optimization, 2011, 44(12): 1447-1462.
- [5] RAO R V, SAVSANI V J, VAKHARIA D P. Teaching-learning based optimization: a novel method for constrained mechanical design optimization problems[J]. Computer Aided Design, 2011, 43(3): 303-315.
- [6] DOKEROGLU T. Hybrid teaching-learning-based optimization algorithms for the quadratic assignment problem[J]. Computers & Industrial Engineering, 2015, 85: 86-101.
- [7] 毕晓君, 潘铁文. 基于教与学优化算法的相关反馈图像检索[J]. 电子学报, 2017, 45(07): 1668-1676.
BI Xiao-jun, PAN Tie-wen. Relevance feedback image retrieval based on teaching-learning-based optimization algorithm[J]. Acta Electronica Sinica, 2017, 45(07): 1668-1676. (in Chinese)
- [8] RAO R V, PATEL V. An elitist teaching-learning-based optimization algorithm for solving complex constrained optimization problems[J]. International Journal of Industrial Engineering Computations, 2012, 3(4): 535-560.
- [9] ZHANG H, LI B, ZHANG J, et al. Parameter estimation of nonlinear chaotic system by improved TLBO strategy[J]. Soft Computing, 2016, 20(12): 4965-4980.
- [10] PATEL V K, SAVSANI V J. A multi-objective improved teaching-learning based optimization algorithm (MO-ITLBO)[J]. Information Sciences, 2014, 257: 182-200.
- [11] CHEN D B, ZOU F, WANG J, et al. A teaching-learning-based optimization algorithm with producer-scrounger model for global optimization[J]. Soft Computing, 2015, 19(3): 745-762.
- [12] 毕晓君, 李月, 陈春雨. 基于混合策略的自适应教与学优化算法[J]. 哈尔滨工程大学学报, 2016, 37(6): 842-848.
BI Xiao-jun, LI Yue, CHEN Chun-yu. A self-adaptive teaching-and-learning-based optimization algorithm with a mixed strategy[J]. Journal of Harbin Engineering University, 2016, 37(6): 842-848. (in Chinese)
- [13] WANG P C, MAY, GENG M Y, et al. New teaching-learning-based optimization with neighborhood structure

- based on small world[J]. Journal of Frontiers of Computer Science and Technology, 2016, 10(9): 1341 – 1350.
- [14] 童楠, 符强, 钟才明. 一种基于反思机制的教与学优化算法[J]. 计算机应用研究, 2018, 35(12): 3678 – 3681. TONG Nan, FU Qiang, ZHONG Cai-ming. Improved TL-BO algorithm based on reflection mechanism[J]. Application Research of Computers, 2018, 35(12): 3678 – 3681. (in Chinese)
- [15] 毕晓君, 王佳荟. 基于混合学习策略的教与学优化算法[J]. 浙江大学学报: 工学版, 2017, 51(5): 1024 – 1031. BI Xiao-jun, WANG Jia-hui. Teaching-learning-based optimization algorithm with hybrid learning strategy[J]. Journal of Zhejiang University (Engineering Science), 2017, 51(5): 1024 – 1031. (in Chinese)
- [16] ZOU F, CHEN D, LU R, et al. Teaching-learning-based optimization with differential and repulsion learning for global optimization and nonlinear modeling[J]. Soft Computing, 2018, 22(21): 7177 – 7205.
- [17] SUGANTHAN P N, HANSEN N, LIANG J J, et al. Problem Definitions and Evaluation Criteria for the CEC 2005 Special Session on Real-Parameter Optimization[R]. Singapore: Nanyang Technological University, 2005.

作者简介



何杰光 男, 1981 年生于广东茂名. 博士, 讲师. 主要研究方向为云计算、智能优化算法和项目调度.
E-mail: hubice@163.com



彭志平 男, 1969 年生于福建泉州. 博士, 教授. 主要研究方向为云计算、机器学习和多 agent 技术.