

融合反向学习与Metropolis准则求解TSP的遗传算法

叶梓萌, 张大斌

(广东白云学院 大数据与计算机学院, 广东 广州 510450)

摘要: 针对传统遗传算法(GA)在求解巡回旅行商(TSP)问题时,因种群多样性、后期局部搜索寻优能力不足所导致全局搜索范围受限、易陷入早熟现象与收敛速度较慢的问题,基于种群逆转遗传算法(EROGA)融合反向学习(OBL)思想,模拟退火算法(SA)的Metropolis准则与现实精英学习理念,提出一种改进的遗传算法OBLGSAA。首先在生成初始种群环节采用反向学习方式,以提升最优解的精度与收敛速度;然后采用Metropolis准则改进交叉、变异算子,以提升算法的局部搜索能力;最后引入现实精英学习理念,通过贪心轮转学习机制进一步提升GA的局部搜索能力。在多种巡回旅行商数据集的仿真实验结果表明,OBLGSAA能有效改善GA种群的多样性,使算法不易陷入早熟收敛,并在收敛性能与求解精度上相较于原始EROGA更优,验证了算法的有效性与优越性。

关键词: 反向学习;Metropolis准则;遗传算法;旅行商问题

DOI:10.11907/rjdk.231452

开放科学(资源服务)标识码(OSID):



中图分类号:TP18

文献标识码:A

文章编号:1672-7800(2023)008-0104-07

Genetic Algorithm Combining Opposition-based Learning and Metropolis Criterion for TSP

YE Zimeng, ZHANG Dabin

(College of Big Data and Computer, Guangdong Baiyun University, Guangzhou 510450, China)

Abstract: When traditional genetic algorithm (GA) is used to solve traveling salesman problem (TSP), the global search scope is limited, and it is easy to fall into premature phenomenon and slow Rate of convergence due to the lack of population diversity and local search ability in the later stage. Based on the population inversion genetic algorithm (EROGA), which combines the idea of reverse learning (OBL), the Metropolis principle of Simulated annealing algorithm (SA) and the idea of real elite learning, an improved genetic algorithm OBLGSAA is proposed. First, reverse learning is adopted in the process of generating initial population to improve the accuracy and Rate of convergence of the optimal solution; Then, the Metropolis criterion is used to improve the crossover and mutation operators to enhance the local search ability of the algorithm; Finally, the concept of real-life elite learning is introduced to further enhance GA's local search ability through a greedy rotation learning mechanism. The simulation results on various traveling salesman datasets show that OBLGSAA can effectively improve the diversity of GA population, making the algorithm less prone to premature convergence, and outperforming the original EROGA in terms of convergence performance and solution accuracy, verifying the effectiveness and superiority of the algorithm.

Key Words: opposition-based learning; Metropolis criterion; genetic algorithm; traveling salesman problem

0 引言

求解旅行商(Traveling Salesman Problem, TSP)^[1]本质是求解 NP-hard^[2]组合优化问题,映射到现实社会具有实

际意义,已被广泛应用于物流运输^[3]、旅行路径规划^[4]、电网规划^[5]、生产作业^[6]等行业领域。求解该问题的算法包括动态规划算法^[7]、神经网络^[8]、遗传算法^[9]、蚁群算法^[10]、粒子群算法^[11]、模拟退火算法^[12]、免疫算法^[13]等,但由于 NFL(No Free Lunch)定理证明了各算法存在优劣

收稿日期:2023-05-04

基金项目:广东省科技创新战略专项资金(大学生科技创新培育)重点项目(PDJH2023A0647)

作者简介:叶梓萌(2002-),男,CCF学生会会员,广东白云学院大数据与计算机学院学生,研究方向为计算机应用;张大斌(1969-),男,博士,广东白云学院大数据与计算机学院教授、博士生导师,研究方向为大数据管理与应用。本文通讯作者:叶梓萌。

性, 尚无一种算法能解决所有实际问题, 为此诸多学者提出不相同的改进算法。

1967 年, J. Holland 提出遗传算法 (Genetic algorithm, GA), 基于自然界物竞天择、适者生存、不适者淘汰的生存进化法则进行设计, 但存在早熟、局部搜索能力较差等缺陷。为此, 许多学者基于此提出多种改进算法, 例如种群逆转遗传算法^[14]、探索—开发—跳跃策略单亲遗传算法^[15]、基于剪枝的改进遗传算法^[16]等。

本文在种群逆转改进遗传算法基础上, 针对遗传算法存在的早熟收敛、后期局部搜索寻优能力不足的问题, 通过改进初代种群、交叉算子与变异算子, 提出一种融合反向学习与 Metropolis 准则的遗传算法 OBLGSAA (Opposition-based Learning Genetic simulated Annealing Algorithm)。首先, 借助反向学习优化初代种群; 然后采用 Metropolis 准则改进交叉与变异算子以提升算法局部搜索能力; 最后, 引入现实精英学习理念, 通过贪心轮转学习机制进一步提升 GA 的局部搜索能力。在多种巡回旅行商数据集 (TSPLIB) 的仿真实验表明, 改进算法能增加种群多样性、有效优化收敛速度与求解精度。

1 旅行商问题描述

TSP 问题可定义为—组城市位置坐标集, 旅行者如何从组中一个坐标出发前往其他全部城市, 途径所有城市并返回起点城市的路径规划问题, 其解问题集可被定义为多组包含多个城市顺序排列的路线方案。

因此, 每组解集代表旅行者从最开始的路线坐标, 依照路线顺序途径所有排序路径坐标, 最终返回起点坐标, 具体数学模型如式 (1) 所示。

$$F(x) = \sum_{a=0}^{n-2} d_{x[a]x[a+1]} + d_{x[n-1]x[0]} \quad (1)$$

式中: n 为城市个数; $(x_1, x_2, \dots, x_n, x_1)$ 为城市路线顺序序列; $d_{x[a]x[a+1]}$ 表示 a 城市至 $a+1$ 城市的距离; $F(x)$ 表示途径所有城市并返回起点的总距离, 当 $F(x)$ 最小时 TSP 问题取得最优解。

2 反向学习机制

反向学习 (Opposition-based Learning, OBL)^[17] 的灵感源于现实事物之间的相对关系, 具体数学表达式如式 (2) 一式 (3), 多维反向学习机制定义如式 (4) 一式 (6):

$$x \in [a, b] \bar{x} = a + b - x \quad (2)$$

$$\text{when } a = 0 \text{ and } b = 1 \bar{x} = 1 - x \quad (3)$$

$$P = (x_1, x_2, \dots, x_n) \quad (4)$$

$$x_i \in [a_i, b_i] \bar{x}_i = a_i + b_i - x_i \quad (5)$$

$$\bar{P} = (\bar{x}_1, \bar{x}_2, \dots, \bar{x}_n) \quad (6)$$

式中: x 为实数集; \bar{x} 为生成的反向实数集; P 为 n 维数

据集; \bar{P} 为反向 n 维数据集。

基于上述定义, 设 $f(x)$ 为求解函数, $g(f(x))$ 为适应度评价函数。如果 x 为 $[a, b]$ 中的随机猜测, \bar{x} 为反向猜测, 则首先在每次迭代时计算 $g(f(x))$ 、 $g(f(\bar{x}))$; 然后借助精英保留策略, 当 $g(f(x)) > g(f(\bar{x}))$ 时保留 x 猜测, 否则保留 \bar{x} 反向猜测。基于反向学习二分法求解一维问题过程如图 1 所示。




Fig. 1 One-dimensional binary reverse learning mechanism

图 1 一维二分反向学习机制

3 OBLGSAA 算法设计

3.1 算法流程

OBLGSAA 算法流程如下, 流程图如图 2 所示。

步骤 1: 输入要求解 TSP 问题的 n 个城市横纵坐标。

步骤 2: 以城市坐标数 n 为长度的二维数组表示该问题的一个解。

步骤 3: 初始化参数。设置 GA 迭代次数 Gen_{max} 、交叉率 P_c 变异率 P_m 、初始温度 T_0 、目标退火温度 T_{obj} 、降温幅度 q 、设定适应度函数 $F(x)$ 。针对 TSP 问题, 适应度函数为城市间距离的倒数。

步骤 4: 反向学习初始化。根据式 (8) 一式 (12) 的随机种群 $P(N)$ 与反向种群 $OP(N)$ 生成初始种群 $P_{initial}$ 。

步骤 5: 计算适应度。利用轮盘赌算法进行选取操作, 种群中 n 个染色体, 第 i 个被选取的概率为:

$$P_i = \frac{\frac{1}{F(x_i)}}{\sum_j^n \frac{1}{F(x_j)}} \quad (7)$$

式中, $F(x)$ 为适应度函数。

步骤 6: 根据式 (13) 一式 (15) 进行 Metropolis 策略交叉。

步骤 7: 根据图 4—图 6 进行贪心精英轮转学习。

步骤 8: 根据式 (13) 一式 (15) 借助 Metropolis 准则进行变异操作。

步骤 9: 根据图 3 进行种群逆转操作。

步骤 10: 开始迭代。每次迭代后按降温幅度 q 进行退火降温, 最后判定是否已达最大迭代次数, 否则进行步骤 5。

步骤 11: 输出最优解, 即算法迭代完成后的旅行城市

路径距离最优值。

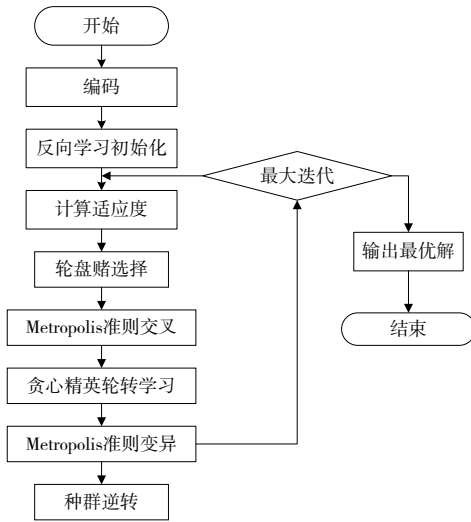


Fig. 2 OBLGSAA process
图2 OBLGSAA 流程

3.2 改进种群初始化

首先随机生成种群,依照反向学习机制生成反向种群;然后选取两个种群中适应度最高的 N 个个体,构成初代种群 $P_{initial}$, GA 反向学习机制为:

$$P(N) = (C_1, C_2, \dots, C_n) \quad (8)$$

$$OP(N) = (\bar{C}_1, \bar{C}_2, \dots, \bar{C}_n) \quad (9)$$

$$C = (c_1, c_2, \dots, c_i, \dots, c_n) \quad (10)$$

$$\bar{C} = (\bar{c}_1, \bar{c}_2, \dots, \bar{c}_i, \dots, \bar{c}_n) \quad (11)$$

$$\bar{c} = a_i + b_i - c_i, c_i \in [a_i, b_i] \quad (12)$$

式中: $P(N)$ 为随机种群; $OP(N)$ 为反向种群; C 为原始个体; \bar{C} 为反向个体; c 为原染色体基因; \bar{c} 为反向染色体基因。

3.3 改进交叉、变异算子

本文将对交叉、变异算子产生的新个体 I_{new} 引入 Metropolis 准则。

首先,在 GA 初始参数下增添初始温度 T_0 、目标退火温度 T_{obj} 、降温幅度 ΔT 。然后,随机生成接受恶化解判定概率 $rand$ ($rand \in [0, 1]$), 计算新个体 I_{new} 与原始个体 I_{old} 的适应度函数 $F(x)$ 值。最后,根据式(14)依据个体适应度差值 df 进行接受新个体的初次判定,若不接受则根据式(15)将 df 与当前温度 T 进行二次判定 (Metropolis 准则恶化解接受判定), 然后根据式(16)执行降温操作。

$$df = F(I_{new}) - F(I_{old}) \quad (13)$$

$$\begin{cases} \text{if } df > 0 & \text{accept} \\ \text{else } df < 0 & \text{Metropolis} \end{cases} \quad (14)$$

$$\begin{cases} \text{if } \text{Exp}(-\frac{df}{T}) > rand & \text{accept} \\ \text{else} & \text{eliminate} \end{cases} \quad (15)$$

$$T_{i+1} = T_i - \Delta T \quad (16)$$

3.4 种群进化逆转操作

种群进化逆转的目的是增加种群进化逆转操作,以提升 GA 局部寻优能力^[14]。首先,在新生成的子代种群个体中,随机选取 r_1 、 r_2 染色体基因位置。然后,按相反顺序倒转处于 r_1 与 r_2 间的基因串后插入原染色体位置,形成新的个体基因串。相较于交叉算子,该操作可使子代继承父代更多基因信息,且运用了精英保留策略,仅接受个体向适应环境的方向逆转进化,因此搜索寻优能力更强。

		r_1		r_2	
父代	1	2	3	4	5
种群逆转					
子代	1	4	3	2	5

Fig. 3 Population reversal operation process
图3 种群逆转操作过程

3.5 贪心精英轮转学习机制

现实中通过学习其他优秀个体,提升自身竞争力是一种常见、有效的学习策略。本文借助该思想提出以贪心算法为基础的贪心精英轮转策略。首先,通过筛选种群个体中最优异的两个精英个体,将其与剩余个体进行精英轮转学习。然后,将个体适应度筛选分离成染色体基因的适应度,通过轮转思想保证种群个体的多样性。最后,运用贪心机制选取最适合的染色体基因来保证种群个体优异性,以此提升 GA 的全局与局部搜索能力。

贪心精英轮转学习步骤如下:

步骤1:生成首位基因。随机生成精英轮转学习后产生个体 D 的首位染色体基因,然后查找该基因在各原个体中基因的索引位。

步骤2:首位基因轮转。如图4、图5所示,将 $A_1A_2A_3$ 首位基因以 D 的首位基因为基础向右轮转形成 $A_{1a}A_{2a}A_{3a}$ 。

A_1	1	2	3	4	5	6	7
轮转							
A_{1a}	2	3	4	5	6	7	1

Fig. 4 Process of population individual greedy elite rotation learning operation

图4 种群个体贪心精英轮转学习操作过程

$i=1$	d_1	d_2	d_3	d_4	d_5	d_6	d_7
A_{1a}	2	3	4	5	6	7	1
A_{2a}	2	6	7	4	3	1	5
A_{3a}	2	4	3	1	6	7	5
D	2						

Fig. 5 Process of revolving learning for greedy elite with multiple individuals in a population

图5 种群多个体贪心精英轮转学习操作过程

步骤3:剩余基因更新轮转。计算染色体 $A_{1a}A_{2a}A_{3a}$ 中 d_{i+1} 与 d_i 位基因间的适应度得到 $l_1l_2l_3$, 接着选取适应度最高的 l_i , 并以 l_i 的原染色体 A_{ia} 的 d_{i+1} 位基因作为学习个体 D 的 d_{i+1} 位基因,如图6所示。其中, $d_1 = 2$; $d_{i+1} = 4$; A_1A_2 为精英个体; A_3 为非精英个体; D 为精英轮转学习后产生

的个体; d_i 为染色体第 i 位基因。

步骤 4: 重复步骤 3 直至产生完整的 D 个体。

$i=2$	d_1	d_2	d_3	d_4	d_5	d_6	d_7
A_{1a}	2	4	5	6	7	1	3
A_{2a}	2	4	3	1	5	6	7
A_{3a}	2	4	3	1	6	7	5
D	2	4					

Fig. 6 Recurrent learning operation process for updating greedy elites with multiple individuals in a population

图 6 种群多个体贪心精英更新轮转学习操作过程

4 实验仿真与结果分析

为了充分比较改进遗传算法的有效性与优越性, 以 GA、种群逆转遗传算法(EROGA)^[14]为基础仿真实验算法测试用例, 分别运用反向学习机制(OBLEROGA)与 Metropolis 准则(SAEROGA)对种群逆转遗传算法进行改进。

4.1 测试环境与算法参数

本文实验 CPU 为 Ryzen 54600H 3.00 GHz, 运行内存为 16 GB, 操作系统为 Windows10, 仿真模拟环境为 MATLAB r2017a。

为了验证算法改进效果, 设置比较算法种群规模 $N=30$, 迭代次数 $Gen=1\ 000$, 交叉概率 $P_c=0.9$, 代沟 $GGAP=0.9$, 考虑到 GA、OBLEROGA、EROGA 的变异率设定过高会在迭代过程中遗失优质个体, 因此将上述 3 种算法的变异率 P_m 设定为 0.05, 而 SAEROGA、OBLGSAA 因引入 Metropolis 准则, 能在迭代过程中保留优质个体, 便将算法的变异率 P_m 提高到 0.09。实验具体参数定义如下:

(1) 参数定义。设本文定种群规模 $N=30$, 迭代次数 $Gen=1\ 000$, 交叉概率 $P_c=0.9$, 变异概率 $P_m=0.09$, 代沟 $GGAP=0.9$ 。

(2) 融合反向学习与 Metropolis 准则改进遗传算法(OBLGSAA)算法、反向学习逆转遗传算法(OBLEROGA)、Metropolis 逆转遗传算法(SAEROGA)、通过种群逆转进化的改进遗传算法(EROGA)、传统遗传算法(GA)的种群规模 $N=30$, 迭代次数 $Gen=1\ 000$, 交叉概率 $P_c=0.9$, 变异概率 $P_m=0.05$, 代沟 $GGAP=0.9$ 。

其中, 融合反向学习与 Metropolis 准则改进遗传算法(OBLGSAA)算法的初温 $C_0=1e1$; 目标退火温度 $C_2=1e-40$; 降温速率 $q=0.9$ 。在上述参数基础上, 分别运用 5 种算法对 TSPLIB 数据集的 Eil51、Eil76、Oliver30、pr76、Eil101、st70 进行 50 次仿真实验, 统计结果如表 1、图 7—图 18 所示。

4.2 种群多样性分析

由图 7—图 11 可见, OBLEROGA 在变异概率 $P_m=0.05$ 时, 算法初期(迭代 100 次前)种群多样性均值为 0.933, 相较于 EROGA、GA 的种群多样性均值分别提升 6.14% (0.879)、51.4% (0.616), 证明了反向学习机制可优化种群多样性。SAEROGA 前期以高概率、后期低概率接收恶化

解, 因此会造成前期多样性较高, 后期多样性迅速降低的现象。结合反向学习、Metropolis 准则与贪心精英轮转学习机制的 OBLGSAA 种群多样性明显优于其他算法, 算法运行全过程多样性均保持在 0.75 上下, 震荡幅度小于 30%, 证实了本文算法不易因种群多样性陷入早熟问题。

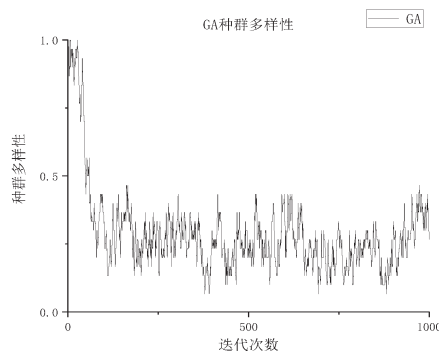


Fig. 7 GA population diversity

图 7 GA 种群多样性

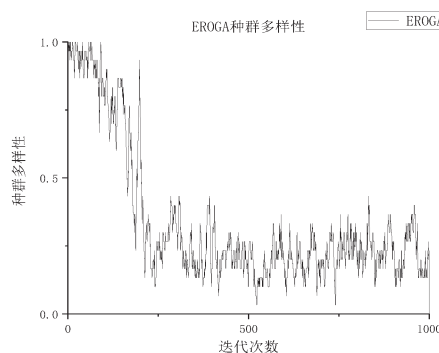


Fig. 8 EROGA population diversity

图 8 EROGA 种群多样性

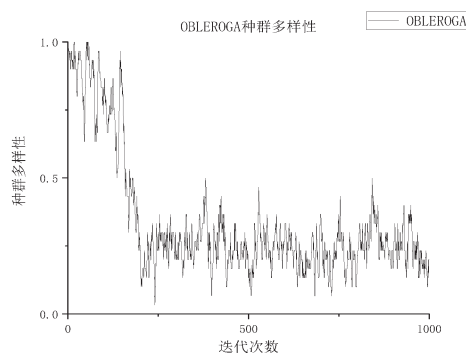


Fig. 9 OBLEROGA population diversity

图 9 OBLEROGA 种群多样性

4.3 收敛速度与效率分析

收敛速度与效率是评价算法性能的重要度量指标, OBLEROGA 因反向学习机制在初始阶段提供了多样性更高的优质种群, 算法前期收敛速度虽提升并不明显, 如图 12 所示。

由图 12 可见, EROGA 在迭代 163 次后陷入局部最优, OBLEROGA 算法却能保持高效收敛持续迭代 250 次, 证实

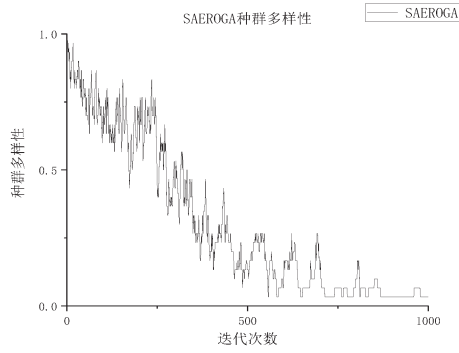


Fig.10 SAEROGA population diversity

图10 SAEROGA 种群多样性




Fig. 11 OBLGSAA population diversity

图11 OBLGSAA 种群多样性




Fig. 12 Optimization curves of various algorithms in Oliver30 data set

图12 Oliver30数据集各算法优化曲线

了反向学习能优化收敛效率。SAEROGA因Metropolis准则改进交叉与变异算子,在迭代122次就收敛于最优解附近且收敛速度优于EROGA,证明了该准则能有效提升GA的局部搜索能力。OBLGSAA结合反向学习与Metropolis准则,并进一步引入贪心精英学习轮转,在迭代早期(55代)就已收敛至最优解附近。

综上,当算法迭代总次数为1000时,OBLGSAA取得最优解的平均迭代次数相较于GA、EROGA、OBLEROGA、SAEROGA分别减少931.28、301.16、236.92、162.37次,不同数据集的收敛曲线验证了OBLGSAA收敛速度与效率的优异性,如图13—图17所示。




Fig. 13 Optimization curves of various algorithms in Eil151 data set

图13 Eil151数据集各算法优化曲线




Fig. 14 Optimization curves of various algorithms in Eil176 data set

图14 Eil176数据集各算法优化曲线




Fig. 15 Optimization curves of various algorithms in Eil101 data set

图15 Eil101数据集各算法优化曲线




Fig. 16 Optimization curves of various algorithms in Pr76 data set

图16 Pr76数据集各算法优化曲线




Fig. 17 Optimization curves of various algorithms in St70 data set

图 17 St70 数据集各算法优化曲线

4.4 寻优精度分析

由图 12、图 18 可见, OBLEROGA 的平均寻优精度为 438, 高于 EROGA 的 455, 表明反向学习策略可优化求解精度。SAEROGA 寻优精度为 431, 同样高于 EROGA 的 455, 说明 Metropolis 准则策略能有效提升算法寻优精度。OBLGSAA 结合上述改进策略, 并添加贪心精英轮转学习策略, 获得的平均寻优精度为 424。

综上, OBLGSAA 相较于 EROGA 极大提升了搜索收敛速度与效率, 种群迭代早期已收敛于最优解附近, 通过种群多样性跳出局部搜索寻优中的局部最优, 以此不断优化算法搜索全局最优解, 使得 OBLGSAA 的全局精度最优。

4.5 稳定性与适用范围分析

除了收敛速度与求解精度外, 稳定性与适用范围也是

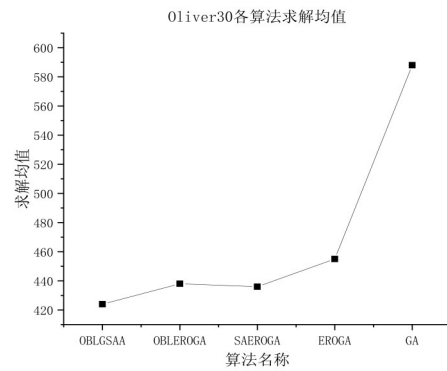


Fig. 18 The mean of Oliver30 data set solved by various algorithms

图 18 Oliver30 数据集各算法求解均值

判定算法优异性的度量指标。本文将算法应用于不同规模的 TSP 数据集, 统计结果如表 1 所示。由此可知, OBLGSAA 在不同规模数据集集中的最优解平均值、标准差及最优解迭代次数等数据均表现最佳, 证实了该方法通用于简单与复杂问题集, 且在一定程度上求解稳定性较高、适用范围较广。

4.6 计算复杂度分析

由于遗传算法复杂度计算较为复杂, 因此本文选择分析改进前后算子的时间复杂度差异。假定种群大小 p 、迭代 T 次、城市规模为 n 、代沟 g 、交叉率 c 、变异率 i 、单次计算适应度的时间复杂度 f 、交叉时间复杂度 b 、变异时间复杂度 m , 采用随机初始化生成初始种群时间复杂度为 $O(pn)$,

Table 1 Statistical analysis of multiple TSP datasets solved by various algorithms

表 1 各算法求解多种 TSP 数据集统计

实例	算法名称	最优解	平均值	标准差	平均迭代次数	迭代总次数
st70	OBLGSAA	681	698	8.5	260.32	1 000
	OBLEROGA	740	742	1	1 000	1 000
	SAEROGA	702	727	12.5	578.96	1 000
	EROGA	738	784	23	804.43	1 000
	GA	1 570	1 672	51	1 000	1 000
Eil51	OBLGSAA	433	436	1.5	780.04	1 000
	OBLEROGA	451	462	5.5	572.43	1 000
	SAEROGA	452	462	5	288.32	1 000
	EROGA	455	465	5	536.76	1 000
	GA	631	716	42.5	1 000	1 000
Eil76	OBLGSAA	551	563	6	730.13	1 000
	OBLEROGA	584	606	11	956.76	1 000
	SAEROGA	578	604	13	645.82	1 000
	EROGA	586	623	18.5	978.87	1 000
	GA	1 024	1 152	64	1 000	1 000
Eil101	OBLGSAA	649	663	7	897.38	1 000
	OBLEROGA	756	833	38.5	1 000	1 000
	SAEROGA	701	716	7.5	907.21	1 000
	EROGA	771	811	20	1 000	1 000
	GA	1 539	1 593	27	1 000	1 000
Oliver30	OBLGSAA	423	424	0.5	68.72	1 000
	OBLEROGA	424	438	7	305.64	1 000
	SAEROGA	425	431	3	231.09	1 000
	EROGA	425	455	15	369.88	1 000
	GA	573	588	7.5	1 000	1 000

续表

实例	算法名称	最优解	平均值	标准差	平均迭代次数	迭代总次数
pr76	OBLGSAA	109 948	111 026	539	778.25	1 000
	OBLEROGA	115 910	123 583	3 836.5	1 000	1 000
	SAEROGA	112 985	116 989	2 002	925.93	1 000
	EROGA	116 947	124 080	3 566.5	986.54	1 000
	GA	240 228	258 522	9 147	1 000	1 000

反向初始化需对每个随机生成的个体进行 n 次反向机制计算,再从原始随机个体与反向个体中筛选适应度最高的 p 个个体,则时间复杂度为 $O(pfn^2)$ 。由于初始化只需执行一次,因此对算法整体影响可忽略不计。

在交叉与变异阶段,GA 交叉与变异时间复杂度分别为 $O(Tpgcb)$ 与 $O(Tpgim)$,引入 Metropolis 准则的交叉与变异需计算新旧个体适应度,因此时间复杂度为 $O(Tpgcbf)$ 与 $(Tpgimf)$,贪心轮转学习的时间复杂度为 (Tp^2gnf) ,种群逆转操作时间复杂度为 $(Tpgnf)$ 。

综上,OBLGASS 的时间复杂度与计算适应度的时间复杂度 f 关系较大,虽然增加了 GA 的时间复杂度,但能有效改善算法的收敛速度与求解精度,在高性能计算中可发挥较大优势。

5 结语

本文借助反向学习机制、Metropolis 准则与贪心精英轮转学习策略,在 EROGA 的基础上提出 OBLGSAA。在求解多种 TSPLIB 数据集的测试结果表明,反向学习机制既能显著提升种群多样性、算法最优解精度,还能有效避免算法早熟导致的全局搜索能力下降问题。

同时,在局部搜索寻优性能方面,引入 Metropolis 准则与贪心精英轮转学习策略的 OBLGSAA 算法明显优于 EROGA 算法,并且因反向学习、Metropolis 准则、贪心精英轮转学习策略数据结构简单,易理解、实现与扩展,因此实际应用价值更高、应用范围更广。

参考文献:

- [1] DANTZIG G B, FULKERSON R D, JOHNSON M S. Solution of a large-scale traveling-salesman problem[J]. *Operations Research*, 1954, 2(4): 393-410.
- [2] ZHENG J Y, CHENG X Q, FU J J. Application of improved ant colony algorithm in TSP[J]. *Computer Simulation*, 2021, 38(5): 126-130, 167. 郑娟毅,程秀琦,付姣姣.改进蚁群算法在TSP中的应用研究[J].计算机仿真,2021,38(5):126-130,167.
- [3] STEPHEN O, YANG J Q, ANUM C A. Optimizing the sustainable multimodal freight transport and logistics system based on the genetic algorithm[J]. *Sustainability*, 2022, 14(18): 11577.
- [4] CAO S. An optimal round-trip route planning method for tourism based on improved genetic algorithm[J]. *Computational Intelligence and Neuroscience*, 2022(2022): 7665874.
- [5] QIN H L, LI K, CHEN Z J. Non-Pareto genetic algorithm for optimal planning of multi-type energy resources in active distribution networks[J]. *Frontiers in Energy Research*, 2022, 10: 966549.
- [6] VALLEJOS C P, RAMIREZ G C, ESCUDERO A A, et al. Energy-aware

production scheduling in flow shop and job shop environments using a multi-objective genetic algorithm[J]. *Engineering Management Journal*, 2019, 31(2): 133851.

- [7] DAN K, DUAN L Z. Dynamic programming algorithm for travel salesman problem based on optimal insertion subset[J]. *Journal of Computer Applications and Software*, 2002, 39(12): 260-265, 297. 但开,段隆振.基于最优插入子集的动态规划算法求解旅行商问题[J].计算机应用与软件,2022,39(12):260-265,297.
- [8] PRATES M, AVELAR H C P, LEMOS H, et al. Learning to solve NP-complete problems: a graph neural network for decision TSP [DB/OL]. <https://arxiv.org/abs/1809.02721>.
- [9] SACHIN S, VINOD J. A novel approach for solving TSP problem using genetic algorithm problem[J]. *IOP Conference Series: Materials Science and Engineering*, 2021, 1116(1): 012194.
- [10] YUAN W H, YOU X M, LIU S, et al. Adaptive simulated annealing ant colony algorithm for TSP problem[J]. *Computer Applications and Software*, 2018, 35(2): 261-266. 袁汪凤,游晓明,刘升,等.求解TSP问题的自适应模拟退火蚁群算法[J].计算机应用与软件,2018,35(2):261-266.
- [11] HONG L. A novel quantum genetic algorithm in TSP[J]. *Applied Mechanics and Materials*, 2014(519-520): 757-761.
- [12] CHEN S Z, ZHANG J H, YU S S, et al. A fluctuating temperature controlled simulated annealing algorithm for traveling salesman problem[J]. *Control and Decision*, 2022, 38(4): 911-920. 陈晟宗,张纪会,于守水,等.求解旅行商问题的波动温控模拟退火算法[J].控制与决策,2022,38(4):911-920.
- [13] FENG Z Y, YOU X M, LIU S. A hierarchical and progressive improved clustering ant colony algorithm for solving TSP problems[J]. *Journal of Computer Science and Exploration*, 2019, 13(8): 1280-1294. 冯志雨,游晓明,刘升.分层递进的改进聚类蚁群算法解决TSP问题[J].计算机科学与探索,2019,13(8):1280-1294.
- [14] GE X M, LI S H. Research on multi-objective shop layout optimization based on improved genetic algorithm[J]. *Modern Manufacturing Engineering*, 2021(3): 9-14. 葛晓梅,李世豪.基于改进遗传算法的多目标车间布局优化问题研究[J].现代制造工程,2021(3):9-14.
- [15] CHEN J J, TAN D L. A single parent genetic algorithm based on exploration-development-jump strategy for traveling salesman problem[J]. *Computer Application Research*, 2023, 40(5): 1375-1380. 陈加俊,谭代伦.求解旅行商问题的探索-开发-跳跃策略单亲遗传算法[J].计算机应用研究,2023,40(5):1375-1380.
- [16] JI S S, HUANG Y Y, ZHANG H, et al. Fire distribution optimization model based on improved genetic algorithm research[J]. *Journal of Nanjing University of Science and Technology*, 2023, 47(1): 33-40. 季顺松,黄炎焱,张寒,等.基于改进遗传算法的火力分配寻优模型研究[J].南京理工大学学报,2023,47(1):33-40.
- [17] TIZHOOSH H R. Opposition-based learning: a new scheme for machine intelligence[C]// *International Conference on International Conference on Computational Intelligence for Modelling, Control & Automation*, 2005: 695-701.

(责任编辑:刘嘉元)