

DOI: 10.7652/xjtuxb201609016

多目标车辆路径问题的粒子群优化算法研究

郭森¹, 秦贵和^{1,2}, 张晋东¹, 于赫¹, 卢政宇¹, 于佳欣³

(1. 吉林大学计算机科学与技术学院, 130012, 长春; 2. 吉林大学符号计算与知识工程教育部重点实验室, 130012, 长春; 3. 吉林大学软件学院, 130012, 长春)

摘要: 针对粒子群算法(PSO)及其变种在约束多目标等复杂问题优化过程中所遇到的易陷入局部最优和收敛性问题,提出了一种基于动态学习和突变因子的粒子群算法(DSPSO)。首先,通过分析粒子群群体的学习机制,采用动态的学习策略,使粒子自适应动态调整认知成分和社会成分在迭代更新中的权重,以引导自身向最优解的方向探索,有效改善了群体的收敛速度;其次,通过引入阶梯突变因子的概念,使粒子在陷入局部最优时进行试探跳跃,阶梯突变赋予粒子突破更新步长限制的能力,使粒子在当前位置速度矢量方向上的二维空间邻域内进行试探寻优,当发现更优解时则跳出当前局部最优;最后,通过在 BenchMark 基准函数测试集中典型函数上的实验,证明了 DSPSO 的求解精度和收敛速度均优于对比算法。在多目标车辆路径问题实例优化中,解的可接受率和成功率分别为 0.91 和 0.66,远优于对比算法中最优解的 0.16 和 0.11,体现了所提改进算法在车辆路径问题中的优越性。

关键词: 车辆路径问题;多目标优化;粒子群

中图分类号: TP273 **文献标志码:** A **文章编号:** 0253-987X(2016)09-0097-08

A Novel Particle Swarm Optimization for Multi-Objective Vehicle Routing Problem

GUO Sen¹, QIN Guihe^{1,2}, ZHANG Jindong¹, YU He¹, LU Zhengyu¹, YU Jiaxin³

(1. College of Computer Science and Technology, Jilin University, Changchun 130012, China; 2. Symbol Computation and Knowledge Engineer of Ministry of Education, Jilin University, Changchun 130012, China; 3. College of Software, Jilin University, Changchun 130012, China)

Abstract: Considering the problems that particle swarm optimization (PSO) algorithm and its variants are easily to fall into local optimal solutions and convergence in the optimization process of complex constrained multi-objective problem, a novel PSO based on dynamic learning strategy and mutation factor (DSPSO) is proposed. First, through analyzing the learning mechanism of particle swarm, DSPSO introduces the dynamic learning strategy, enabling particles to adaptively adjust the weights of cognitive component and social component in the iteration renewal process and guide themselves to explore in the optimal direction, hence effectively accelerating the convergence rate. Second, by introducing the ladder mutation factor, when the particles are trapped in a local optimum, they are enabled to break the limit of update-step size to make tentative jumps in the two-dimensional spatial neighborhood of the velocity vector direction.

收稿日期: 2016-01-01。 作者简介: 郭森(1991—),男,硕士生;秦贵和(通信作者),男,教授,博士生导师。 基金项目: 国家自然科学基金资助项目(51205154);吉林省科技发展计划资助项目(20140520073JH);吉林省重点科技攻关资助项目(2015020434);中央大学基础研究基金资助项目(JCKY-QKJC14)。

网络出版时间: 2016-07-14 网络出版地址: <http://www.cnki.net/kcms/detail/61.1069.T.20160714.1117.004.html>

When a better solution is found, the optimal solution would be updated. Finally, experiments are conducted on the typical functions of BenchMark, and the results show that the accuracy and convergence rate of DSPSO are better than the contrast algorithms. In the multi-objective vehicle routing problem optimization, the acceptable and success rates of the DSPSO solutions are 0.91 and 0.66, respectively, far outperform the results of 0.16 and 0.11 by comparison algorithm, reflecting the superiority of DSPSO in the multi-objective vehicle routing problem.

Keywords: vehicle routing problem; multi-objective optimization; particle swarm optimization

基于群体行为的群体智能算法由于在多向性和全局性等层面的优越性,使其对 Pareto 非支配解集前沿的形状和连续性相对不敏感,是目前应用研究较为理想的随机优化策略。基于随机优化技术的遗传算法、蚁群算法等多目标优化算法^[1-2]和结合粒子群算法、神经网络等机制的融合算法^[3-5],在约束多目标求解 Pareto 最优解集中取得了良好的效果。

粒子群算法是 1995 年由 Kennedy 等提出的启发式方法,最初用来解决连续解空间上的优化问题。随后,提出了基于离散空间的粒子群优化算法(BP-SO),并应用于 0-1 规划的离散问题上^[6]。文献[7]对连续 PSO 直接离散化,在更新过程中进行近似取整,将改进的 BPSO 应用于高维整数规划问题,得到了稳定性较高的解,且很少产生陷入搜索停滞的情形。文献[8]将 PSO 应用于多目标旅行商(MOTSP)问题中,文献[9]将 PSO 用于车辆路径问题(VRP)的优化中,均取得了良好的优化结果。此外,粒子群算法在约束优化、动态优化、多目标优化等领域^[10-11]都取得了广泛的研究与应用,但是粒子群及其变种算法在解决复杂问题时普遍具有收敛性和易陷入局部最优的问题。

车辆路径问题是典型的组合优化问题,考虑距离、时间和费用成本等多目标约束条件下的车辆路径优化,是一种类多峰问题。本文从分析粒子群算法本身的学习机制入手,通过动态学习方式进行种群的迭代更新,让粒子自适应调整更新过程中认知成分和社会成分的比重,并采用突变机制赋予粒子突破更新步长限制的能力,以跳出局部最优解。文中选取其他 5 种改进的粒子群算法作对比,并通过 BenchMark 基准测试函数和多目标的有容量限制的调度问题(CVRP)验证了本文改进算法的有效性。

1 标准 PSO 算法

经典标准 PSO 算法^[12]中,粒子群中的粒子迭代更新公式为

$$\left. \begin{aligned} v_{id} &= \omega v_{id} + c_1 r_1 (p_{id} - x_{id}) + c_2 r_2 (p_{gd} - x_{id}) \\ x_{id} &= x_{id} + v_{id} \end{aligned} \right\} \quad (1)$$

式中: ω 为经典线性模型; p_{id} 和 p_{gd} 分别为粒子群中个体局部最优和全局最优位置; c_1 、 c_2 为学习因子常量; r_1 、 r_2 为两个 0 与 1 之间的随机数; $c_1 r_1 (p_{id} - x_{id})$ 、 $c_2 r_2 (p_{gd} - x_{id})$ 分别为粒子更新过程中的认知成分和社会成分, $c_1 r_1$ 、 $c_2 r_2$ 决定着每个个体对个体最优和全局最优的信任程度。当 $c_1 r_1$ 较大时粒子更加信任个体极值,受个体极值的影响较大,将会更多的向个体极值靠近,此时有利于粒子在局部寻优,提高开发能力;反之,当 $c_2 r_2$ 较大时粒子会更加信任当前全局最优值,受全局最优值影响较大,粒子将会向全局最优值移动,有利于粒子全局寻优过程的进行,增强其探索能力,同时有利于算法的收敛。

2 改进 PSO 算法及 VRP 问题模型

2.1 改进的 PSO 算法

2.1.1 动态学习因子的引入 在经典标准 PSO 模型中,粒子在迭代更新中向社会成分和认知成分学习的程度是不受控的。本文引入动态学习因子 $\langle \theta_1, \theta_2 \rangle$,粒子在 d 维空间搜索时,其速度 $v_i = [v_i^1, v_i^2, \dots, v_i^d]$ 和位置 $x_i = [x_i^1, x_i^2, \dots, x_i^d]$ 的更新公式为

$$\left. \begin{aligned} v_{i+1}^d &= \omega v_i^d + c_1 r_1 \theta_1 (p_{\text{best}}^d - x_i^d) + c_2 r_2 \theta_2 (g_{\text{best}}^d - x_i^d) \\ x_{i+1}^d &= x_i^d + v_{i+1}^d \end{aligned} \right\} \quad (2)$$

式中: p_{best}^d 、 g_{best}^d 分别为粒子的个体最优值和全局最优值在 d 维上的分量值。学习因子的取值由学习概率 P_b 和 φ 共同决定, φ 为通过随机函数产生的 $[0, 1]$ 区间内的随机数, P_b 和 φ 的关系式为

$$\left. \begin{aligned} \theta_1 &= 1, \theta_2 = \theta_0, & \varphi > P_b \\ \theta_1 &= \theta_0, \theta_2 = 1, & \varphi < P_b \end{aligned} \right\} \quad (3)$$

$\theta_0 \in [0, 1]$ 为一常数,当随机数 φ 大于 P_b 时,适当降低社会成分在速度更新中的比重,此时粒子受个体极值的引导较大,反之则减少认知成分在速度更新中的比重,粒子更多向全局最优值学习。 P_b 的处理

机制为^[14]

$$\left. \begin{aligned} P_b(i+1) &= m(h_1 + h_2) + n \\ h_1 &= \frac{\text{fit}(g_{\text{best}})}{\text{fit}(x_i) + \exp(-10)} \\ h_2 &= \frac{T-t}{T} \end{aligned} \right\} \quad (4)$$

式中: T 、 t 分别为种群最大迭代次数和当前迭代次数,在迭代初期对学习概率影响较大,使得粒子更倾向于向全局最优学习,使群体较快收敛,迭代对学习概率的影响逐渐减小,粒子更多向个体极值学习,这有利于种群多样性的保持; $\text{fit}(x_i)$ 为当前解 x_i 的适应度计算函数; h_1 为粒子当前位置适应度与全局最优位置适应度的近似程度; h_2 为迭代次数的改变对学习概率的影响; m 、 n 分别取值为 0.15 和 0.30^[13]。

本文采用 BenchMark 基准函数测试集中的典型函数来测试常量 θ_0 的最优取值区间,选取 Sphere、Rosenbrock 两个单峰函数及 Restigin、Schwefel 两个多峰函数,将学习因子常量 θ_0 在区间 $[0, 1]$ 中均匀取 11 组值,分别执行 100 次,得到 4 个测试函数上的平均运行结果,如图 1 所示。




图1 动态学习因子常量在测试函数中的运行结果

2.1.2 避免陷入局部最优解的辅助机制 由粒子群算法的优化机制可知,粒子在进行一步更新后,当且仅当此次更新后所得解优于个体极值,该解才能被采纳,成为新的个体最优值,否则该解对整个种群的进化无效,粒子将在原个体极值基础上重新进行一步更新。当粒子陷入局部最优时,以当前的更新步长难以发现该局部最优解以外的全局最优解。

本文采用阶梯突变的机制,引入突变因子 σ ,赋予粒子突破当前更新机制限制的能力。当群体陷入

局部最优时,通过调整粒子的更新步长和前进方向,让粒子在当前个体最优解速度矢量方向上进行阶梯试探。本文采用调整权重因子的方法实现该突变机制,当发现种群陷入局部最优时,在当前迭代数的基础上调整权重因子 w 的大小,即

$$\omega = \omega \pm k\sigma, \quad k = 1, 2, 3, \dots, n \quad (5)$$

式中: σ 为突变因子,采用线性惯性权重模型^[12] 在当前迭代数下的单步步长; k 为突变阶梯; n 为阶梯上限。当粒子陷入局部最优时,突变阶梯 k 从 1 开始取值进行突变,此时权重因子分别进行一次正向和反向的突变,并进行一次更新过程,若一次突变后仍不能发现更优解,则增大突变阶梯值,此时权重因子将随之产生更大幅度的突变,粒子将会跳向原本正常更新机制中所不可能行进到的位置进行寻优,若在某次突变过程中发现比当前最优解更好的解,停止突变,粒子则跳出当前局部最优位置,行进到该突变位置处继续寻优过程。若突变阶梯值达到上限值 n 后仍不能跳出当前局部最优值,终止该突变操作,还原权重因子到突变前的状态,将突变阶梯值 k 取为 1,继续先前迭代过程至迭代数上限,结束该寻优过程。

2.2 多目标的车辆路径问题

多目标优化问题可描述为

$$\left. \begin{aligned} \mathbf{x} &= [x_1, x_2, \dots, x_n]^T \\ \min \mathbf{y} &= g(\mathbf{x}) = \{g_1(\mathbf{x}), g_2(\mathbf{x}), \dots, g_m(\mathbf{x})\} \\ \mathbf{x} &\in M = \{\mathbf{x} \mid l_j(\mathbf{x}) \leq 0; j = 1, 2, \dots, p\} \end{aligned} \right\} \quad (6)$$

式中: $\mathbf{x}$ 为决策变量; $\mathbf{y}$ 为目标向量; M 为约束条件集合所决定的可行解域。

车辆路径问题是指通过配送中心调度,为一系列配送点配送货物,通过合理安排配送路线,达到最优配送的目的,问题描述如下。

有一个配送中心站,配备有 K 辆配送车,装载容量为 $h_k (k=1, 2, \dots, K)$,有 L 个配送点要求配送货物,各配送点的货物需求量为 $e_i (i=1, 2, \dots, L)$,且 $\max e_i \leq \max h_k$,求满足需求的最优配送路线。

车辆路径问题(VRP)比多旅行商(MTSP)问题^[14]的约束条件严格,求解复杂,且具有实际意义。最优配送是指配送路线的最优化如距离最短等,本文采用多目标模型来处理车辆路径问题,考虑车辆配送路线中的距离最短、时间最短和费用最少 3 个目标,各目标距离、时间、费用的计算公式为

$$S = \sum_{i=1}^K S_{e_i} = \sum_{i=1}^K \sum_{j=1}^H L_{e_{ij}} \quad (7)$$

$$T = \sum_{i=1}^K T_{e_i} = \sum_{i=1}^K \sum_{j=1}^H \frac{L_{e_{ij}}}{V_{e_{ij}}} \quad (8)$$

$$Q = \sum_{i=1}^K Q_{e_i} = \sum_{i=1}^K \sum_{j=1}^T L_{e_{ij}} (\omega_{e_{ij}} + u) \quad (9)$$

式中： i 为车辆编号； S_{e_i} 为车辆 i 在配送任务中的总路程； j 为两个配送点间路段的编号； H 为路段总数； $L_{e_{ij}}$ 为 i 车路线中的 j 路段长度； T_{e_i} 为完成 i 车路线所需的时间； $V_{e_{ij}}$ 为 i 车 j 路段上的平均行驶速度； $\omega_{e_{ij}}$ 为 i 车 j 路段单位距离的收费标准； u 为单位距离耗油费用。

本文建立的多目标函数模型为

$$\min y = f(x) = \{g_1(x), g_2(x), g_3(x)\} \quad (10)$$

$$g_1(x) = S; \quad g_2(x) = T; \quad g_3(x) = Q \quad (11)$$

为尽可能减少算法计算量以降低算法的复杂度,在计算最终配送路线的优化程度时,采用如下权重模型^[15]统一各目标值量纲

$$\left. \begin{aligned} G &= 1 - \sum_{i=1}^N \omega_i \left(\frac{g_i(x) - g_i(x)^*}{g_i(x)^*} \right) \\ \sum_{i=1}^N \omega_i &= 1, \quad \omega_i \in [0, 1] \end{aligned} \right\} \quad (12)$$

式中： G 为配送路线的最终近似度； $g_i(x)^*$ 为第 i 个目标在单目标约束下最优配送路线的理想值； ω_i 为单目标所占比重； N 为目标总数。 G 越高,配送路线就越理想。求解 DSPSO 算法的多目标车辆路径问题 $\text{fit}(x) = G(x)$, 则可得求解过程如下。

开始

1. 初始化 ω , 随机初始化各粒子的 v_i^d, x_i^d ;
2. 初次计算各粒子的适应度;
3. 计算 $p_{\text{best}}, g_{\text{best}}$ 并确定多目标最终相似度 G ;
4. loop
5. 计算学习概率 P_b ;
6. 确定动态学习因子对 $\langle \theta_1, \theta_2 \rangle$;
7. 更新粒子的速度 v_i^d 和位置 x_i^d ;
8. 计算各粒子的适应度;

9. 更新各粒子的 p_{best} 及最终相似度 G' ;
 10. if $G' > G$
 11. 更新全局最优解 g_{best} 并更新 $G, G = G'$;
 12. else if $G = G'$
 13. For $j = 1$ to n
 14. 进行一次阶梯突变, 更新 ω , 重新计算 G' ;
 15. if $G' > G$
 16. 更新 $p_{\text{best}}, g_{\text{best}}, G, G = G'$
 17. 还原 ω 到突变前的值, 终止突变;
 18. end if
 19. 如果迭代次数达最大迭代数, 跳出循环;
 20. end loop
- 结束

3 实验结果与分析

3.1 Benchmark 测试函数

为了检验本文算法的有效性,采用 Benchmark 基准函数测试集中的典型函数进行测试,选取 4 个单峰问题函数和 4 个多峰问题函数,如表 1 所示。实验环境为:AMD Athlon 处理器,主频 2.70 GHz, 2.0 GB 内存,Win7 环境下搭建 Microsoft VS 2013。

实验中 ω 采用文献[12]的经典线性模型,递变区间为 $[0.4, 0.9]$, 粒子个体数为 40, 函数维数为 30, 动态学习因子常量取值 0.2, 最大迭代数为 10 000, 并选取带惯性权重的粒子群算法 PSO- ω ^[16]、标准 PSO 算法 SPSO^[12]、带收敛因子的 PSO 算法 PSO- x ^[17]、组合学习策略 PSO 算法 CPSO^[13]、平均最优信息的 PSO 算法^[18] AVGPSO 5 种粒子群变体算法进行测试比较。此 5 种算法与本文改进算法参数设置一致,每个算法在每一基准函数上分别运行 60 次,统计各算法在各基准函数上运行的最优值(BR)、标准差(SD)、达到可接受解的成功次数(SN)及成功率(SR)等,如表 2 所示。

表 1 8 个维度为 30 的 Benchmark 基准测试函数

函数	最优解	求解区域	最优值	可接受解
Sphere	$[0, 0, \dots, 0]$	$[100, 100]$	0	1×10^{-20}
Schwefel's P2. 22	$[0, 0, \dots, 0]$	$[-10, 10]$	0	10
Rosenbrock	$[1, 1, \dots, 1]$	$[-10, 10]$	0	70
Noise	$[0, 0, \dots, 0]$	$[-1.28, 1.28]$	0	0.5
Schwefel	$[420.96, \dots, 420.96]$	$[-500, 500]$	0	3 000
Rastrigin	$[0, 0, \dots, 0]$	$[-5.12, 5.12]$	0	2
Ackley	$[0, 0, \dots, 0]$	$[-32, 32]$	0	1×10^{-10}
Griewank	$[0, 0, \dots, 0]$	$[-600, 600]$	0	0.01

表 2 6 种对比算法在 Benchmark 测试函数上的运行结果

函数	解	PSO-w	UPSO	PSO-x	CPSO	AVGPSO	DSPSO
Sphere	BR	4.94	1.07×10^{-23}	7.47×10^{-82}	7.46×10^{-27}	1.75×10^{-243}	1.09×10^{-138}
	SD	79	1.88×10^{-20}	2.96×10^{-72}	7.43×10^{-24}	0.00	1.21×10^{-127}
	SN,SR	0,0.00	50,83.33	60,100.00	60,10.00	60,100.00	60,100.00
Rosen-brock	BR	455	11.7	83	45.6	26.7	4.24×10^{-5}
	SD	309	18.2	31.8	32.8	0.974	17.11
	SN,SR	0,0.00	53,88.33	0,0.00	15,25.00	60,100.00	58,96.67
Schwefel's	BR	10.8	9.63	21	34.9	8.20×10^{-101}	0.113
	SD	18.9	19.8	15.6	18.2	5.87×10^{-75}	1.90
	P2.22	0,0.00	1,1.67	0,0.00	0,0.00	60,100.00	58,96.67
Noise	BR	0.175	0.299	0.171	0.198	5.62×10^{-3}	0.160
	SD	0.341	0.35	0.325	0.312	0.699	0.325
	SN,SR	11,18.33	11,18.33	11,18.33	11,18.33	29,48.33	11,18.33
Rastrigin	BR	126	8.96	94.5	14.9	0.00	0.00
	SD	159	5.45	67.7	13	0.00	8.55
	SN,SR	0,0.00	33,55.00	0,0.00	8,13.33	60,100.00	54,90.00
Ackley	BR	2.99	7.55×10^{-15}	7.55×10^{-15}	7.55×10^{-15}	4.00×10^{-15}	7.55×10^{-15}
	SD	0.104	3.28×10^{-15}	0.85	2.87×10^{-15}	0.00	2.87×10^{-15}
	SN,SR	0,0.00	60,100.00	20,33.33	60,100.00	60,100.00	60,100.00
Grieramk	BR	0.165	0.00	0.00	0.00	0.00	0.000
	SD	2.88×10^{-2}	1.01×10^{-2}	0.419	8.77×10^{-3}	0.00	1.2×10^{-3}
	SN,SR	0,0.00	39,65.00	5,8.33	37,61.67	60,100.00	41,68.33
Schwefel	BR	4 500	1 620	2 750	1 780	9 080	1 190
	SD	596	383	756	617	1 090	3 810
	SN,SR	0,0.00	54,90.00	1,1.67	31,51.67	0,0.00	58,96.67

由表 2 可得,单峰函数中 Noise 函数由于其持续的扰动特性,本文算法无法获得较为理想的解。AVGPSO 算法在迭代初期开始就引入平均信息,而本文算法的动态学习引导是一个逐渐调整的过程,调整较缓慢,故在相同迭代数下 AVGPSO 优于本文算法。在求解精度和稳定性上,本文算法明显优于其他对比算法。

为了检验各算法的特性,本文采用迭代数来反映各算法的收敛性,避免由于编程技巧的不同而对收敛时所用 CPU 时间产生的影响,对单峰函数采集各算法在测试函数上每迭代 200 次后的优化值,最大迭代数为 4 000,多峰函数每 500 次迭代采集一次优化结果,最大迭代次数为 10 000,根据执行 60 次的平均结果数据,在 MATLAB 上进行拟合,收敛性对比如图 2、3 所示。

由图 2、3 可知,单峰函数中极值点处即为最优解。相比其他对比算法,本文算法中采用的自适应引导能够使粒子在较少迭代数内求得更好的最优解,即使粒子群体更快速收敛到极值点。多峰函数具有多个极值点,过快的收敛会因为早熟而使粒子




图 2 4 个单峰函数上各对比算法的收敛性对比

陷入局部最优或者跳过全局最优位置,本文突变机制有效增加了种群的多样性,防止种群陷入局部最优而失去全局探索能力,在保证种群收敛的前提下能探索获得更好的全局最优解。




图 3 4 个多峰函数上各对比算法的收敛性对比

3.2 车辆调度实例验证

为了验证本文改进算法在多目标车辆路径问题上的处理能力,本文选取 VRP 数据库中的 E-n22-k4 实例,该实例共有 22 个配送点,一个为配送中心(编号 1),其余为待配送点,各点坐标位置及配送需求如表 3 所示。

借鉴文献[9]的编码机制,车辆调度的多目标选取为距离 S 、时间 T 和费用 Q_0 。为了简化问题,假定任两个配送点间为单一路段,并用该两点间的欧氏距离代表该路段的长度,得距离矩阵 S_0 。根据表 5 中各个配送点位置坐标,为了尽可能模拟任意路段本身及其各种属性的多变性和不确定性,本文采用生成随机对称矩阵 V_0 、 W_0 和 U_0 的方式,矩阵分别代表 S_0 中各路段上的平均行驶速度、道路收费和油耗费用,通过式(7)、(8)、(9)、(12)计算配送路线中的各单目标值和最终近似度。

实验中惯性权重 ω 采用文献[12]的经典线性权重模型,动态学习因子常量取值 0.2,种群大小为 60,迭代数为 200,配送车辆 $K=4$,单车限载容量为 6 000,使用本文算法对各单目标进行多车单目标优化,如图 4 所示。

各单目标最优值及最优配送路线如下。

距离 S :394.433

车 1 路线:1→12→5→4→2→3→8→1

车 2 路线:1→17→20→14→1

车 3 路线:1→13→10→6→7→9→11→1

车 4 路线:1→16→19→21→22→18→15→1




图 4 单目标优化最优路径轨迹图

表 3 各配送点坐标位置及配送需求

位置点编号	坐标	需求量
1	(145,215)	0
2	(151,264)	1 100
3	(159,261)	700
4	(130,254)	800
5	(128,252)	1 400
6	(163,247)	2 100
7	(146,246)	400
8	(161,242)	800
9	(142,239)	100
10	(163,236)	500
11	(148,232)	600
12	(128,231)	1 200
13	(156,217)	1 300
14	(129,214)	1 300
15	(146,208)	300
16	(164,208)	900
17	(141,206)	2 100
18	(147,193)	1 000
19	(164,193)	900
20	(129,189)	2 500
21	(155,185)	1 800
22	(139,182)	700

时间 T :5.702

车 1 路线:1→6→7→2→3→8→10→15→1

车 2 路线:1→16→19→21→22→18→1

车 3 路线:1→17→20→14→1

车 4 路线:1→4→5→9→12→11→13→1

费用 Q :356.271

车 1 路线:1→13→15→18→19→21→22→1

车 2 路线:1→17→20→14→1

车 3 路线:1→12→3→2→5→4→1

车 4 路线:1→16→7→9→6→8→10→11→1

上述单目标最优值为多目标优化时的各单目标理想值,对比 5 种变种粒子群算法与本文改进算法在多目标优化实例上的效果。实验中粒子种群大小为 60,迭代数为 200,配送车辆数为 4,单车载容量为 6 000,每个算法分别运行 70 次,将相似度大于 0.5 的优化结果称为可接受解,大于 0.6 为成功解。分别计算各算法获得可接受解与成功解的次数及最优解,可接受率/成功率记为 R_1/R_2 ,最优相似度记为 S ,最优相似度解对应的各单目标值(距离/时间/费用)记为 B ,结果如表 4 所示。

表 4 各对比算法在实例上的运行结果对比

算法	R_1/R_2	S	B
PSO- w	0.03/0	0.548	596.28/7.80/533.73
UPSO	0.04/0.04	0.686	553.22/7.27/451.48
PSO- x	0.16/0.11	0.837	453.39/6.65/421.03
CPSO	0.10/0.04	0.774	491.42/6.38/467.22
AVGPSO	0/0	0.148	670.26/10.43/727.67
DSPSO	0.91/0.66	0.887	470.48/6.08/385.97

本文改进算法最优配送路线如下。

车 1 路线:1→4→5→9→7→2→3→8→15→1

车 2 路线:1→12→14→20→22→1

车 3 路线:1→6→10→11→16→13→1

车 4 路线:1→18→21→19→17→1

在相同实验环境下,各参数设置:粒子种群大小为 60,迭代数为 100,配送车辆数为 4,车载容量为 6 000。将 5 种对比算法及本文改进算法 DSPSO 分别在该实例上运行 400 次,采集每次运行所得最终近似度,如图 5~7 所示。






图 5 PSO- w 和 SPSO 对比算法运行结果



(a)PSO- x 运行结果 (b)CPSO 运行结果

图 6 PSO- x 和 CPSO 对比算法运行结果



(a)AVGPSO 运行结果 (b)DSPSO 运行结果

图 7 AVGPSO 和 DSPSO 的运行结果

由表 4 可得,本文改进算法在可接受率和成功率上优于其他对比算法,且最优相似度也远优于其他对比算法。对比图 5~7 可得,5 种对比算法相似度聚集在 0.1,而本文改进算法则较多分布在 $[0.45,0.85]$ 区间内,说明本文改进算法在多目标优化问题中更接近真实 Pareto 边界,体现了在多目标优化问题上的有效性。

4 结 论

针对粒子群及其变种算法易陷入局部最优和收敛性问题,本文提出基于动态学习策略的粒子群算法。将优化过程中的迭代数和粒子个体极值与全局极值的近似度相结合,动态调整社会成分和认知成分在更新时的比重,引导粒子发现更优解,有效改善了种群的收敛性。同时,引入阶梯突变因子,赋予粒子突破当前更新步长的能力,有效避免粒子陷入局部最优,增强全局寻优的能力。

通过 Benchmark 基准测试函数集中的典型单峰和多峰函数测试,结果表明本文改进算法较其他对比算法有更好的求解精度和稳定性,且可在保证收敛的前提下调节算法的收敛速度。多目标车辆路

径问题的实验表明,本文算法较其他对比算法能够获得更优的配送路线,体现了在 CVRP 优化问题上的良好性能。

参考文献:

- [1] YUSUF I, BABA M S, IKSAN N. Applied genetic algorithm for solving rich VRP [J]. *Applied Artificial Intelligence*, 2014, 28(10): 957-991.
- [2] ZHANG Changsheng, YIN Hao, ZHANG Bin. A novel ant colony optimization algorithm for large scale QoS-based service selection problem [J]. *Discrete Dynamics in Nature and Society*, 2013(6): 1104-1116.
- [3] KENNEDY J, EBERHART R C. Particle swarm optimization [M]. Berlin, Germany: Springer, 2010: 760-766.
- [4] CHATTERJEE S, SARKAR S, HORE S, et al. Particle swarm optimization trained neural network for structural failure prediction of multistoried RC buildings [M/OL] // *Neural Computing & Applications*. [2015-12-12]. <http://link.springer.com/article/10.1007/s00521-016-2190-2>.
- [5] 许榕,周东,蒋士正,等.自适应粒子群神经网络交通流预测模型 [J]. *西安交通大学学报*, 2015, 49(10): 103-108.
- XU Rong, ZHOU Dong, JIANG Shizheng, et al. A traffic forecasting model using adaptive particle swarm optimization trained neural network [J]. *Journal of Xi'an Jiaotong University*, 2015, 49(10): 103-108.
- [6] KENNEDY J, EBERHART R C. A discrete binary version of the particle swarm algorithm [C]//*IEEE International Conference on Systems, Man, and Cybernetics*. Piscataway, NJ, USA: IEEE, 1997: 4104-4108.
- [7] PARSOPOULOS K E, VRAHATIS M N. Recent approaches to global optimization problems through particle swarm optimization [J]. *Natural Computing*, 2002, 1(2): 235-306.
- [8] WANG Zutong, GUO Jiansheng, ZHENG Mingfa, et al. Uncertain multiobjective traveling salesman problem [J]. *European Journal of Operational Research*, 2015, 241(2): 478-489.
- [9] LI Ning, ZOU Tong, SUN Debao. Particle swarm optimization for vehicle routing problem [J]. *Journal of Systems Engineering*, 2005, 19(6): 596-600.
- [10] DUAN Peibo, ZHANG Changsheng, ZHANG Bin. A local stability supported parallel distributed constraint optimization algorithm [J/OL]. *The Scientific World Journal*. [2015-12-10]. <http://www.hindawi.com/journals/tswj/2014/734975/abs/>.
- [11] YIN Hao, ZHANG Changsheng, ZHANG Bin, et al. A hybrid multi-objective discrete particle swarm optimization algorithm for a SLA-aware service composition problem [J]. *Mathematical Problems in Engineering*, 2014, 89(1): 112-121.
- [12] SHI Yuhui, EBERHART R C. Empirical study of particle swarm optimization [C]//*Proceedings of the 1999 Congress on Evolutionary Computation*. Piscataway, NJ, USA: IEEE, 1999: 1945-1950.
- [13] TAN Guanzheng, BAO Kun, RIMIRU R. A composite particle swarm algorithm for global optimization of multimodal functions [J]. *Journal of Central South University*, 2014, 21(5): 1871-1880.
- [14] LI Jun, SUN Qirui, ZHOU Mengchu, et al. A new multiple traveling salesman problem and its genetic algorithm-based solution [C]//*The 2013 IEEE International Conference on Systems, Man, and Cybernetics*. Piscataway, NJ, USA: IEEE, 2013: 627-632.
- [15] TANG Yaoping, YU Hong, WANG Wenmu, et al. Application of TSP model based multi-objective in Yongzhou city's tourist routes [J]. *Journal of Central South University of Forestry & Technology*, 2011(10): 154-157.
- [16] SHI Yuhui, EBERHART R C. A modified particle swarm optimizer [C]//*The IEEE International Conference on Evolutionary Computation*. Piscataway, NJ, USA: IEEE, 1998: 69-73.
- [17] CLERC M. The swarm and the queen: towards a deterministic and adaptive particle swarm optimization [C]//*Proceedings of the 1999 Congress on Evolutionary Computation*. Piscataway, NJ, USA: IEEE, 1999: 1951-1957.
- [18] LI Zhuangkuo, MA Yannan, LIU Liang. Particle swarm optimization based on the average optimal information for vehicle routing problem [C]//*The 6th International Symposium on Computational Intelligence and Design*. Piscataway, NJ, USA: IEEE, 2013: 51-54.

(编辑 赵炜)