

田倩, 潘大志. 改进遗传算法求解 0-1 定时炸弹背包问题[J]. 智能计算机与应用, 2026, 16(4): 226-237. DOI: 10.20169/j.issn.2095-2163.25112602

改进遗传算法求解 0-1 定时炸弹背包问题

田倩, 潘大志

(西华师范大学 数学科学学院, 四川 南充 637009)

摘要: 针对 0-1 定时炸弹背包问题(0-1 Time-Bomb Knapsack Problem)这一具有 NP 难特性的组合优化问题, 提出了一种精英导向的自适应遗传算法(EGALS-GA)。该算法构建 3 层协同优化架构: 首先, 设计精英引导的进化机制, 在交叉操作中注入 20%~30% 的精英基因片段, 并在变异操作中实施基于差异位的精英导向扰动, 强化优质基因的传播; 其次, 建立动态自适应体系, 通过精英影响因子实现变异强度的衰减控制, 平衡全局探索与局部开发。最后, 引入精英自学习策略, 对每代前 20% 的精英个体执行变邻域局部搜索, 增强局部优化能力。在标准测试集上的实验表明 EGALS-GA 在保持标准遗传算法时间复杂度的前提下, 加快了收敛速度, 且对高维算例表现稳健。该方案为 01-TB-KP 问题提供了高效的求解框架, 适用于解决各领域中涉及风险因素的实际问题。

关键词: 0-1 定时炸弹背包问题; 遗传算法; 风险感知优化; 随机组合问题; 精英自学习策略

中图分类号: TP181; O224

文献标志码: A

文章编号: 2095-2163(2026)04-0226-12

Enhanced genetic algorithm for solving the 0-1 Time-Bomb Knapsack Problem

TIAN Qian, PAN Dazhi

(School of Mathematical Sciences, China West Normal University, Nanchong 637009, Sichuan, China)

Abstract: Focusing on the 0-1 Time-Bomb Knapsack Problem, an NP-hard combinatorial optimization problem, an elitism-guided adaptive genetic algorithm (EGALS-GA) was proposed. A three-layer collaborative optimization framework was constructed; first, an elitism-guided evolution mechanism was designed, in which 20%-30% of elite gene fragments were injected into the crossover operation, and elite-oriented perturbations based on differential bits were implemented during mutation to enhance the propagation of high-quality genes; second, a dynamic adaptive system was established, where the attenuation of mutation intensity was controlled through an elite influence factor to balance global exploration and local exploitation; finally, an elite self-learning strategy was introduced, in which a variable neighborhood local search was performed on the top 20% of elite individuals in each generation to improve local optimization capability. Experiments conducted on standard test sets showed that EGALS-GA accelerated convergence speed and exhibited stable performance on high-dimensional instances while maintaining the time complexity of the standard genetic algorithm. This scheme provides an efficient solution framework for the 01-TB-KP and is suitable for addressing practical problems involving risk factors across various fields.

Key words: 0-1 Time-Bomb Knapsack Problem; genetic algorithm; risk-aware optimization; stochastic combinatorial problem; elite self-learning strategy

0 引言

0-1 背包问题^[1] (0-1 Knapsack Problem, 0-1KP) 是组合优化领域的经典问题, 其应用范围广泛, 涉及物流、金融和资源分配等多个领域。在该问

题的基础上发展出了众多变体, 如多维背包^[2]、0-1 折扣背包^[3]、有界背包^[4]等, 都是背包问题中的热点问题。Monaci 等^[5]在 0-1 KP 问题的基础上提出了 0-1 定时炸弹背包问题 (01-TB-KP), 因其引入了现实世界中固定的不可预测因素, 所以归属于随

基金项目: 国家自然科学基金(11871059); 四川省教育厅自然科学基金(18ZA0469)。

作者简介: 田倩(2001—), 女, 硕士研究生, 主要研究方向: 智能计算, 组合优化。

通信作者: 潘大志(1974—), 男, 博士, 教授, 主要研究方向: 智能计算, 算法设计。Email: pdzjz@126.com。

收稿日期: 2025-11-26

机背包问题。在01-TB-KP中部分物品有一个爆炸概率,如果选择一个会爆炸的物品放入背包,则背包就有了爆炸的风险,若是背包中的物品发生了爆炸则背包损坏,所有利润都将消失。这一模型可用于高风险领域,例如危险材料的运输,比如当车辆装载具有火灾风险的锂离子电池^[6],若是运输途中发生意外,则整个车辆的物品都将损毁。在数据中心管理中,此背包模型可用于分配虚拟机到服务器或应用程序到容器。容器中运行的应用能带来收益,不过若某一应用出现可被黑客利用的漏洞,就可能让入侵者掌控整个容器,导致所有收益丢失。

目前针对01-TB-KP问题,Monaci等^[5]提出了朴素枚举法、动态规划法、带有多种可选分支策略的定制化分支定界法,共3种适应该问题的精确算法;Montemanni等^[7]提出了两种基于模型的算法,均利用对数的性质将模型中的非线性关系转化为线性形式。其中一种以最大化利润为目标,将生存概率作为约束;另一种以最大化生存概率为目标,将利润作为约束。且均利用约束条件保证解的差异性,通过迭代,求解整数线性规划问题。尽管Monaci等^[5]定制化的精确算法和Montemanni等^[7]提出的算法均可有效求解中小规模的01-TB-KP,但当算例规模突破5000个物品、炸弹物品比例超过50%时,前者因搜索空间的扩张、后者因线性化子问题的求解难度增大,都使得耗时增加,难以满足实际决策的实时性需求。在面对当物品数量增多、背包容量变大,计算效率随之降低的问题时,元启发算法作为一种近似搜索算法已逐渐成为处理这种大规模问题的主要手段^[8]。典型的元启发算法包括模拟退火(Simulated Annealing, SA)^[9]、蚁群优化(Ant Colony Optimization, ACO)^[10]、粒子群优化(Particle Swarm Optimization, PSO)^[11]、禁忌搜索(Tabu Search, TS)^[12]以及帝王蝶优化算法^[13]等,通过模仿自然现象或群体智能行为,在合理时间内获得高质量可行解。

遗传算法^[14](Genetic Algorithm, GA)是一种典型的进化型算法,其凭借独特的选择、交叉、变异算子以及概率化的寻优方式,能够自动掌握解空间的布局,还能自适应地调整搜索状态,因此具备较强的全局协同搜索能力,被广泛应用于各类复杂优化问题。研究者们针对不同应用场景的需求,对遗传算法进行了持续的改进与创新。Sharma等^[15]利用遗传算法对从深度学习模型提取的高维特征进行筛选,有效提升了水稻病害图像分类的准确率;Li

等^[16]构建了一个多模态改进的遗传算法框架,将其应用于医疗软件工程的成本估算,显著提高了模型的预测精度与稳定性;Li等^[17]引入自适应迁移策略对遗传算法进行增强,成功解决了5G通信基站选址中成本、覆盖与干扰的多目标优化问题;Xu等^[18]将改进的遗传算法与脉冲神经膜系统融合,提出了双变异策略,用于高效求解二进制优化问题(如0-1背包问题);Sun等^[19]采用改进遗传算法,实现了五轴测量中探头姿态与测量路径的协同优化,大幅提升了复杂曲面的检测效率;Zou等^[20]将强化学习与多目标遗传算法深度融合,利用Q学习自适应选择进化算子,以应对大规模个性化制造背景下柔性作业车间的节能调度挑战。

为解决01-TB-KP的问题,本文提出了基于精英引导的自适应学习遗传算法(Elite-Guided Adaptive Learning Search Genetic Algorithm, EGALS-GA)。在交叉阶段引入20%~30%精英基因注入,变异阶段实施基于差异位的精英导向扰动,利用精英个体引导种群进化方向。并设计精英影响因子实现变异强度随进化代数的自适应衰减,平衡算法的探索与开发。最后对每代的父代和子代中选出前20%精英个体执行变邻域局部搜索,通过5次迭代的定向优化突破局部最优。算法在不同性质的问题及大规模的测试集上进行了测试,显示出较好的性能。

1 01-TB-KP问题

现有物品集合 $A = \{1, 2, \dots, n\}$ 和一个容量为 $C \in N^*$ 的背包,每个物品 $i \in A$ 都有各自的价值 p_i 、重量 w_i 和爆炸概率 π_i ,选取一组满足背包容量约束和安全概率约束的子集 T ,使其期望价值之和最大。

$$\max f(x) = \left(\sum_{i=1}^n p_i x_i \right) \left(\prod_{i \in T} q_i x_i \right) \quad (1)$$

$$\text{s. t. } \sum_{i=1}^n w_i x_i \leq C \quad (2)$$

$$\prod_{i \in T} q_i x_i \geq Q \quad (3)$$

$$x_i \in \{0, 1\}, i \in \{1, 2, \dots, n\} \quad (4)$$

其中, $f(x)$ 是为所有选入背包的物品的期望价值也是本文的适应度函数; x_i 为决策变量, $x_i = 1$ 表示物品被选择, $x_i = 0$ 表示不被选择; $q_i = 1 - \pi_i$ 为物品的安全概率,在背包中若选中的物品发生爆炸,则整个背包失效;公式为了符合生活实际,加入了背包的安全约束,即背包中放入的物品的总的安全概

率不能小于一定的数值,不然背包过于危险会使其与现实选择方案相悖。 Q 为背包的最小安全约束,为了能在后期的各类算例中有效应用,将其大小设为 0.8。在实际应用中可将其设置为符合问题实际的数值。

2 基于精英引导的自适应学习遗传算法

2.1 随机初始化

本文采用二进制编码,种群内的每个个体均被随机编码为一个 n 维 0-1 向量。其中,1 表示对应物品被选入背包,0 表示该物品未被放入背包, n 为物品的数量。

2.2 解的修复

遗传算法求解背包问题时,种群初始化、交叉与变异操作通常基于随机机制生成候选解,常会产生不满足背包约束的不可行解。因此,本文引入了一种解修复机制,将不可行解转化为满足约束的可行解。

算法 1 修复算法

步骤 1 计算每一物品的单位安全价值密度 σ_i

$= \frac{q_i \times p_i}{w_i}$, 并依 σ_i 降序对物品进行排序。

步骤 2 计算当前解的总重量和安全概率,若违反背包的容量约束或者安全约束则转至步骤 3,否则返回当前解。

步骤 3 从序号最大的物品开始向前遍历,若当前物品已放入背包,则将其移除并更新总重量和安全概率。

步骤 4 重复步骤 3,直至满足所有约束条件,返回修复后的解。

2.3 锦标赛选择

锦标赛选择^[21]是遗传算法中常用的父代选择方式,是一种高效且易于实现的选择机制,核心思想是通过小规模竞争来筛选优质个体。本文采用二元锦标赛策略,该方法在维持种群多样性与选择压力之间取得良好平衡。

算法 2 二元锦标赛选择算法

步骤 1 从种群中随机无放回地选取两个个体。

步骤 2 比较这两个个体的适应度值,选择适应度较高者进入父代种群。

步骤 3 重复步骤 1-2,直至父代种群规模达到预设值。

其中每个个体被选中的概率为:

$$P_i = \frac{2}{n} \times \frac{n - r_i}{n - 1} \quad (5)$$

其中, r_i 为个体 i 的适应度值的排名,例如当个体适应度值最大时其排名为 1。

2.4 精英导向交叉操作

本文设计的精英导向交叉算子,结合了传统交叉操作的探索能力和精英个体的开发引导能力。其核心思想是将当前种群中最优个体(精英)的优质基因片段有选择地注入到子代中,从而加速算法收敛并提高解的质量。

算法 3 精英导向交叉算法

步骤 1 设置交叉概率 P_c , 选取两个普通个体进行传统的两点交叉操作;

步骤 2 在精英种群中随机选取一个精英个体 e_i ;

步骤 3 在交叉生成的两个个体中随机选择基因注入点,将精英个体 20%~30% 的优秀基因注入其中。

步骤 4 重复上述过程,直至所有个体处理完毕,并利用算法 1 对个体进行修复,形成新种群。

2.5 精英引导变异操作

精英引导变异是一种结合基础随机变异和精英引导的混合变异策略。该策略在保留传统随机变异全局探索能力的基础上,引入精英个体的信息引导局部开发,通过动态调整精英影响力实现探索与开发的平衡。该操作在保持种群多样性的同时,利用精英个体的信息引导变异方向,显著提高算法收敛效率。

算法 4 精英引导变异算法

步骤 1 对种群中每个个体的每个基因,以固定概率 P_m 进行基因位的翻转。

步骤 2 计算动态精英影响因子 $\varphi = \alpha \times (1 - \frac{g}{G_{\max}}) + \varphi_0$ 。其中, φ_0 为最小精英影响因子,取值为 0.1; g 为当前代数; G_{\max} 为最大迭代次数; α 为调节系数,取值为 0.5。该因子随进化进程线性递减,确保了早期强化精英引导而后期保障种群多样性。

步骤 3 以概率 φ 触发精英引导变异操作,确定当前个体与精英个体之间的差异基因位点集合 $D = \{i \mid x_i \neq e_i\}$ 。

步骤 4 采用自适应变异强度策略,随机确定变异点数量 $I = \min\{K, |D|\}$,其中 $K = \text{randi}([1, 3])$, $|D|$ 为差异点总数,确保变异强度与差异程度相适应。

步骤 5 从差异位置集合中随机选择 l 个点执行基因翻转操作, 实现定向优化。

步骤 6 重复上述步骤 1~5, 直至所有个体完成变异, 并利用算法 1 将所有个体修复, 形成新种群。

2.6 精英个体的自学习策略

将父代种群与子代种群合并为一个家庭种群, 在家庭种群中筛选出适应度值排名前 20% 的个体作为精英个体。再对每一代的精英个体进行变邻域

搜索, 这一操作也可视为精英算子对自身不断学习的过程, 有利于种群在优秀基因上的深度探索, 从而提高算法的局部搜索能力。本文采用交换、反转、插入 3 种学习算子, 在每一代中精英个体随机选择这 3 种算子进行学习, 每代学习 5 次。若学习后的个体适应度值增加则更新个体, 反之, 不更新。

2.7 算法流程图

综上, 基于精英引导的自适应学习遗传算法解决 01-TB-KP 问题的流程图如图 1 所示。

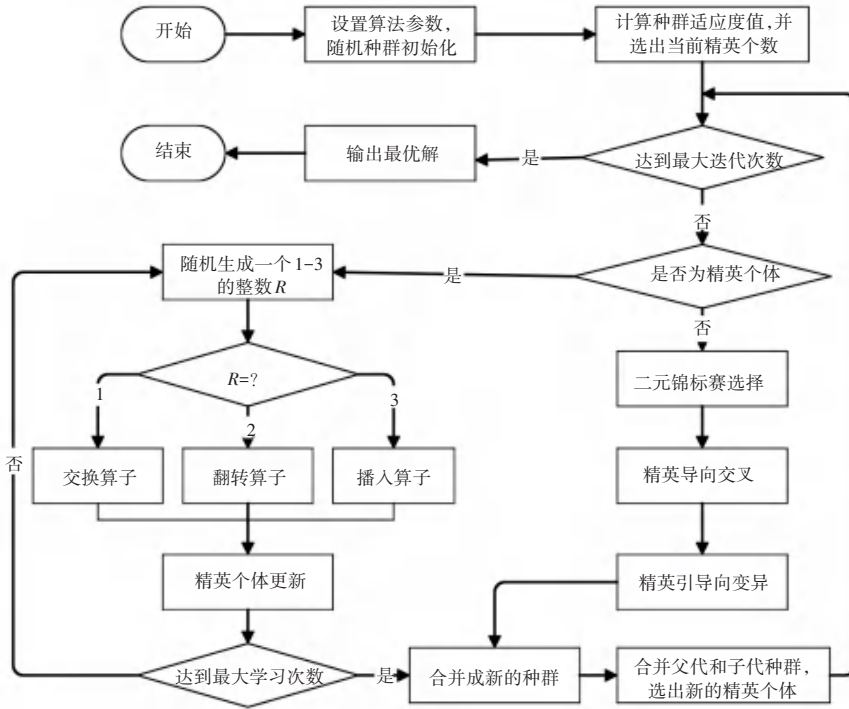


图 1 算法流程图

Fig. 1 Algorithm flow chart

3 实验分析

3.1 实验算例

本文实验基准测试集采用了文献[5]中对 01-TB-KP 问题所提出的 5 类算例。前 4 类算例是在 Pisinger^[22] 为 0-1 背包问题设计的算例基础上加入物品爆炸概率生成, 最后一类则是专门为挑战文献[5]中讨论的边界值而创建。该测试集包含 600 个算例, 数据规模广泛。详细内容参见原始文献。

3.2 参数设置

为获取最佳参数组合, 本文在标准算例下进行测试。每个算例独立运行 30 次, 为了在合理的时间内完成对比实验, 本文将种群大小固定为 100, 迭代次数为 1 000 次, 该设置能在求解质量和计算效率之间提供一个良好的平衡。

在标准算例 type1-5 000-0-0.2-1 上对交叉概率 P_c 、变异概率 P_m 、精英个体在种群中的占比 P_e 和精英个体自学习的次数做了四参数四水平的正交实验, 实验的设置和结果展示在表 1~表 3 中。其中变异概率与算例中物品数量相关, n 表示物品数量; $Ex(x = 1, 2, 3, 4)$ 表示不同水平下实验结果的均值; Max 和 Min 分别表示不同水平下实验结果均值的最大值和最小值; Range 表示最大值和最小值之间的差值。最后的方案就是正交实验所得到的最佳参数组合, 表 3 所示 P_c 、 P_m 、 P_e 和 k 分别在 level 4、level 1、level 4、level 1 时, 对应水平的平均适应度值最大, 对应表中加粗标注的最优结果。这表明算法在使用这组参数时表现更佳。因此, 确定算法的最佳参数组合为 $P_c = 0.9$, $P_m = 1/n$, $P_e = 20\%$, $k = 5$ 。

表1 实验参数和水平

Table 1 Experimental factors and levels

level	P_c	P_m/n	$P_e/\%$	k
level 1	0.6	1	5	5
level 2	0.7	2	10	10
level 3	0.8	3	15	15
level 4	0.9	4	20	20

表2 正交实验方案和结果

Table 2 Orthogonal test scheme and test results

实验号	P_c	P_m/n	$P_e/\%$	k	最佳适应度值
1	0.6	1	5	5	1 371 976
2	0.6	2	10	10	1 275 041
3	0.6	3	15	15	1 172 039
4	0.6	4	20	20	1 086 687
5	0.7	1	10	15	1 239 611
6	0.7	2	5	20	1 145 729
7	0.7	3	20	5	1 336 838
8	0.7	4	15	10	1 227 928
9	0.8	1	15	20	1 164 605
10	0.8	2	20	15	1 212 026
11	0.8	3	5	10	1 268 638
12	0.8	4	10	5	1 336 158
13	0.9	1	20	10	1 338 938
14	0.9	2	15	5	1 388 845
15	0.9	3	10	20	1 121 031
16	0.9	4	5	15	1 172 254

表3 实验结果分析

Table 3 Analysis of test results

平均适应度值	P_c	P_m/n	$P_e/\%$	k
E1	1 226 435.75	1 278 782.50	1 239 649.25	1 358 454.25
E2	1 237 526.50	1 255 410.25	1 242 960.25	1 277 636.25
E3	1 245 356.75	1 224 636.50	1 238 354.25	1 198 982.50
E4	1 255 267.00	1 205 756.75	1 243 622.25	1 129 513.00
Max	1 255 267.00	1 278 782.50	1 243 622.25	1 358 454.25
Min	1 226 435.75	1 205 756.75	1 238 354.25	1 129 513.00
Range	28 831.25	73 025.75	5 268.00	228 941.25
方案	level 4	level 1	level 4	level 1

3.3 不同策略的有效性及其收敛性分析

为验证本文改进算法的优势,本节重点考察所提策略的有效性,并依据表4将所提策略组合成不同的优化方案。将这些方案在不同规模的算例上进行测试,每种方案运行30次,最大迭代次数设为

1 000。其中 Strategy-0 为传统的遗传算法,所用参数与本文算法一致。Strategy-1、Strategy-2、Strategy-3、Strategy-4 和 Strategy-5 (EGALS-GA) 分别表示增加各策略后的算法,具体优化方案详见表4。

表4 优化方案分组

Table 4 Grouping of optimization schemes

策略	优化方案
Strategy-0	GA
Strategy-1	Strategy-0+精英引导变异
Strategy-2	Strategy-1+精英个体自学习
Strategy-3	Strategy-0+精英导向交叉
Strategy-4	Strategy-3+精英个体自学习
Strategy-5	EGALS-GA

3.3.1 不同策略的有效性分析

表5~表9展示了不同策略算法在不同类型、不同规模算例上的实验结果,包含了各算法在每个算例上求出的最优值、最差值、平均值及标准差。

表5为传统遗传算法、不同策略改进算法、及融合全策略的EGALS-GA在Type1类12个算例的性能对比结果。实验表明,在Type1类算例中,传统遗传算法(Strategy-0)所获得的最优值与平均值均为最低,且标准差较高。例如,在算例type1-5 000-0-0.1-9中,其平均值显著低于EGALS-GA,标准差为后者的9倍以上。除Type1-5 000-0-0.5-2因解空间较为简单,EGALS-GA略逊于Strategy-3外,其余11个算例中EGALS-GA均取得最高的最优值与平均值,其中5个算例的标准差为0。

表6记录了在Type2类中12个算例上对比不同算法的结果。结果表明,Strategy-0的求解精度与稳定性较差,例如Type2-5 000-0-0.1-2的平均值仅为325.62,Type2-500-0-0.2-5的标准差高达31 381.49。所有改进算法均优于传统算法,其中EGALS-GA在全部12个算例中均取得最高的最优值与平均值,且标准差最小,4个算例的标准差为0,且随问题规模增大,其优势更加明显。

表7为不同策略算法在Type3类中12个算例的性能测试结果。实验显示,Strategy-0表现较差,如Type3-5 000-0-0.5-1的平均值远低于其他改进算法,Type3-1 000-0-0.2-10的标准差为EGALS-GA的181.6倍。EGALS-GA在全部12个算例中的最优值与平均值均最高,其中5个算例的标准差为0,在规模为5 000的算例中,其精度较最优单一策略提高了0.4%~2.8%。

表 5 Type1 类算例下不同策略实验结果
Table 5 Experimental results of different strategies on Type1 instance

算例	Strategy-0	Strategy-1	Strategy-2	Strategy-3	Strategy-4	Strategy-5	
Type1-100-0-0.1-6	最优值	11 302	11 883	11 883	11 883	11 883	11 883
	最差值	10 800	11 790	11 841	11 841	11 869	11 869
	平均值	11 096.400 0	11 854.700 0	11 874.133 3	11 876.933 3	11 882.066 7	11 882.533 3
	标准差	132.321 9	17.154 8	11.904 0	9.504 7	3.551 9	2.556 0
Type1-100-0-0.2-3	最优值	33 987	34 289	34 289	34 289	34 289	34 289
	最差值	32 971	34 208	34 208	34 208	34 289	34 289
	平均值	33 657	34 248.500 0	34 267.400 0	34 270.833 3	34 289	34 289
	标准差	246.210 3	41.192 4	36.431 9	33.705 7	0	0
Type1-100-0-0.5-8	最优值	28 770.544 1	28 770.544 1	28 770.544 1	28 770.544 1	28 770.544 1	28 770.544 1
	最差值	28 617.910 8	28 770.544 1	28 770.544 1	28 770.544 1	28 770.544 1	28 770.544 1
	平均值	28 760.832 3	28 770.544 1	28 770.544 1	28 770.544 1	28 770.544 1	28 770.544 1
	标准差	29.992 6	0	0	0	0	0
Type1-500-0-0.1-5	最优值	171 180	176 670	176 760	176 850	176 850	176 850
	最差值	169 650	176 040	176 400	176 580	176 670	176 670
	平均值	170 439	176 472	176 616	176 739	176 796	176 811
	标准差	400.881 4	157.488 9	112.360 3	73.548 0	69.311 9	51.148 9
Type1-500-0-0.2-6	最优值	56 158	57 486	57 486	57 486	57 486	57 486
	最差值	54 838	57 486	57 486	57 486	57 486	57 486
	平均值	55 610.233 3	57 486	57 486	57 486	57 486	57 486
	标准差	347.614 3	0	0	0	0	0
Type1-500-0-0.5-1	最优值	159 647.118 0	162 154.521 5	162 154.521 5	162 154.521 5	162 154.521 5	162 154.521 5
	最差值	151 374.445 0	162 154.521 5	162 154.521 5	162 154.521 5	162 154.521 5	162 154.521 5
	平均值	155 389.579 0	162 154.521 5	162 154.521 5	162 154.521 5	162 154.521 5	162 154.521 5
	标准差	1 539.709 2	0	0	0	0	0
Type1-1000-0-0.1-8	最优值	300 892	316 334	317 194	317 228	317 884	317 918
	最差值	238 605.533 0	313 715	316 125	315 265	317 539	317 573
	平均值	262 988.930 0	315 030.466 7	316 675.733 3	316 553.766 7	317 702.266 7	317 801.900 0
	标准差	23 879.469 6	656.051 0	316.233 6	408.231 0	109.464 2	80.975 7
Type1-1000-0-0.2-8	最优值	155 511.736 0	308 984	308 984	308 984	308 984	308 984
	最差值	141 653.155 0	308 984	308 984	308 984	308 984	308 984
	平均值	147 074.172 0	308 984	308 984	308 984	308 984	308 984
	标准差	3 078.913 0	0	0	0	0	0
Type1-1000-0-0.5-9	最优值	72 564.957 1	127 727.434 8	127 727.434 8	127 727.434 8	127 727.434 8	127 727.434 8
	最差值	68 368.123 2	127 675.241 9	127 727.434 8	127 693.045 5	127 727.434 8	127 727.434 8
	平均值	70 368.946 0	127 712.686 6	127 727.434 8	127 722.640 4	127 727.434 8	127 727.434 8
	标准差	1 112.353 6	17.124 2	0	8.978 7	0	0
Type1-5000-0-0.1-9	最优值	1 520 655.680 0	2 835 248	2 848 097	2 909 139	2 935 171	2 936 286
	最差值	1 484 000.320 0	2 824 329	2 831 053	2 894 063	2 930 260	2 931 239
	平均值	1 504 668.380 0	2 830 992.467 0	2 840 841.600 0	2 901 413.167 0	2 932 907.533 0	2 934 196.433 0
	标准差	9 183.356 4	3 123.133 0	5 149.763 1	4 264.855 9	1 351.937 0	1 004.137 2
Type1-5000-0-0.2-1	最优值	881 643	1 325 383	1 333 961	1 406 179	1 424 802	1 430 340
	最差值	880 719.399 0	1 313 097	1 313 503	1 396 993	1 417 647	1 420 368
	平均值	881 547.526 0	1 319 715.467 0	1 323 930.700 0	1 401 619.567 0	1 421 926.033 0	1 426 185.767 0
	标准差	224.623 4	3 467.414 0	4 201.952 9	2 257.992 1	1 802.024 3	2 183.110 2
Type1-5000-0-0.5-2	最优值	574 012.950 0	1 414 182	1 357 733	1 490 708	1 360 313.325 0	1 361 969
	最差值	521 582.172 0	1 390 448	1 324 815.858 0	1 484 490	1 318 287.393 0	1 326 255.417 0
	平均值	549 599.723 0	1 402 916.325 0	1 340 446.289 0	1 487 780.267 0	1 340 341.106 0	1 342 185.824 0
	标准差	13 083.311 4	6 675.695 1	8 068.871 6	1 689.876 4	8 563.694 0	8 532.362 7

表 8 记录了不同策略算法在 Type4 类中 12 个算例的实验结果,结果表明,随着算例规模从 100 增至 5 000,Strategy-0 的性能瓶颈更加突出,例如 type4-5 000-0-0.5-3 的平均值不足 EGALS-GA 的 60%,

标准差为后者的 83 倍。Strategy-1 至 Strategy-4 虽优于传统算法,但仍存在局限;而 EGALS-GA 在最优值、平均值上均为最高,标准差最小,且最差值普遍更优,表现出更强的全局搜索能力。

表6 Type2类算例下不同策略实验结果

Table 6 Experimental results of different strategies on Type2 instance

算例	Strategy-0	Strategy-1	Strategy-2	Strategy-3	Strategy-4	Strategy-5	
Type2-100-0-0.1-1	最优值	42 449.750 6	44 868.572 1	44 868.572 1	44 868.572 1	44 868.572 1	44 868.572 1
	最差值	40 272.334 4	44 336.777 3	44 851.673 9	44 822.220 9	44 853.661 9	44 868.572 1
	平均值	41 249.005 7	44 838.929 7	44 864.231 6	44 856.403 4	44 866.650 3	44 868.572 1
	标准差	544.583 1	95.372 7	5.522 0	10.843 0	4.151 5	0
Type2-100-0-0.2-1	最优值	57 021.635 5	57 403.524 4	57 403.524 4	57 403.524 4	57 403.524 4	57 403.524 4
	最差值	56 162.015 1	57 091.325 5	57 343.032 8	57 164.147 0	57 285.632 3	57 344.023 8
	平均值	56 597.623 0	57 329.496 7	57 391.359 1	57 363.337 1	57 393.974 6	57 399.953 8
	标准差	201.341 4	81.492 6	21.744 7	74.341 2	25.189 4	10.666 7
Type2-100-0-0.5-6	最优值	18 935	18 935	18 935	18 935	18 935	18 935
	最差值	18 870	18 935	18 935	18 935	18 935	18 935
	平均值	18 932.833 3	18 935	18 935	18 935	18 935	18 935
	标准差	11.867 3	0	0	0	0	0
Type2-500-0-0.1-1	最优值	83 088	83 175	83 205	83 193	83 217	83 229
	最差值	83 046	83 145	83 184	83 148	83 190	83 202
	平均值	83 072.600 0	83 164.500 0	83 193	83 176.400 0	83 207.800 0	83 214.700 0
	标准差	9.510 8	8.728 7	6	10.591 5	7.512 7	5.983 6
Type2-500-0-0.2-5	最优值	109 186.728 2	152 967	152 952	152 961	152 964	152 967
	最差值	20 477.162 8	152 925	152 922	152 922	152 934	152 928
	平均值	50 425.332 3	152 938.900 0	152 936	152 946.300 0	152 950.500 0	152 951.600 0
	标准差	31 381.491 5	11.430 0	8.533 9	9.131 8	7.123 3	8.584 7
Type2-1000-0-0.1-1	最优值	732 012	738 314	738 314	738 314	738 314	7383 14
	最差值	727 908	738 314	738 314	738 314	738 314	738 314
	平均值	730 075.133 3	738 314	738 314	738 314	738 314	738 314
	标准差	1 058.041 6	0	0	0	0	0
Type2-1000-0-0.2-1	最优值	494 029.457 0	532 257	532 366	532236	533 491	533 647
	最差值	485 027.487 0	526 223	529 906	527 786.685 0	532 271	532 442
	平均值	488 541.570 3	528 545.929 0	531 006.958 2	529 951.219 2	532 962.191 1	533 326.842 8
	标准差	2 245.777 5	1 310.870 3	754.697 1	1 079.094 4	403.429 9	306.304 2
Type2-1000-0-0.2-8	最优值	24 528.420 0	296 748	297 221	297 433	297 732	297 906
	最差值	22 305.780 0	295 128	296 150	295 813	297 308	297 308
	平均值	23 311.260 0	296 151.300 0	296 702	296 847.700 0	297 572.900 0	297 669.666 7
	标准差	532.633 2	362.713 4	282.488 2	353.530 4	135.583 1	138.132 2
Type2-5000-0-0.1-1	最优值	2 303 798.721 0	2 387 013	2 412 539	2 595 602	2 768 717	2 770 038
	最差值	2 153 910.708 2	2 337 726.524 0	2 389 091.517 0	2 570 549	2 756 528	2 757 964
	平均值	2 208 186.308 1	2 364 124.285 0	2 400 323.688 0	2 578 288.080 0	2 762 590.433 0	2 764 393.033 0
	标准差	30 591.204 2	11 578.410 0	5 958.509 5	5 612.432 7	2 907.661 2	3 333.060 1
Type2-5000-0-0.1-2	最优值	1165.640 1	1 714 533	1 725 092	1 738 152	1 876 780	1 877 207
	最差值	325.620 0	1 702 587.700 0	1 710 062	1 736 894	1 871 048	1 872 604
	平均值	629.506 7	1 709 141.424 0	1 717 959.595 0	1 737 647	1 874 011.700 0	1 875 211.033 0
	标准差	201.125 0	2 898.994 6	3 303.968 7	272.804 0	1 390.803 4	1 089.510 8
Type2-5000-0-0.2-1	最优值	269 379	269 418	269 511	269 451	269 631	269 643
	最差值	269 319	269 361	269 412	269 370	269 565	269 535
	平均值	269 356.100 0	269 389.600 0	269 467.400 0	269 410.200 0	269 594.800 0	269 595.400 0
	标准差	14.686 0	18.672 5	26.233 2	21.045 8	16.951 0	21.033 0
Type2-5000-0-0.5-1	最优值	1 156 606	1 396 120	1 396 120	1 396 120	1 396 120	1 396 120
	最差值	1 084 501	1 396 120	1 396 120	1 396 120	1 396 120	1 396 120
	平均值	1 122 483.267 0	1 396 120	1 396 120	1 396 120	1 396 120	1 396 120
	标准差	19 448.654 1	0	0	0	0	0

表9为不同策略算法在Type5类中9个算例上的实验结果。实验结果显示,Strategy-0无法稳定输出最优解,例如type5-100-2.0-0-5的平均值仅为

43.524,标准差为67.620 6;type5-500-2.4-0-1的平均值为EGALS-GA的70.2%。Strategy-1至Strategy-4的普适性有限,仅能在部分算例中稳定获

取最优解;而 EGALS-GA 在全部 9 个算例中的最优值与平均值一致,且标准差均为 0。由于 Type5 类

在物品规模为 5 000 时可直接获得确定性解,无需迭代搜索,因此未将该规模算例纳入实验。

表 7 Type3 类算例下不同策略实验结果

Table 7 Experimental results of different strategies on Type3 instance

算例	Strategy-0	Strategy-1	Strategy-2	Strategy-3	Strategy-4	Strategy-5
Type3-100-0-0.1-3	最优值	18 203.877 9	19 905	19 905	19 905	19 905
	最差值	16 041.135 5	19 905	19 905	19 895	19 905
	平均值	17 039.206 4	19 905	19 905	19 904.666 7	19 905
	标准差	521.885 5	0	0	1.825 7	0
Type3-100-0-0.2-1	最优值	33 478.431 4	44 835.373 7	44 835.373 7	44 835.373 7	44 835.373 7
	最差值	28 536.683 2	44 835.373 7	44 835.373 7	44 835.373 7	44 835.373 7
	平均值	30 628.233 5	44 835.373 7	44 835.373 7	44 835.373 7	44 835.373 7
	标准差	992.456 7	0	0	0	0
Type3-100-0-0.5-1	最优值	17 445.386 2	17 475.300 4	17 475.300 4	17 475.300 4	17 475.300 4
	最差值	17 159.712 1	17 475.300 4	17 475.300 4	17 475.300 4	17 475.300 4
	平均值	17 330.617 5	17 475.300 4	17 475.300 4	17 475.300 4	17 475.300 4
	标准差	63.062 3	0	0	0	0
Type3-500-0-0.1-8	最优值	149 486.748 7	268 794	269 194	268 993	269 194
	最差值	137 857.413 0	267 394	268 594	268 194	269 194
	平均值	142 575.581 9	268 231.533 3	269 040.533 3	268 651.300 0	269 194
	标准差	2 747.913 1	341.483 6	154.768 3	216.635 4	0
Type3-500-0-0.2-6	最优值	92 636.880 7	156 594	156 603	156 434.409 0	156 609
	最差值	85 443.670 8	155 959.442 6	156 121.540 2	155 947.490 6	156 434
	平均值	88 687.039 4	156 233.994 4	156 409.157 4	156 118.731 3	156 574.700 2
	标准差	1 684.132 4	159.396 7	145.556 2	177.592 6	60.441 1
Type3-500-0-0.5-8	最优值	46 872.228 4	54 106	54 106	54 106	54 106
	最差值	41 667.818 9	54 051.894 0	54 106	54 106	54 106
	平均值	43 824.608 3	54 104.196 5	54 106	54 106	54 106
	标准差	1 335.716 3	9.878 4	0	0	0
Type3-1000-0-0.1-4	最优值	405 448	451 521	452 727	452 314	453 414
	最差值	395 876	447 957	451 067	449 143	452 343
	平均值	400 307.300 0	449 661	452 027.433 3	451 297.366 7	453 072.066 7
	标准差	2 602.929 8	798.572 1	511.016 9	689.226 7	240.907 2
Type3-1000-0-0.2-1	最优值	245 152	270 858	271 775	271 575	272 176
	最差值	239 549	269 376	270 176	270 076	271 576
	平均值	242 140.051 8	270 150.533 3	271 050.300 000 0	270 840.466 7	271 912.533 3
	标准差	1546.594 2	364.012 3	321.569 300 0	388.861 8	178.940 3
Type3-1000-0-0.2-10	最优值	201 928.969 6	265 515	266 034	266 079	266 450
	最差值	161 397.772 5	264 344	265 382	265 397	266 272
	平均值	189 170.737 8	264 863.433 3	265 750.533 3	265 732.003 8	266 407.566 7
	标准差	7 962.859 0	264.563 6	155.794 2	160.931 4	38.770 5
Type3-5000-0-0.1-1	最优值	1 099 972.366 6	1 414 797	1 414 863	1 414 806	1 415 028
	最差值	1 060 308.630 0	1 413 319.266 0	1 414 773	1 414 677	1 414 884
	平均值	1 083 942.276 3	1414 681.242 0	1 414 825	1 414 738.200 0	1 414 963.600 0
	标准差	10 414.281 9	258.653 5	23.148 7	30.630 6	32.193
Type3-5000-0-0.2-1	最大值	1 227 774.957 3	2 087 721	2 103 708	2 388 105	2 435 386
	最小值	1 175 705.828 5	2 032 060.774 0	2 063 108.826	2 361 608	2 414 412.171 0
	平均值	1 198 977.583 8	2 063 654.933 0	2 090 438.841	2 374 826.733 0	2 425 601.618 0
	标准差	12 099.446 1	11 935.364 7	8 953.431 4	6 678.414 9	5 185.439 3
Type3-5000-0-0.5-1	最大值	420 660.856 7	1 023 792.249 0	1 056 294.723 0	1 043 975.072 0	1 136 531.814 0
	最小值	366 433.304 7	995 520.260 5	1 031 620.708 0	1 026 674.183 0	1 118 366.193 0
	均值	388 521.306 8	1 007 800.202 0	1 038 415.807 0	1 036 506.537 0	1 126 171.010 0
	标准差	12 573.511 3	7 822.469 9	8 187.725 5	5 173.964 7	3 574.309 8

表8 Type4类算例下不同策略实验结果

Table 8 Experimental results of different strategies on Type4 instance

算例	Strategy-0	Strategy-1	Strategy-2	Strategy-3	Strategy-4	Strategy-5	
Type4-100-0-0.1-6	最优值	33 295	35 330.080 0	35 330	35 330.080 0	35 330.080 0	35 330.080 0
	最差值	31 916	35 040.416 0	35 135.648 0	35 222	35 215.605 2	35 238.816 0
	平均值	32 535.318 2	35 248.740 8	35 294.002 8	35 304.137 9	35 320.770 0	35 324.785 9
	标准差	347.129 0	85.227 3	52.340 7	40.313 3	26.030 5	16.762 1
Type4-100-0-0.2-3	最优值	65 949.063 8	66 090.354 8	66 090.354 8	66 090.354 8	66 090.354 8	66 090.354 8
	最差值	64 317.889 7	65 969.958 9	65 992.844 1	65 962.876 1	66 043.589 4	66 037.619 4
	平均值	64 994.840 8	66 035.901 3	66 076.676 5	66 049.488 8	66 086.381 3	66 086.945 1
	标准差	377.338 3	42.385 0	27.632 9	37.009 6	12.351 2	11.247 6
Type4-100-0-0.5-2	最优值	16 216.432 6	16 177.766 8	16 177.766 8	16 177.766 8	16 216.432 6	16 216.432 6
	最差值	15 539.092 2	16 121.368 6	16 121.368 6	15 950.464 9	16 121.368 6	16 121.368 6
	平均值	16 000.760 4	16 147.415 7	16 139.986 6	16 128.650 0	16 164.622 9	16 177.175 7
	标准差	170.410 2	28.332 2	26.787 6	41.224 3	26.285 2	12.683 6
Type4-500-0-0.1-1	最优值	77 242	85 734.273 9	86 031.678 2	86 031.678 2	86 031.678 2	86 047.640 2
	最差值	74 018	84 248	85 354.560 0	84 971.801 1	85 901.938 1	85 901.938 1
	平均值	75 702.539 7	84 932.693 6	85 777.360 2	85 634.723 9	85 988.431 5	85 997.219 2
	标准差	729.454 6	326.580 3	187.307 0	285.661 2	62.205 6	59.223 9
Type4-500-0-0.2-1	最优值	253 312	258 777	259 178	259 172	259 378	259 578
	最差值	250 803	257 764	258 575	257 978	258 978	258 978
	平均值	252 144.453 7	258 300.966 7	258 946.466 7	258 626.633 3	259 305.400 0	259 391
	标准差	676.115 9	261.295 5	191.226 8	303.290 5	119.874 2	138.258 8
Type4-500-0-0.5-1	最优值	88 132.382 0	90 877.065 3	91 242.666 0	90 958.486 5	91 742.166 0	91 758.082 1
	最差值	86 345.492 1	89 963.478 5	90 389.395 7	90 143.766 0	91 142.766 0	91 359.281 3
	平均值	86 929.127 5	90 401.633 5	90 858.220 9	90 541.856 2	91 432.937 8	91 559.250 8
	标准差	357.664 5	245.670 7	234.662 3	231.503 0	132.965 6	107.345 9
Type4-1000-0-0.2-1	最优值	561 791	566 491	567 228	568 021	569 226	569 404
	最差值	558 455	562 465	564 824	564 528	568 228	568 227
	平均值	559 745.648 6	564 858.133 3	566 505.666 7	566 036.766 7	568 656	568 913
	标准差	832.227 6	923.162 2	549.037 7	825.532 9	251.699 7	299.900 6
Type4-1000-0-0.2-7	最优值	433 491	437 028	437 259	437 259	437 400	437 400
	最差值	430 834.037 7	435 748.202 6	435 888.639 3	436 029.076 0	437 058.504 0	437 058.504 0
	平均值	432 446.054 8	436 641.050 3	436 907.812 7	436 757.843 2	437 275.533 6	437 253.533 6
	标准差	686.150 8	336.560 2	271.731 0	386.926 8	103.277 2	102.957 6
Type4-1000-0-0.5-1	最优值	266 080	269 989	270 798	271 003	272 603	273 101
	最差值	263 797.938 0	268 175.341 7	269 103	268 561.8	270 903	271 903
	平均值	264 870.833 8	269 156.960 1	269 968.004 3	269 684.900 1	272 038.843 0	272 554.773 0
	标准差	496.592 3	420.578 9	342.796 8	595.059 4	382.526 9	320.112 3
Type4-5000-0-0.1-1	最优值	559 632	616 187	618 872	625 428	632 912	633 952
	最差值	552 719	608 132	6 118 991	616 187	629 476	629 758
	平均值	555 746.433 3	611 971.533 3	615 711.033 3	621 709.066 7	631 472.733 3	631 855.500 0
	标准差	1 491.628 4	1 889.296 2	1 590.345 6	2 388.788 0	923.338 1	898.648 8
Type4-5000-0-0.2-1	最优值	881 652	881 658	881 697	881 676	881 826	881 829
	最差值	879 889.230 0	881 574	881 616	881 577	881 676	881 757
	平均值	881 530.153 2	881 630.400 0	881 658.600 0	881 623.700 0	881 771.300 0	881 787.100 0
	标准差	348.102 1	21.248 3	18.947 5	22.040 9	28.369 7	21.726 1
Type4-5000-0-0.5-3	最优值	546 473.745 2	837 043	837 043	837 043	837 043	837 043
	最差值	498 719.708 7	835 687.115 4	834 826.503 2	835 470.710 0	836 243.919 0	836 307.855 0
	平均值	523 847.928 7	836 918.349 7	836 890.534 3	836 910.651 6	836 944.054 7	837 014.261 8
	标准差	11 214.709 8	308.401 8	447.036 8	337.107 5	226.879 4	134.552 5

综上所述,所提出的各策略在多个性能维度上均一致优于原始遗传算法,且改进效果显著。具体而言,精英引导变异策略与精英导向交叉策略均能有效提升解的质量,而引入精英自学习策略后,解的性能得到进

一步改善,验证了该策略的有效性。最终,融合以上策略的 EGALS-GA 算法无论是在求解质量方面还是解的稳定性方面实现了显著的提升。充分证明了3种策略在提高算法性能方面的有效性与协同作用。

表 9 Type5 类算例下不同策略实验结果
Table 9 Experimental results of different strategies on Type5 instance

算例		Stratey-0	Stratey-1	Stratey-2	Stratey-3	Stratey-4	Stratey-5
Type5-100-1.6-0-1	最优值	404.114 4	404.114 4	404.114 4	404.114 4	404.114 4	404.114 4
	最差值	296.234 7	404.114 4	404.114 4	404.114 4	404.114 4	404.114 4
	平均值	364.651 6	404.114 4	404.114 4	404.114 4	404.114 4	404.114 4
	标准差	46.475 9	0	0	0	0	0
Type5-100-2.0-0-5	最优值	145.080 0	394.409 7	394.409 7	394.409 7	394.409 7	394.409 7
	最差值	0	394.409 7	394.409 7	394.409 7	394.409 7	394.409 7
	平均值	43.524 0	394.409 7	394.409 7	394.409 7	394.409 7	394.409 7
	标准差	67.620 6	0	0	0	0	0
Type5-100-2.4-0-1	最优值	774.229 9	774.229 9	774.229 9	774.229 9	774.229 9	774.229 9
	最差值	628.911 7	774.229 9	774.229 9	774.229 9	774.229 9	774.229 9
	平均值	758.300 2	774.229 9	774.229 9	774.229 9	774.229 9	774.229 9
	标准差	35.112 0	0	0	0	0	0
Type5-500-1.6-0-2	最优值	132.693 7	132.693 7	132.693 7	132.693 7	132.693 7	132.693 7
	最差值	75.795 0	110.553 5	132.693 7	127.952 2	132.693 7	132.693 7
	平均值	114.300 4	129.979 1	132.693 7	131.435 7	132.693 7	132.693 7
	标准差	14.002 2	5.668 9	0	2.122 0	0	0
Type5-500-2.0-0-7	最优值	135.320 2	135.320 2	135.320 2	135.320 2	135.320 2	135.320 2
	最差值	92.442 7	92.752 2	135.320 2	113.890 7	135.320 2	135.320 2
	平均值	118.264 9	128.423 8	135.320 2	133.284	135.320 2	135.320 2
	标准差	14.092 7	11.409 1	0	6.232 1	0	0
Type5-500-2.4-0-1	最优值	105.341 0	105.341 0	105.341 0	105.341 0	105.341 0	105.341 0
	最差值	56.304 0	80.803 2	82.363 4	80.803 2	105.341 0	105.341 0
	平均值	73.898 1	89.814 6	103.809 1	94.410 1	105.341 0	105.341 0
	标准差	17.483 1	11.178 5	5.829 6	11.895 5	0	0
Type5-1000-1.6-0-1	最优值	26.441 0	26.441 0	26.441 0	26.441 0	26.441 0	26.441 0
	最差值	18.326 0	26.441 0	26.441 0	26.441 0	26.441 0	26.441 0
	平均值	23.592 7	26.441 0	26.441 0	26.441 0	26.441 0	26.441 0
	标准差	3.814 6	0	0	0	0	0
Type5-1000-2.0-0-1	最优值	23.075	251.715 0	251.715 0	251.715 0	251.715 0	251.715 0
	最差值	21.600 0	251.715 0	251.715 0	251.715 0	251.715 0	251.715 0
	平均值	22.292 6	251.715 0	251.715 0	251.715 0	251.715 0	251.715 0
	标准差	0.596 2	0	0	0	0	0
Type5-1000-2.4-0-1	最优值	38.500 0	38.500 0	38.500 0	38.500 0	38.500 0	38.500 0
	最差值	37.080 0	37.080 0	37.080 0	37.080 0	38.500 0	38.500 0
	平均值	37.932 0	37.364 0	38.452 7	37.742 7	38.500 0	38.500 0
	标准差	0.707 5	0.577 7	0.259 3	0.720 5	0	0

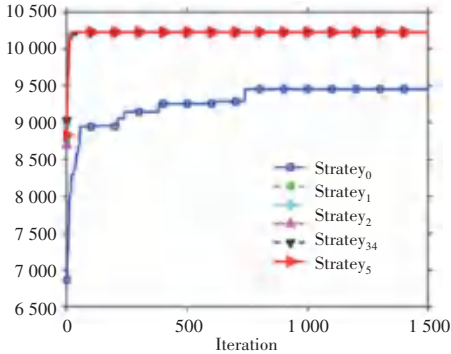
3.3.2 算法收敛性分析

图 2 为加入各策略后的算法分别在算例 Type1-100-0-0.2-5, Type3-500-0-0.1-5, Type2-1000-0-


0.2-8, Type4-5000-0-0.1-1 上得到的迭代收敛曲线图。由图 2 可知,原始算法在各算例中收敛速度慢,在小规模算例中需数百次才收敛,且最终值与加

入各策略后的算法的最终值差距大。而完整改进算法迭代约 100 次内就快速收敛,最终值更高,曲线平稳无震荡。这表明完整改进算法在算例求解中,收敛速度、精度与稳定性均远超原始算法,多策略融合改


进效果显著。可以看出各种策略均能有效提升算法的收敛性能,且精英导向交叉策略与精英引导变异策略相较更加优越。实验数据充分证明了 3 种策略在提高算法性能方面的有效性与协同作用。



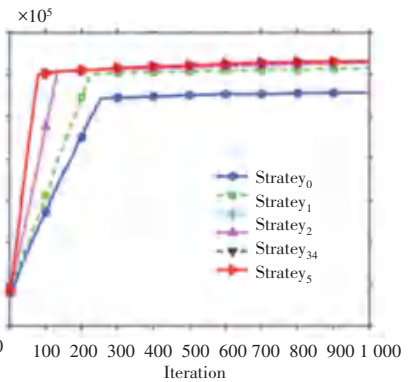
(a) 算例 Type1-100-0.2-5



(b) 算例 Type3-500-0.1-5



(c) 算例 Type2-1000-0.2-8



(d) 算例 Type4-5000-0.1-1

图 2 迭代曲线图

Fig. 2 Iteration curve diagram

4 结束语

本研究针对 0-1 定时炸弹背包这一具有特殊约束与高风险特征的复杂组合优化问题提出了 EGALS-GA 算法。该算法通过融合精英引导变异、精英导向交叉与精英自学习机制,显著提升了传统遗传算法在应对此类稀缺且高风险问题时的综合性能。大量实验结果表明,EGALS-GA 不仅在解质量、收敛稳定性及鲁棒性方面表现优异,还展现出对异构算例和风险约束的良好适应能力。目前该领域研究尚属少见,本文不仅为 0-1 定时炸弹背包问题提供了一个有效的求解框架,也为具有类似复杂约束与不确定性优化问题的算法设计提供了重要参考。未来研究可进一步探索算法在更大规模或动态环境下的应用性能,以及风险感知机制与策略参数的自适应调整方法。

参考文献

- [1] HE Yichao, WANG Jinghong, CHEN Guoxin, et al. One-way mutation: An efficient strategy to improve the performance of evolutionary algorithms for solving 0-1 knapsack problem [J]. International Journal of Machine Learning and Cybernetics, 2025, 16 (7/8): 1-20.
- [2] 韩丽萍, 潘大志. 求解多维背包的改进差分进化算法[J]. 智能计算机与应用, 2023, 13(12): 98-101.
- [3] 杨洋, 潘大志, 刘益, 等. 折扣 0-1 背包问题的简化新模型及遗传算法求解[J]. 计算机应用, 2019, 39(3): 656-662.
- [4] 肖颜, 潘大志, 冯世强. 基于环论的改进猴群算法求解有界背包问题[J]. 数学的实践与认识, 2021, 51(13): 166-174.
- [5] MONACI M, PIKE-BURKE C, SANTINI A. Exact algorithms for the 0-1 Time-Bomb Knapsack Problem [J]. Computers and Operations Research, 2022, 145: 105848.
- [6] FARRINGTON M D. Safety of lithium batteries in transportation [J]. Journal of Power Sources, 2001, 96(1): 260-265.
- [7] MONTEMANNI R, SMITH D H. Model-based algorithms for the 0-1 Time-Bomb Knapsack Problem [J]. Computers and Operations Research, 2025, 178: 107010.
- [8] 陈楨, 钟一文, 林娟. 求解 0-1 背包问题的混合贪婪遗传算法

- [J]. 计算机应用, 2021, 41(1):87-94.
- [9] 黄金凤, 周彦玲, 汪海涛, 等. 基于模拟退火算法的水声应答器声场建模方法 [J]. 中国舰船研究, 2025, 20(5):1-10. DOI: 10.19693/j.issn.1673-3185.04517.
- [10] 夏小云, 周育人. 蚁群优化算法的理论研究进展 [J]. 智能系统学报, 2016, 11(1): 27-36.
- [11] SHEN Jiaying, ZHU Donglin, XIONG Wenqing, et al. DNA sequence-driven multi-strategy particle swarm optimization for global optimization [J]. Cluster Computing, 2025, 28(9): 612-612.
- [12] COLMENAR J M, LAGUNA M, MARTÍN-SANTAMARÍA R. Tabu search: An application to the minimum dominating set problem [J]. TOP, 2025, 33(2): 1-23.
- [13] XU Tianpeng, ZHAO Fuqing, TANG Jianxin, et al. A knowledge-driven monarch butterfly optimization algorithm with self-learning mechanism [J]. Applied Intelligence, 2022, 53(10): 12077-12097.
- [14] PATEL P S, SINGH A. A diversity preserving genetic algorithm with tailor-made variation operators for the quadratic bottleneck knapsack problem [J]. Evolutionary Intelligence, 2023, 17(3): 1953-1965.
- [15] SHARMA R, SINGH A, KUMAR P, et al. Genetic algorithm-aided deep feature selection for improved rice disease classification [J]. Operations Research Forum, 2024, 6(1): 7-7.
- [16] LI L Y, MANSOR Z B, LI S Y, et al. Medical software engineering cost estimation model based on multimodal improved genetic algorithm [J]. International Journal of Information Technologies and Systems Approach (IJITSA), 2024, 17(1): 1-22.
- [17] LI Jinxuan, WANG Hongyan, FANG Shengliang, et al. Communication base station site selection method based on an improved genetic algorithm [J]. Electronics, 2025, 14(20): 3977.
- [18] XU Jiachang, YU Dongliang, FANG Ruichong, et al. A dual mutation strategy based on an improved genetic algorithm and a spike neural membrane system to solve binary problems [J]. Journal of Membrane Computing, 2026, 8(1):115-134.
- [19] SUN Zhen, WU Tao, ZUO Xiang, et al. An improved genetic algorithm for dynamic matching of five-axis probe orientation in measurement path planning [J]. Measurement, 2026, 257(PA): 118634-118634.
- [20] ZOU Haigi, WANG Kaipu, HOU Zhuhao, et al. A reinforcement learning-improved genetic algorithm for order reorganization-driven energy-efficient flexible job-shop hybrid batch scheduling towards mass personalized manufacturing [J]. Computers and Operations Research, 2026, 185:107304-107304.
- [21] HUSSAIN A, RIAZ S, AMJAD M S, et al. Genetic algorithm with a new round-robin based tournament selection: Statistical properties analysis. [J]. PloS One, 2022, 17(9): e0274456.
- [22] PISINGER D. Where are the hard knapsack problems? [J]. Computers and Operations Research, 2004, 32(9): 2271-2284.