

一种求解旅行商问题的进化多目标优化方法

陈 彧[†], 韩 超

(武汉理工大学 理学院, 武汉 430070)

摘 要: 为了克服传统小生境(Niching)策略中的参数设置难题,提出一种求解旅行商问题的进化多目标优化方法:建立以路径长度和平均离群距离为目标的双目标优化模型,利用改进非支配排序遗传算法(NSGAI)进行求解.为了在全局探索能力与局部开发能力之间保持平衡,算法中采用一种使路径长度相同的可行解互不占优的评价策略,并通过一种新的离散差分进化算子和简化的2-Opt策略生成候选解.与已有算法的数值试验结果比较表明,求解旅行商问题(TSP)的改进非支配排序遗传算法(NSGAI-TSP)能够更好地保持种群多样性,从而克服局部最优解的吸引并具有更鲁棒的全局探索能力.通过借助特殊的个体评价策略,所提出的算法可以更好地进行全局优化,甚至同时得到多个全局最优解.

关键词: 旅行商问题; 多目标进化算法; 离散差分进化; 组合优化; 多目标化; 多样性

中图分类号: TP183

文献标志码: A

An evolutionary multiobjective optimization method for traveling salesman problems

CHEN Yu[†], HAN Chao

(School of Science, Wuhan University of Technology, Wuhan 430070, China)

Abstract: An evolutionary multi-objective optimization method is proposed for the traveling salesman problem (TSP) to overcome the parameter-setting trouble in traditional niching strategies, where we develop an optimization model minimizing the tour length as well as the averaged mutual distance, and solve it to get the global optimal solutions of TSPs via the nondominated sorting genetic algorithm II (NSGAI). To strike a balance between global exploration and local exploitation, it incorporates an evaluation strategy that makes different solutions of the same length nondominated, and generates new candidate solutions via a novel discrete differential evolution strategy as well as a simplified 2-Opt strategy. Numerical comparisons with existing algorithms demonstrate that the NSGAI for TSP (NSGAI-TSP) can better keep the population diversity, be kept away from the absorption of local optima, and consequently has robust global exploration ability. With assistance of the special strategy making different solutions of the same length nondominated, the proposed algorithm can perform global optimization better, and locate several global optimal solutions at a time.

Keywords: traveling salesman problem; multiobjective evolutionary algorithm; discrete differential evolution; combinatorial optimization; multiobjectivization; diversity

0 引 言

旅行商问题(Travelling salesman problem, TSP)是一类经典的组合优化问题,旨在求出一条基于已知交通网络的遍历所有城市的最短Hamilton回路.许多科学研究和工程计算中的实际问题都可以描述为TSP问题,对TSP问题求解算法的研究具有重要意义.然而,TSP问题中的可行路径数目随着城市规模的增

大迅速增加,传统的确定优化算法求解的时间复杂度高,利用智能优化算法求解TSP问题已成为当前TSP问题研究的一个热门课题^[1].

按照旅行路径生成方式的不同,可以将求解TSP的智能优化算法分为两类:一类是路径构建型算法,从某个城市开始基于某种程度上的贪婪策略进行搜索并最终得到可行的旅行路径,如禁忌搜索算法^[2]、

收稿日期: 2017-10-08; 修回日期: 2017-12-05.

基金项目: 国家自然科学基金项目(61303028).

责任编委: 侯忠生.

作者简介: 陈彧(1981—),男,副教授,博士,从事进化算法及其应用等研究;韩超(1993—),男,硕士生,从事进化组合优化的研究.

[†]通讯作者. E-mail: chymath@gmail.com.

蚁群算法^[3]等,虽然具有较好的局部开发能力,却容易陷入局部最优解.第二类是整体探索型算法,如遗传算法^[4]、粒子群优化算法^[5]、差分进化算法^[6]等.他们通过某种整体搜索策略生成新解,故具有较好的全局探索能力,但这些算法常需要对不合法的新解进行修复.然而,新解的修复破坏了种群的进化进程,因此需要采用局部搜索策略提高算法的局部开发能力.近年来,为了更好地实现种群进化过程中全局探索能力与局部开发能力的平衡,一些新兴的智能优化算法也被应用于求解TSP问题^[7-10].

小生境(Niching)策略是一种常用的种群多样性保持策略,然而其中的参数设置却非常困难^[11].因此,学者们试图将单目标多峰优化问题转化为多目标优化问题,并称之为多峰问题的“多目标化”^[12].一般地,这一策略将多峰优化问题转化为一个双目标优化问题:其中一个目标为原多峰问题的优化目标,而另一个目标为基于某种梯度信息^[13-14]或者距离信息^[15-17]的多样性指标;另外,Wang等^[18]也提出了一种不同的策略,将第二个目标构造为与原目标(第一个目标)相矛盾的函数,并成功地运用所构建的双目标优化模型得到非线性方程组的多个不同解.由于多目标进化算法(Multi-objective evolutionary algorithms, MOEAs)的种群进化过程中蕴含了隐式的自适应多样性保持机制,利用MOEAs求解多峰问题的双目标优化模型更有利于搜索到全局最优解而不需要为了保持种群多样性而进行复杂的参数设置.

目前,将多峰问题进行多目标化的进化多目标优化方法已在连续多模问题的研究中取得了重要进展,但在TSP问题上的研究尚处于起步阶段.本文拟对求解TSP问题的进化多目标优化方法进行研究,具体工作包括:建立以路径长度和平均离群距离为目标的双目标优化模型;提出一种使路径长度相同的可行解互不占优的评价策略;采用一种新的离散编码差分进化算子生成候选解,并利用简化的2-Opt策略进行局部搜索;利用NSGAI^[19]作为MOEA框架求解TSP问题,通过数值试验结果验证方法的有效性.

1 TSP问题及其双目标优化模型

1.1 TSP问题

TSP问题的一般描述为:在 n 个城市构成的交通网中,让一个旅行商人从某个城市出发,寻找仅经过所有 n 个城市一次并最终回到出发城市的最短路径.将需要访问的 n 个城市编号为 $1, 2, \dots, n$,城市间的距离矩阵为 $D = (d(i, j))_{n \times n}$,则需要寻找一条路径

$R_b = (c_1, c_2, \dots, c_n)$,使得

$$f(R_b) = \min f(R).$$

其中: $f(R) = \sum_{i=1}^{n-1} d(c_{j_i}, c_{j_{i+1}}) + d(c_{j_n}, c_{j_1})$, $R = (c_{j_1}, c_{j_2}, \dots, c_{j_n})$ 表示由 n 个城市序号 $1, 2, \dots, n$ 构成的一个排列; $d(c_{j_i}, c_{j_{i+1}})$ 为城市 c_{j_i} 与城市 $c_{j_{i+1}}$ 之间的直接路径长度.若 $d(c_i, c_j) = d(c_j, c_i), \forall i, j \in \{1, 2, \dots, n\}$,则称之为对称的TSP问题;否则,称为不对称TSP问题.本文主要讨论对称的TSP问题,并采用城市顺序编码表示TSP问题的一个可行解,即: $R = (c_{j_1}, c_{j_2}, \dots, c_{j_n})$ 表示从城市 c_{j_1} 到 $c_{j_2}, c_{j_3}, \dots, c_{j_n}$ 再返回到 c_{j_1} 的旅行路径.

1.2 多目标优化问题

多目标优化问题(Multiobjective optimization problem, MOP)表示如下:

$$\begin{aligned} \min \quad & \mathbf{F}(\mathbf{x}) = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x})); \\ \text{s.t.} \quad & \mathbf{x} = (x_1, x_2, \dots, x_n) \in S_x \subset \mathbf{R}^n. \end{aligned} \quad (1)$$

在该多目标优化问题中, m 个优化目标 $f_1, f_2, \dots, f_m$ 往往是相互冲突的,不可能在可行域 S_x 中找到一个可行解 $\mathbf{x}^*$ 使得 $f_1, f_2, \dots, f_m$ 同时达到最小值.因此,在MOP研究中常采用Pareto支配(Pareto dominance)关系比较两个可行解的优劣.

定义1 (Pareto支配) 令 $\mathbf{u} = (u_1, u_2, \dots, u_m), \mathbf{v} = (v_1, v_2, \dots, v_m)$.如果 $u_i \leq v_i$ 对于所有 i 都成立,且至少存在一个 j 使得 $u_j < v_j$ 成立,则称 $\mathbf{u}$ (Pareto)支配 $\mathbf{v}$,记作 $\mathbf{u} \prec \mathbf{v}$.

定义2 (Pareto最优) 对于MOP(1)的某个可行解 $\mathbf{x} \in S_x$,如果不存在可行解 $\mathbf{y} \in S_x$ 使得 $\mathbf{F}(\mathbf{y}) \prec \mathbf{F}(\mathbf{x})$,则称 $\mathbf{x}$ 为MOP(1)的Pareto最优解;所有Pareto最优解构成Pareto最优集;Pareto最优集在向量函数 $\mathbf{F}(\cdot)$ 下的像称为Pareto前沿.

1.3 求解TSP问题的双目标优化模型

一般地,多目标优化问题(1)具有多个Pareto最优解,而基于种群搜索的MOEA则可以在一次运行中同时得到多个Pareto最优解.为了充分利用MOEAs的自适应多样性保持机制得到TSP问题的全局最优解,建立将TSP问题多目标化的双目标优化模型,即

$$\min \quad \mathbf{F}(\mathbf{x}) = (f(\mathbf{x}), 1/d(\mathbf{x})). \quad (2)$$

其中: $f(\mathbf{x})$ 为路径 $\mathbf{x}$ 的长度; $d(\mathbf{x}) = \frac{1}{N} \sum_{j=1}^N \text{dist}(\mathbf{x}, \mathbf{x}_j)$ 定义了个体 $\mathbf{x}$ 的平均离群距离, $\text{dist}(\mathbf{x}, \mathbf{x}_j)$ 为两条合法路径 $\mathbf{x}$ 与 $\mathbf{x}_j$ 中所有对应城市在路径中的位

置序数差的绝对值之和,其计算方法如下:若 $\mathbf{x} = (53412)$, $\mathbf{y} = (32154)$ 为 5 个城市的 TSP 问题的两条合法路径,则 1~5 号城市在路径 $\mathbf{x}$ 和 $\mathbf{y}$ 中的位置序数分别为 $I_{\mathbf{x}} = (45231)$ 和 $I_{\mathbf{y}} = (32154)$. 于是有

$$\text{dis}(\mathbf{x}, \mathbf{y}) = \|I_{\mathbf{x}} - I_{\mathbf{y}}\|_1 =$$

$$|4 - 3| + |5 - 2| + |2 - 1| + |3 - 5| + |1 - 4| = 10.$$

个体 $\mathbf{x}$ 的平均离群距离 $d(\mathbf{x})$ 刻画了个体 $\mathbf{x}$ 与种群中其他个体的平均距离, $d(\mathbf{x})$ 越大,则越应该在进化过程中被保留下来以保持种群多样性. 考虑到 TSP 问题可能具有多个有相同路径长度的可行路径,而多目标进化算法中基于 Pareto 支配的个体比较方法可能导致其中某个解被淘汰从而陷入局部最优,采用如下方法将具有相同路径长度的不同可行解转化为互不支配的可行解. 若路径 $\mathbf{x}$ 与 $\mathbf{y}$ 具有相同的路径长度,即 $f(\mathbf{x}) = f(\mathbf{y})$,则将 $d(\mathbf{x})$ 与 $d(\mathbf{y})$ 进行比较:若 $d(\mathbf{x}) < d(\mathbf{y})$,则令 $f(\mathbf{y}) = f(\mathbf{y}) + 1/d(\mathbf{y})$;若 $d(\mathbf{x}) > d(\mathbf{y})$,则令 $f(\mathbf{x}) = f(\mathbf{x}) + 1/d(\mathbf{x})$;若 $d(\mathbf{x})$ 与 $d(\mathbf{y})$ 相等,则令 $f(\mathbf{x}) = f(\mathbf{x}) + 1/\text{dist}(\mathbf{x}, \mathbf{y})$, $d(\mathbf{y}) = d(\mathbf{y}) + 1/\text{dist}(\mathbf{x}, \mathbf{y})$.

2 求解 TSP 问题的多目标进化算法

2.1 基于城市顺序编码的离散差分进化策略

差分进化 (Differential evolution, DE) 算法以种群中的个体差异向量方向作为变异的方向,通过放缩因子控制变异程度,再实行交叉操作来生成新个体,在求解连续优化问题时具有很好的优化效率. 然而,组合优化问题的离散可行域却使得高效的离散差分算子的设计变得很有挑战性. 为了较好地模拟差分进化策略的进化机制,本文设计一种基于城市序列编码的差分变异算子和杂交算子,其具体步骤如下.

Step 1: 随机选择 3 个父代个体 $\mathbf{x}_1 = (c_{1,1}, c_{1,2}, \dots, c_{1,n})$, $\mathbf{x}_2 = (c_{2,1}, c_{2,2}, \dots, c_{2,n})$ 和 $\mathbf{x}_3 = (c_{3,1}, c_{3,2}, \dots, c_{3,n})$. 对于 $\forall j = 1, 2, \dots, n$, 在 $\mathbf{x}_3$ 中定位城市 $c_{2,j}$ 所处的位置序数,记 $c_{2,j}$ 在 $\mathbf{x}_2$ 和 $\mathbf{x}_3$ 中的位置序数之差为 mov_j . 于是得到将路径 $\mathbf{x}_2$ 转化为 $\mathbf{x}_3$ 的城市位移向量 $\text{mov} = (\text{mov}_1, \text{mov}_2, \dots, \text{mov}_n)$.

Step 2: 将候选解 $\mathbf{v} = (v_1, v_2, \dots, v_n)$ 初始化为 $(0, 0, \dots, 0)$; 对于 $\forall j = 1, 2, \dots, n$, 以概率 F 将 $\mathbf{x}_1$ 中的城市 $c_{1,j}$ 的位置从 j 移到 $j + \text{mov}_j$, 即

$$v_j = \begin{cases} j + \text{mov}_j, & \text{if } \text{rand} < F; \\ 0, & \text{else.} \end{cases} \quad (3)$$

对于 $\forall j = 1, 2, \dots, n$, 若 $v_j = 0$, 则从路径 $\mathbf{v}$ 中未出现的城市中随机选择一个赋予 v_j .

Step 3: 将候选解 $\mathbf{v}$ 与 $\mathbf{x}_1$ 杂交生成新解 $\mathbf{u} = (u_1,$

$u_2, \dots, u_n)$: 随机生成 $1 \sim n$ 之间的整数 $\text{rand } i$. 对于 $\forall j = 1, 2, \dots, n$, 若 $\text{rand} < \text{CR}$ 或 $j = \text{rand } i$, 则令 $u_j = v_j$; 否则, 在 $\mathbf{x}_1$ 中找到 v_j 所处的位置 k , 令 $u_j = v_k, u_k = v_j$.

2.2 2-Opt 局部搜索策略

2-Opt 是一种被广泛应用于 TSP 问题的局部搜索策略^[20], 其基本操作是相邻城市的交换, 如图 1 所示: 若城市 c, b 之间的距离与 a, d 之间的距离之和小于 a, b 之间的距离与 c, d 之间的距离之和, 则将 TSP 路径变为由 a 到 d 经 b 到 c 再回到 a , 称对城市 a 和 c 做了一次 2-交换. 2-Opt 算法将所有相邻城市对进行搜索, 若进行了 2-交换, 则重新对所有相邻城市进行搜索, 在最坏情况下其时间复杂度是指数阶的^[21]. 为了降低局部搜索算法的时间复杂度, 对 TSP 问题的可行路径 $(c_1, c_2, \dots, c_n)$ 采用简化的 2-Opt 局部搜索策略, 只对所有城市遍历一遍进行 2-交换.




图 1 2-Opt 算法的城市交换策略

2.3 求解 TSP 问题的 NSGAI

NSGAI 算法^[19] (Non-dominated sorting genetic algorithm) 是一种高效的多目标进化算法, 本文对其进行改进得到求解 TSP 问题的 NSGAI-TSP:

Step 1: 随机生成 N 个初始可行解, 构成种群 Pop, 并利用式 (2) 对个体进行评价, 令 $t = 1$.

Step 2: 采用 2.1 节中的生成策略生成规模为 N 的新个体种群 NewPop, 并利用简化的 2-Opt 算子进行局部搜索, 改善生成的新解; 利用式 (2) 对 NewPop 进行评价.

Step 3: 令 $\text{IntPop} = \text{Pop} \cup \text{NewPop}$, 评价 IntPop 中个体之间的支配关系, 计算每个个体的非支配序数 (Nondomination rank) 和拥挤距离 (Crowding distance)^[19].

Step 4: 根据非支配序数和拥挤距离对个体进行排序: 非支配序数小的个体好于非支配序数大的个体; 若两个个体的非支配序数相同, 则拥挤距离大的个体优于拥挤距离小的个体.

Step 5: 选择最好的 N 个个体构成下一代种群 Pop; 若停机准则得到满足, 则输出 Pop, 算法结束; 否

则,令 $t = t + 1$,转到Step 2.

个体的非支配序数为种群中支配该个体的解的个数,拥挤距离刻画了非支配序数相同的各个个体与其他解之间的距离大小. NSGAI算法采用了保留非支配序数最小的个体的精英策略,并偏好于具有较大拥挤距离个体的选择方式,蕴含了多样性保持机制,从而能够收敛于均匀分布的近似Pareto前沿.

3 数值试验

为了验证本文方法的有效性,将TSPLIB (<https://www.iwr.uni-heidelberg.de/groups/comopt/software/TSPLIB95/>)中的测试问题与已有算法进行比较. 其中,NSGAI-TSP算法通过windows7操作系统中的Matlab2017a编程实现,在处理器为Intel(R)Core(TM) i5-6500,内存为16 G的PC机上运行. 由于各算法采用了不同的种群进化机制,算法适用的种群规模也会不同,在作比较时设定相同或者更少的函数评价(Function evaluations, FEs)次数作为NSGAI-TSP算法的迭代停止条件. 考虑到NSGAI的时间复杂度为 $O(MN^2)$ ^[19],随着种群规模的增加,算法时间复杂度增加较快,在算法测试中采用较小的种群规模 $N = 20$;另外,由于进化多目标优化方法中已经隐含了多样性保持策略,为了得到更快的收敛速度,差分进化算子中缩放因子设为 $F = 0.9$,交叉概率为 $CR = 0.9$.

TSPLIB中的对称TSP测试问题给出了各个城市的坐标,而城市之间的直接路径的长度则可通过计算城市间的欧氏距离得到. 为了更好地验证NSGAI-TSP算法的效率,采用两种不同方法得到城市之间的直接路径长度:

1) 对两个城市之间的欧氏距离取整得到城市之间的直接路径长度,这样得到的测试问题称为取整的对称旅行商问题(Rounded symmetric traveling salesman problem, RSTSP);

2) 以两个城市之间的欧氏距离作为城市之间的直接路径长度,这样得到的测试问题称为未取整的对称旅行商问题(Unrounded symmetric traveling salesman problem, USTSP).

3.1 求解RSTSP的数值试验结果

RSTSP通过对城市间的欧氏距离取整得到城市间的直接路径长度,消除了欧氏距离中小数部分带来的细微差距,从而在测试问题中产生大量的局部最优解,使得问题的求解变得更加困难;另外,取整也可能使得测试问题中出现不止一个全局最优解,即可能存在多条具有相同长度的最短旅行路径.

本文以TSPLIB中的Eil51, Berlin52, St70, Eil76和Pr107作为RSTSP的测试问题,并将运行结果与文献中的算法ACGA(Ant colony genetic algorithm)、HGI-ACGA(Heuristic genetic information based ant colony genetic algorithm)^[22]以及NACA(New ant colony algorithm)^[23]进行比较. 在文献[23]中,NACA的种群规模为50,迭代次数为500,至少进行了25 000次函数评价;本文中NSGAI-TSP的种群规模为20,最大迭代代数数为1 000,只进行了20 000次函数评价. 由于不同问题的路径长度数量级不同,以得到的路径长度与最优路径长度的相对误差来评价近似解的优劣. 将每个算例独立运行10次,得到的结果的平均相对误差为

$$\sigma = \frac{\sum_{i=1}^{10} (S_i - S_0)}{10S_0} \times 100\%.$$

其中: S_i 为第 i 次运行结果的路径长度, S_0 为已知最短路径的路径长度. 统计得到的最短路径长度Best, 平均路径长度Mean和平均相对误差 σ 如表1所示.

表1 求解RSTSP的NSGAI-TSP与其他算法的结果比较

Problem	Algorithm	Best	Mean	$\sigma / \%$
Eil51	ACGA	463	499	8.6
	HGI-ACGA	453	488	6.2
	NACA	440	458	5.6
	NSGAI-TSP	426	428.2	0.5
Berlin52	ACGA	7 820	8 201	6.3
	HGI-ACGA	7 769	7 989	2.2
	NACA	7 602	7 892	1.6
	NSGAI-TSP	7 542	7 568	0.3
St70	ACGA	762	814	12.2
	HGI-ACGA	736	789	8.9
	NACA	712	768	6.9
	NSGAI-TSP	675	677.9	0.4
Eil76	ACGA	602	662	15.3
	HGI-ACGA	586	640	9.3
	NACA	575	620	7.8
	NSGAI-TSP	539	548.1	1.8
Pr107	ACGA	4 589	49 363	7.2
	HGI-ACGA	46 659	48 989	5.1
	NACA	46 659	48 989	5.1
	NSGAI-TSP	44 326	44 545.8	0.5

数值试验结果表明,利用NSGAI-TSP求解TSP问题可以得到更好的优化结果. 其中算法ACGA、HGI-ACGA和NACA求解Eil76, St70, Eil51, Pr107和Berlin52得到的平均相对误差越来越小,表明对于这3种算法而言,测试问题的求解难度从高到低依次为Eil76, St70, Eil51, Pr107和Berlin52. NSGAI-TSP的求解结果更好,平均相对误差比较稳定,表明

NSGAI-TSP的全局探索能力更加稳定,算法的鲁棒性更好。这是因为NSGAI-TSP在求解双目标优化模型(2)的过程中较好地保持了种群多样性,而简化的2-Opt搜索策略一方面可以增强局部开发能力,另一方面在降低时间复杂度的同时避免了因过度局部搜索而陷入局部最优解的问题,同时又提高了全局探索能力。

与连续多模优化问题的情况类似^[17-18],当所求解的TSP问题具有多个全局最优解时,NSGAI-TSP可以同时得到多个全局最优解。以Eil51为例,NSGAI-TSP在一次运行的最后结果中同时包含两个不同的全局最优解,其路径如图2和图3所示。




图2 Eil51的最优路径1




图3 Eil51的最优路径2

由图2和图3可以看到,Eil51问题的最优路径1和最优路径2略有不同,其中经过城市42到达城市13的路径分别为 $\dots \rightarrow 42 \rightarrow 40 \rightarrow 19 \rightarrow 41 \rightarrow 13 \rightarrow \dots$ 和 $\dots \rightarrow 42 \rightarrow 19 \rightarrow 40 \rightarrow 41 \rightarrow 13 \rightarrow \dots$,而两个不同的全局最优解正是由于对城市间的欧氏距离取整而产生的。NSGAI-TSP将不同的全局最优解评价为互不支配的Pareto最优解,故可以在一次运行中同时得到多个全局最优解。

3.2 求解USTSP的数值试验结果

USTSP以欧氏距离为城市之间的直接路径长度,可能导致不同的可行路径的路径长度差异变小。因此,算法需要具备更强的局部开发能力以得到精确的全局最优解。为了验证NSGAI-TSP求解USTSP的效率,将其与新型帝国竞争算法(ICA)^[10]进行比较。其

中:ICA的种群规模为100,迭代次数为500,总共进行50 000次个体评价;NSGAI-TSP的种群规模为20,迭代次数为2 500,进行50 000次个体评价。对每个测试问题独立运行20次NSGAI-TSP,得到最好结果Best,最差结果Worst以及平均结果Mean,如表2所示。需要注意的是,USTSP与对应的RSTSP的全局最优解并不相同,可直接对所得的路径长度进行比较来评价算法的优劣。

表2 求解USTSP的NSGAI-TSP与ICA的结果比较

Problem	ICA	NSGAI-TSP		
	Best ^[10]	Best	Mean	Worst
Eil51	428.87	428.87	428.90	428.98
Eil76	544.37	544.37	549.34	554.17
Eil101	640.21	643.22	646.51	653.18
Pr107	44 301.68	44 301.68	44 369.93	44 480.74
Bier127	118 703.56	118 759.52	119 521.66	120 507.81
Pr136	96 770.92	96 879.95	97 315.58	98 634.68

由表2的结果可知:对于5个测试问题,NSGAI-TSP得到的最短、最长以及平均路径长度相差均很小,表明NSGAI-TSP的运行结果比较稳定,鲁棒性较好;同时,算法NSGAI-TSP在城市个数较小的Eil51和Eil76测试问题上可以得到与ICA相同的最短路径,而城市个数相对较大的Eil107, Bier127, Pr136三个测试问题得到的最短路径则略大于ICA得到的最好结果,这可能是因为NSGAI-TSP只采用了简化版本的2-Opt局部搜索策略,其局部开发能力略有欠缺。

4 结 论

考虑到TSP问题具有大量的局部最优解,本文考虑采用进化多目标优化方法求解TSP问题,从而克服传统的单目标优化方法中小生境策略的参数设置难题。本文建立了以TSP问题的路径长度和个体平均离群距离的倒数为目标的双目标优化模型,设计了基于离散差分进化算子和简化的2-Opt策略的个体生成机制和能够区分具有相同路径长度的不同可行路径的个体评价方法。数值试验结果表明,所得到的NSGAI-TSP具有更好的全局寻优能力,鲁棒性强,并且能够在一次运行中同时得到多个全局最优解,是一种求解TSP问题的有效方法。

参考文献(References)

- [1] 高海昌, 冯博琴, 朱利. 智能优化算法求解TSP问题[J]. 控制与决策, 2006, 21(3): 241-247.
(Gao H C, Feng B Q, Zhu L. Reviews of the meta-heuristic algorithms for TSP[J]. Control and Decision, 2006, 21(3): 241-247.)
- [2] 杨宁, 田蔚风, 金志华. 一种求解旅行商问题的交叉禁

- 忌搜索[J]. 系统仿真学报, 2006, 18(4): 897-899.
(Yang N, Tian W F, Jin Z H. Crossover tabu search for traveling salesman problem[J]. J of System Simulation, 2006, 18(4): 897-899.)
- [3] 申铨京, 刘阳阳, 黄永平, 等. 求解TSP问题的快速蚁群算法[J]. 吉林大学学报: 工学版, 2013, 43(1): 147-151.
(Shen X J, Liu Y Y, Huang Y P, et al. Fast ant colony algorithm for solving traveling salesman problem[J]. J of Jilin University: Engineering and Technology Edition, 2013, 43(1): 147-151.)
- [4] 王宇平, 李英华. 求解TSP的量子遗传算法[J]. 计算机学报, 2007, 30(5): 748-755.
(Wang Y P, Li Y H. A novel quantum genetic algorithm for TSP[J]. Chinese J of Computers, 2007, 30(5): 748-755.)
- [5] 高海兵, 周驰, 高亮. 广义粒子群优化模型[J]. 计算机学报, 2005, 28(12): 1980-1987.
(Gao H B, Zhou C, Gao L. General particle swarm optimization model[J]. Chinese J of Computers, 2005, 28(12): 1980-1987.)
- [6] 任子武, 熊蓉, 褚健. 混合量子差分进化算法及应用[J]. 控制理论与应用, 2011, 28(10): 1349-1355.
(Ren Z W, Xiong R, Chu J. Hybrid quantum differential evolutionary algorithm and its applications[J]. Control Theory & Applications, 2011, 28(10): 1349-1355.)
- [7] 周永权, 黄正新. 求解TSP的人工萤火虫群优化算法[J]. 控制与决策, 2012, 27(12): 1816-1821.
(Zhou Y Q, Huang Z X. Artificial glowworm swarm optimization algorithm for TSP[J]. Control and Decision, 2012, 27(12): 1816-1821.)
- [8] 冯翔, 张进文, 虞慧群. 仿生蚊子追踪算法[J]. 计算机学报, 2014, 37(8): 1794-1808.
(Feng X, Zhang J W, Yu H Q. Mosquito host-seeking algorithm for TSP problem[J]. Chinese J of Computers, 2014, 37(8): 1794-1808.)
- [9] 吴虎胜, 张凤鸣, 李浩, 等. 求解TSP问题的离散狼群算法[J]. 控制与决策, 2015, 30(10): 1861-1867.
(Wu H S, Zhang F M, Li H, et al. Discrete wolf pack algorithm for traveling salesman problem[J]. Control and Decision, 2015, 30(10): 1861-1867.)
- [10] 张鑫龙, 陈秀万, 肖汉, 等. 一种求解旅行商问题的新型帝国竞争算法[J]. 控制与决策, 2013, 31(4): 586-592.
(Zhang X L, Chen X W, Xiao H, et al. A new imperialist competitive algorithm for solving TSP problem[J]. Control and Decision, 2013, 31(4): 586-592.)
- [11] Li X, Eptropakis M, Deb K, et al. Seeking multiple solutions: An updated survey on niching methods and their applications[J]. IEEE Trans on Evolutionary Computation, 2017, 21(4): 518-538.
- [12] Wessing S, Preuss M, Rudolph G. Niching by multiobjectivization with neighbor information: Trade-offs and benefits[C]. Proc of the 2013 IEEE Conf on Evolutionary Computation. Cancún: IEEE, 2013: 103-110.
- [13] Yao J, Kharm N, Grogono P. Bi-objective multipopulation genetic algorithm for multimodal function optimization[J]. IEEE Trans on Evolutionary Computation, 2010, 14(1): 80-12.
- [14] Deb K, Saha A. Multimodal optimization using a bi-objective evolutionary algorithm[J]. Evolutionary Computation, 2012, 20(1): 27-62.
- [15] Bandaru S, Deb K. A parameterless-niching-assited bi-objective approach to multimodal optimization[C]. Proc of the 2013 the IEEE Congress on Evolutionary Computation. Cancún: IEEE, 2013: 95-102.
- [16] Basak A, Das S, Yang K C. Multimodal optimization using a biobjective differential evolution algorithm enhanced with mean distance-based selection[J]. IEEE Trans on Evolutionary Computation, 2013, 17(5): 666-685.
- [17] Cheng R, Li M Q, Li K, et al. Evolutionary multiobjective optimization based multimodal optimization: Fitness landscape approximation and peak detection[J]. IEEE Trans on Evolutionary Computation, 2018, 22(5): 692-706.
- [18] Wang Y, Li H X, Yen G G, et al. Mommop: Multiobjective optimization for locating multiple optimal solutions of multimodal optimization problems[J]. IEEE Trans on Cybernetics, 2015, 45(4): 830-843.
- [19] Deb K, Pratap A, Agarwal S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Trans on Evolutionary Computation, 2002, 6(2): 182-197.
- [20] Johnson D S, McGeoch L A. The traveling salesman problem: A case study in local optimization[M]. Local Search in Combinatorial Optimization. New York: Wiley, 1997: 215-310.
- [21] Englert M, Röglin H, Vöcking B. Worst case and probabilistic analysis of the 2-opt algorithm for the TSP[J]. Algorithmica, 2014, 68(1): 190-264.
- [22] 徐金荣, 李允, 刘海涛. 一种求解TSP的混合遗传蚁群算法[J]. 计算机应用, 2008, 28(8): 2084-2088.
(Xu J R, Li Y, Liu H T. Hybrid genetic ant colony algorithm for traveling salesman problem[J]. Computer Applications, 2008, 28(8): 2084-2088.)
- [23] 张弛, 涂立, 王加阳. 新型蚁群算法在TSP问题中的应用[J]. 中南大学学报: 自然科学版, 2015, 46(8): 2944-2949.
(Zhang C, Tu L, Wang J Y. Application of self-adaptive ant colony optimization in TSP[J]. J of Central South University: Science and Technology, 2015, 46(8): 2944-2949.)