

DOI: 10.3969/j.issn.2096-8248.2025.04.005

引用格式: 戴红伟, 徐子瑞, 胡青怡, 等. 改进 NSGA-II 算法在低碳泊位岸桥调度中的应用[J]. 江苏海洋大学学报(自然科学版), 2025, 34(4): 34-47.

改进 NSGA-II 算法在低碳泊位岸桥调度中的应用

戴红伟¹, 徐子瑞¹, 胡青怡¹, 何浩², 杨玉¹

(1. 江苏海洋大学 计算机工程学院, 江苏 连云港 222005;

2. 连云港港口控股集团有限公司, 江苏 连云港 222000)

摘要: 传统多目标遗传算法在解决决策变量维度较高泊位分配和岸桥调度问题时效果较差。为了解决这一问题, 研究提出了一种改进的多目标遗传算法。该算法通过采用佳点集初始化、二项交叉、自适应变异和两阶段选择策略, 有效提升了算法的多样性和收敛速度, 避免了传统多目标遗传算法在进化过程中容易陷入局部最优的困境, 并在求解高维决策变量时展现出优越的性能。在基准函数和低碳泊位岸桥调度问题上测试, 与 5 个多目标优化算法进行比较, 实验结果证明该算法具有更好的鲁棒性和寻优能力。

关键词: 多目标遗传算法; 佳点集初始化; 二项交叉; 自适应变异; 泊位岸桥

中图分类号: TP399 文献标志码: A 文章编号: 2096-8248(2025)04-0034-14

Application of the improved NSGA-II algorithm in low-carbon berth allocation and quay crane assignment

DAI Hongwei¹, XU Zirui¹, HU Qingyi¹, HE hao², YANG Yu¹

(1. School of Computer Engineering, Jiangsu Ocean University, Lianyungang 222005, China;

2. Lianyungang Port Holdings Group Co., Ltd., Lianyungang 222000, China)

Abstract: Traditional multi-objective genetic algorithms often perform poorly when addressing berth allocation and quay crane assignment problems with high-dimensional decision variables. To overcome this limitation, an improved multi-objective genetic algorithm is proposed in this paper. The algorithm enhances diversity and convergence speed by incorporating a good-point set initialization, binomial crossover, adaptive mutation, and a two-stage selection strategy. This effectively prevents the algorithm from becoming trapped in local optima during evolution and demonstrates superior performance in solving high-dimensional decision variables. The algorithm is tested on benchmark functions and the low-carbon berth allocation and quay crane assignment problem. Experimental results, comparing it with five other multi-objective optimization algorithms, show that the proposed algorithm exhibits better robustness and optimization capability.

Key words: multi-objective genetic algorithm; good-point set initialization; binomial crossover; adaptive mutation; berth allocation and quay crane

收稿日期: 2025-03-03; 修订日期: 2025-04-14

基金项目: 国家自然科学基金资助项目(62373171)

作者简介: 戴红伟, 教授, 博士, 研究方向为自然启发计算、最优化问题、大数据分析 with 处理和复杂网络, (E-mail) hwdai@jou.edu.cn.

0 引言

随着全球气候变化加剧和中国“双碳”目标的提出,航运业面临巨大挑战与机遇,需要通过减排、能源结构转型和技术创新推动低碳转型,助力绿色发展。作为航运业的重要组成部分,集装箱码头在这一转型中发挥着关键作用,其中泊位分配和岸桥调度是码头运营的核心环节^[1]。Chargui 等^[2]提出一种兼顾能源不确定性与作业可持续性的泊位分配与岸桥调度方法,建立了以最大化可再生能源的使用和最小化成本为目标的双目标模型,采用了一种降低模型复杂性的精确分解算法进行求解。陆后军等^[3]考虑潮汐因素,利用粒子群与遗传算法的混合优化算法求解以碳排放成本和船舶在港成本之和最小为目标的混合整数规划模型。闵德权等^[4]为减少港区碳排放并兼顾港口整体利益,提出了一种岸电分配与泊位分配的协同优化方案,并采用多目标遗传算法进行求解,旨在港口提供不同功率配置下,实现岸电使用成本的最小化和港口环境效益的最大化。Ma 等^[5]建立了以最小化平均碳排放和总服务时间为目标的多目标随机泊位分配模型。采用随机规划方法对船舶的不确定到达时间和运行时间进行规划,设计了一种基于随机仿真的增强型多目标人工蜂群算法,通过与 NSGA-II 对比验证所提算法的有效性。在传统的泊位岸桥调度问题中,由于船舶规模较小,通常采用精确分解方法获得全局最优解。然而,随着船舶规模的扩大,问题的复杂性和决策变量维度的增加,精确分解方法在计算效率上逐渐下降,且难以有效求解大规模问题。因此,求解方法逐步转向智能优化算法,以提高求解效率并优化调度方案。

非支配排序遗传算法 (nondominated sorting genetic algorithm II, NSGA-II) 是一种基于进化计算的多目标智能优化算法,由 Deb 等^[6]在 2002 年提出,用于解决具有多个相互冲突目标的问题。NSGA-II 的基本思想是通过模拟自然选择和遗传操作(如选择、交叉和变异),逐步优化种群,使其收敛到 Pareto 最优解集。NSGA-II 目前已广泛应用于工程调度^[7-9]、机器学习^[10]、金融投资^[11]等多目标优化问题。随着研究的深入,学者们发现传统的 NSGA-II 算法在进化过程中存在搜索精度不足^[12]、容易陷入局部最优解或计算量大等问题。因此,很多学者对算法进行了不同程度的改进。李鑫等^[13]针对传统 NSGA-II 局部搜索能力差的问题,引入新的适

应度函数,改进精英保留策略,提升算法局部搜索能力,不断逼近 Pareto 真实前沿。陈仁胜等^[14]设计了四段式染色体编码,对各个编码段采用不同的交叉变异,采用基于反向学习的精英保留策略,提出了一种结合混合学习策略的 NSGA-II 算法。Yuan 等^[15]提出了非支配排序和拥挤距离的评价函数,并引入了竞争机制。采用随机突变策略和交叉方法生成新一代种群,改进精英保留策略,设计变比例法确定概率,采用层次分析法确定最优解。Hao 等^[16]采用 Levy 分布进行全局搜索,扩大全局搜索范围,随机行走采用混合变异和交叉生成新的解,增强种群的多样性,防止陷入局部最优,从而提高算法的搜索能力,此外,设计了一个自适应平衡参数来调整各自的探索和开发能力的贡献,从而提高算法的搜索速度。上述研究均针对特定问题对算法进行改进,但针对高维决策变量问题的系统性研究仍较为缺乏。高维决策变量能够提供更全面的优化视角,提升系统适应性和资源利用效率,从而更好地应对复杂的多目标优化问题。

因此,本文针对问题复杂性较大且决策变量维度较高的低碳泊位岸桥调度问题,提出了改进 NSGA-II 算法 (improve nondominated sorting genetic algorithm II, INSGA-II)。该算法首先采用佳点集初始化使得初始化更加均匀,避免陷入局部最优且增加初始种群的多样性;其次,使用二项交叉和自适应变异策略,动态调整变异概率,避免算法过早收敛的同时保持良好的多样性,避免算法陷入局部最优;最后,采用两阶段选择策略,前期参考点引导加快种群收敛,后期使用拥挤距离优先选择较为稀疏的区间保持种群的多样性。

1 非支配排序遗传算法

NSGA-II 通过非支配排序评估个体适应度,优先选取非支配解形成下一代种群,为了保持解的多样性采用拥挤距离选择策略,避免个体聚集到某一特定区域。种群中适应度更高的个体具有更强的繁殖能力,而劣质解逐步被淘汰,从而不断逼近 Pareto 最优前沿^[17-18]。NSGA-II 的核心思想是通过非支配排序与拥挤距离计算来筛选个体,同时利用精英选择逐步搜索并保持 Pareto 前沿解集,NSGA-II 算法原理如图 1 所示。

(1) 非支配排序。在多目标优化中,一个解 x 支配另一个解 y 当且仅当满足以下两个条件:解 x 在

所有目标函数上不劣于解 $y (f_i(x) \leq f_i(y))$; 解 x 在至少一个目标函数上严格优于解 $y (f_i(x) < f_i(y))$ 。非支配排序的核心是根据个体之间的支配关系, 将种群划分为不同的层级, 以引导进化过程向 Pareto 最优解集逼近。

(2) 拥挤距离计算。拥挤距离是一种衡量个体在目标空间中所处位置密集程度的方法, 计算每个个体的拥挤距离, 在同一个非支配层级内, 按照每个目标函数的值分别对个体进行排序, 计算各个目标的分布情况, 边界个体拥挤距离为无穷大; 非边界个体, 计算相邻个体间的目标函数值差值的归一化距离作为个体的拥挤距离, 计算公式为

$$dis(i) = \sum_{m=1}^M \frac{f_m^{i+1} - f_m^{i-1}}{f_m^{\max} - f_m^{\min}} \quad (1)$$

(3) 精英选择。根据算子的非支配排序等级和拥挤距离进行选择, 规则如下: ① 如果两个种群成员的等级不同, 那么等级较高的那个被选入下一代; ② 如果两个种群成员都属于同一等级, 则选择拥挤距离较大的一个作为下一代。

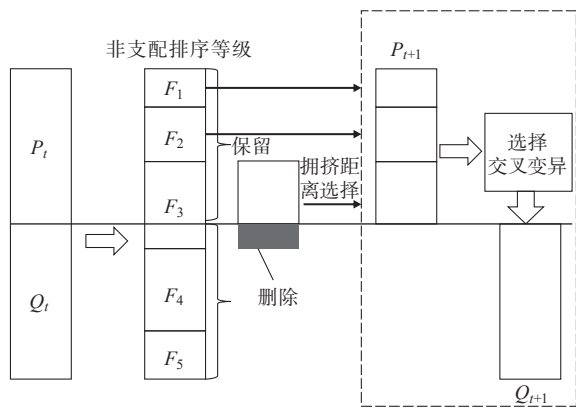


图1 NSGA-II 新种群构成示意图

Fig. 1 Diagram of new population formation in NSGA-II

2 改进多目标遗传算法 (INSGA-II)

2.1 基于佳点集的初始种群生成策略

种群初始化分布的位置影响全局搜索速度和最优解的质量, 种群的多样性会影响智能算法的优化能力。由于传统的多目标遗传算法在初始化种群时采用的策略是随机生成^[19], 很难保证初始种群的分布性和多样性。为了解决上述随机初始化的分布不均匀、不确定性大和多样性不好的问题, 本文使用佳点集初始化种群, 增强种群的多样性。佳点集初始化主要目的是确保种群的初始个体尽可能覆盖解

空间的全部区域, 增强搜索的多样性, 从而提高优化算法的效率和全局搜索能力^[20]。

假设 G_s 为 s 维的欧几里得空间的单位立方体, $r = (r_1, r_2, r_3, \dots, r_s) \in G_s$, 则 $P_n(k)$ 如式(2)所示, 其中, $P_n(k)$ 和 r 分别表示佳点集和佳点, $\{r_s^{(n)} \cdot k\}$ 是 $r_s^{(n)} \cdot k$ 的小数部分, n 为样本数量。佳点 r 的计算如式(3)所示, 其中 p 是满足 $s \leq \frac{p-2}{2}$ 的最小素数。 P_n 的偏差满足方程如式(4)所示, 其中, $C(r, \varepsilon)$ 是仅与 r 和 ε 相关的常数。

$$P_n(k) = \{ (\{r_1^{(n)} \cdot k\}, \{r_2^{(n)} \cdot k\}, \{r_3^{(n)} \cdot k\}, \dots, \{r_s^{(n)} \cdot k\}), 1 \leq k \leq n \} \quad (2)$$

$$r = \{ 2 \cos \frac{2\pi k}{p}, 1 \leq k \leq s \} \quad (3)$$

$$\varphi(n) = C(r, \varepsilon) n^{-1+\varepsilon} \quad (4)$$

通过佳点集初始化策略将其映射到种群定义域的公式为

$$x_i(j) = (Ub_j - Lb_j) \cdot P_n(j) + Lb_j \quad (5)$$

其中, Ub_j 和 Lb_j 分别表示搜索空间第 j 维度的上下界。

图2是在二维和三维空间中, 分别使用佳点集初始化和随机初始化方法, 生成初始种群的分布对比图。可以明显看出, 佳点集初始化生成的初始种群分布得更加均匀, 为后代进化提供了更多的信息, 有助于增加种群的多样性, 提升算法的全局搜索能力, 加快收敛速度。

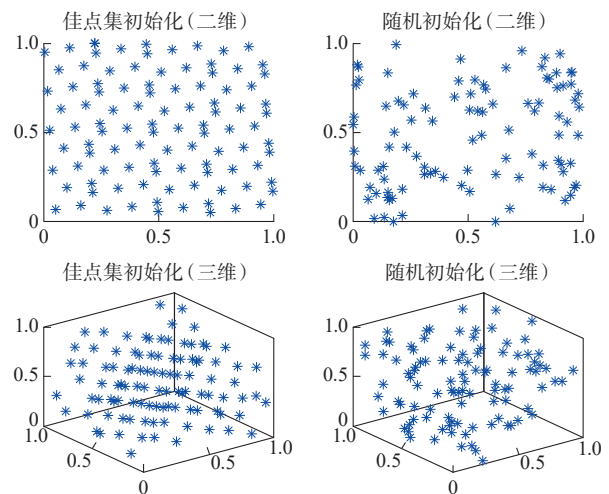


图2 佳点集初始化和随机初始化的示意图

Fig. 2 Diagram of good point set initialization and random initialization

2.2 交叉和自适应变异

2.2.1 交叉操作

本文为了增加种群的多样性采用的交叉操作

是二项交叉^[21], 随机选择两个父代为 $X_i=(x_{i1}, x_{i2}, \dots, x_{ij})$ 和 $V_i=(v_{i1}, v_{i2}, \dots, v_{ij})$ 进行交叉操作, 交叉的过程如式(6)所示,

$$y_{ij} = \begin{cases} v_{ij}, & \text{rand}_j \leq \text{CR}; \\ x_{ij}, & \text{rand}_j > \text{CR}. \end{cases} \quad (6)$$

其中, rand_j 为随机数, CR 为交叉概率, y_{ij} 为产生的新解。

2.2.2 变异操作

变异操作采用自适应变异^[22], 变异概率通过线性衰减方式进行动态调整, 在优化的初期阶段, 需要更多的探索性, 较强的变异来避免陷入局部最优^[23]; 而在优化的后期阶段, 需要更多的开发性, 较弱的变异来细化搜索区域。线性衰减计算如式(7)所示,

$$\mu = \max(\mu_{\max}(1 - \frac{\text{iter}}{\text{MaxIt}}), \mu_{\min}). \quad (7)$$

其中, μ 为当前变异概率, μ_{\max} 为最大变异概率, μ_{\min} 为最小变异概率, iter 为当前迭代次数, MaxIt 为最大迭代次数。

2.3 两阶段选择策略

两阶段选择策略结合了参考点、非支配排序和拥挤距离的选择机制, 可以有效地维持种群的多样性并引导算法向 Pareto 前沿逼近^[24]。

2.3.1 参考点选择策略

(1) 确定参考点。使用 Das 和 Dennis 的方法在超平面中均匀地生成参考点, 以维持种群的多样性^[25]。假设 H 个参考点的集合 $S=(S^1, S^2, S^3, \dots, S^H)$, 生成参考点 S^i ,

$$\begin{cases} S^i = [S^1, S^2, S^3, \dots, S^H]^T; \\ S^j \in \{ \frac{0}{P}, \frac{1}{P}, \frac{2}{P}, \dots, \frac{P}{P} \}, \sum_{j=1}^m S^j = 1. \end{cases} \quad (8)$$

$$H = C_{m+P-1}^P. \quad (9)$$

其中, H 是参考点数量, P 是每个目标上的分段数, m 为目标函数个数。

首先构建 $m-1$ 维 X 的组合, 其中 $x \in \{ \frac{0}{P}, \frac{1}{P}, \frac{2}{P}, \dots, \frac{P+m-2}{P} \}$; 然后对于 $x \in X$ 进行如下操作并且获得新的 $xx_{ij} = x_{ij} - \frac{j-1}{P}$, 最后参考点计算公式如式(10)所示。

$$S_{ij} = \begin{cases} xx_{ij} - 0, & i=1; \\ xx_{ij} - xx_{i(j-1)}, & 1 < i < m; \\ 1 - xx_{i(j-1)}, & i=m. \end{cases} \quad (10)$$

(2) 个体标准化。首先确定种群 pop 中每个目标函数的最小值为 Z_i^{\min} , 构建理性点 $Z=(Z_1^{\min}, Z_2^{\min}, \dots, Z_M^{\min})$, 对种群中个体的目标函数值进行初步标准化转换为 $f'_i(X) = f_i(X) - Z_i^{\min}$, 然后使用 M 个极值点构建 M 维超平面, 计算各个轴上的截距 a_i , 目标函数可以标准化为

$$f_i^n(X) = \frac{f'_i(X)}{a_i} = \frac{f'_i(X) - Z_i^{\min}}{a_i - Z_i^{\min}}, \quad i=1, 2, 3, \dots, M. \quad (11)$$

(3) 建立参考点关联。将 pop 种群中个体自适应标准化后, 通过参考点与原点形成的射线为参考线^[26], 计算种群中每个个体与每条参考线的垂直距离, 计算方法如式(12), 并且被分配给最近的参考点。

$$d(s_n, w_j) = \left\| s_n - \frac{w_j^T s_n w_j}{\|w_j\|^2} \right\|. \quad (12)$$

其中, w_j 为参考点 j 与原点构成的参考线, s_n 为目标个体, w_j^T 为 w_j 转置。

(4) 参考点选择。优先选择非支配等级高的个体, 如果两个个体处于相同的非支配层级, 则结合参考点的选择频次, 优先保留被选次数较少的参考点对应的个体, 以此作为最终个体筛选的依据, 小生境数 ρ_j 表示参考点 j 被分配的个体数量, 具体流程如算法 1 所示。

算法 1: 参考点选择

输入: 选择个体数量 K , 参考点的小生境数 ρ_j , 个体所属的参考点 π , 个体到参考线距离 d , 支配关系 F , 当代种群 P_t , 参考点 Z

输出: 参考点选择的集合 P_{t+1}

- 1: 根据参考点计算小生境数 ρ_j 。
- 2: 如果 ρ_j 最小的参考点只有 1 个, 将其选为参考点, 如果 ρ_j 最小的参考点有多个, 随机选择 1 个作为参考点。
- 3: 从前沿等级为 l 的集合中, 筛选出与参考点相关联的个体, 记为集合 I 。
- 4: 如果 I 为空集, 将这个参考点从集合中删除, 如果不是空集, 计算参考点的小生境数。
- 5: 如果小生境数 $\rho_j=0$, 表示前 $l-1$ 级别的非支配个体没有与参考点进行关联, 但是第 l 级别的非支配个体与参考点有关联, 从集合中选择距离参考点最近的个体加入到 P_{t+1} 中, 如果 $\rho_j \neq 0$, 则在 I 集合随机选择 1 个个体加入到 P_{t+1} 。
- 6: 更新相关参数, 且重复 2~5 操作直到 P_{t+1} 个体数量等于 N 。

2.3.2 非支配排序和拥挤距离选择

(1) 非支配排序。将种群根据非支配排序划分

为不同的层级。

(2) 拥挤距离选择。优先选择非支配等级高的个体,如果两个个体处于相同的非支配层级,则选择拥挤度距离较大的个体。

2.4 改进多目标遗传算法的总体流程

图3为INSGA-II的总体流程图。

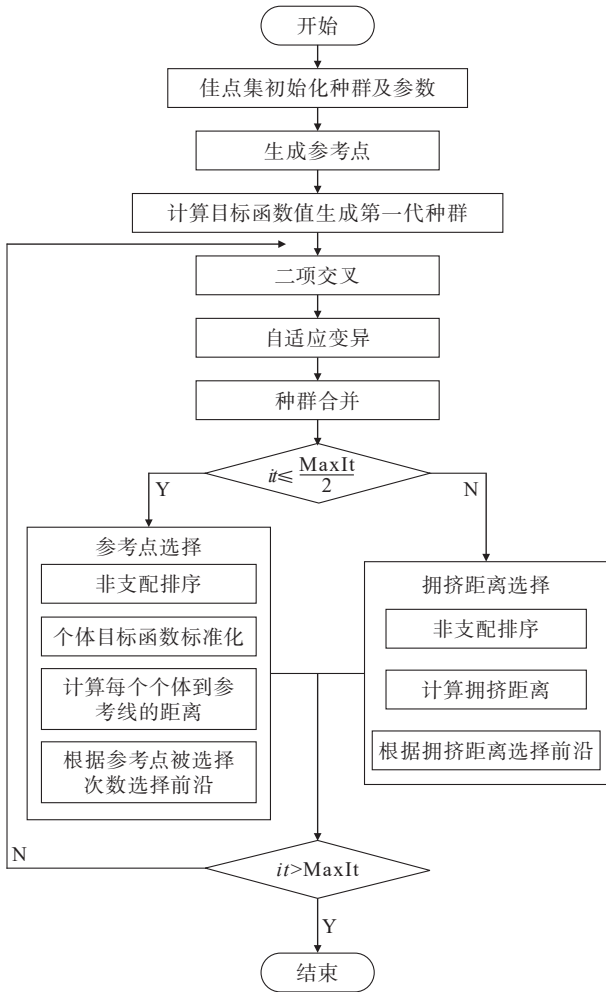


图3 改进多目标遗传算法总体流程
Fig. 3 Overall flowchart of INSGA

详细流程如下。

步骤1: 首先设置算法的相关参数,为了确保初始种群的多样性和分布均匀性,采用佳点集初始化方法来生成种群。

步骤2: 为了在多目标优化过程中维持种群的多样性,通过算法生成一组参考点来引导种群向不同的目标区域分布。

步骤3: 计算种群的目标函数值,根据非支配排序结果进行选择生成第一代种群。

步骤4: 通过二项交叉有助于探索新解并加速全局搜索,通过自适应变异策略在搜索过程中既不会过早收敛,也能够在搜索后期聚焦于更具潜力的区域,从而提高最终解的质量。

步骤5: 采用两阶段选择策略,前期采用参考点选择策略,通过参考点的引导加速解的收敛,快速找到潜在的 Pareto 前沿区域;后期采用拥挤距离策略,优先选择那些位于解集稀疏区域的个体,从而保持种群的多样性。

2.5 算法时间复杂度分析

在初始化阶段,本文采用佳点集初始化的复杂度为 $O(MND)$,其中, M 为目标函数个数, N 为种群大小, D 为变量维度;在进化阶段,交叉变异的复杂度为 $O(TND)$;在选择阶段,非支配排序和参考点选择机制的复杂度分别为 $O(TMN^2)$ 和 $O(TMN)$ 。本文前期采用参考点选择的复杂度为 $O(\frac{T}{2} \times NM) = O(TNM)$,后期采用拥挤距离选择 $O(\frac{T}{2} \times MN \log N) = O(TMN \log N)$,其中, T 为最大迭代次数(见表1)。

表1 时间复杂度分析表
Table 1 Time complexity analysis table

算法	初始化复杂度 (O_1)	交叉变异复杂度 (O_2)	非支配排序复杂度 (O_3)	选择机制复杂度 (O_4)
NSGA-II	$O(MND)$	$O(TND)$	$O(TMN^2)$	$O(TMN \log N)$
INSGA-II	$O(MND)$	$O(TND)$	$O(TMN^2)$	$O(TNM) + O(TMN \log N)$

从表1中可以看出,本文算法的复杂度与NSGA-II在初始化、交叉变异和非支配排序方面都相同,分别为 $O(MND)$, $O(TND)$ 和 $O(TMN^2)$ 。在选择机制上,NSGA-II采用拥挤距离选择,导致较高的计算复杂度。本文算法通过阶段性选择机制,前期采用参考点机制以减少计算复杂度。

3 低碳泊位岸桥调度模型

随着环境污染与全球气候变暖问题日益严重,能源短缺的加剧,在制定泊位分配和岸桥调度方案时,如何有效平衡港口的经济与环境效益是港口管理者不容回避的问题。因此,本文建立以最小化船舶等待成本、延迟离港成本、偏离偏好泊位成本和最小化船舶碳排放量的双目标模型^[27]。

$$\min f_1 = \sum_{i=1}^n [c_i^1 (tb_i - s_i) + c_i^2 (tb_i + t_i - e_i) + c_i^3 |p_i - b_i|], \quad (13)$$

$$\min f_2 = 3.11 \sum_{i=1}^n \frac{1}{24} (r_i^0 s_i + r_i^1 \frac{m_i^3}{s_i^2}) + 0.683 \sum_{i=1}^n PQ_i EN_i (tb_i + t_i - e_i). \quad (14)$$

其中, tb_i 为船舶 i 的靠泊时间, s_i 为船舶 i 预计抵达码头时间, t_i 为船舶 i 装卸时间, b_i 为船舶 i 偏好靠泊位置, e_i 为船舶 i 预计离港时间, p_i 为船舶 i 靠泊位置, c_i^1 为船舶 i 等待单位时间成本, c_i^2 为船舶 i 延迟离港单位时间成本, c_i^3 为船舶 i 偏离偏好泊位成本, r_i^0 为船舶 i 航行日辅机油耗量, r_i^1 为船舶 i 机舱系数, m_i 为船舶 i 距离港口距离, PQ_i 为船舶 i 辅机耗油率, EN_i 船舶 i 辅机的数量。

船舶靠泊时间与靠泊位置约束为

$$tb_i \geq s_i, \forall i \in V, \quad (15)$$

$$0 \leq p_i + l_i \leq L, \forall i \in V. \quad (16)$$

表示船舶 i 靠泊时间晚于到港时间和靠泊位置在岸线上。 l_i 为船舶 i 船长, L 为海岸线长度。

船舶 i 靠泊时间离港时间约束为

$$x_k + t_k + \theta_k \leq tb_i + M(1 - \varphi_{ki}), \forall i, k \in V, i \neq k. \quad (17)$$

表示船舶 i 靠泊时间需在船舶 k 装卸完成并且加入缓冲时间后进行靠泊。 θ_k 为船舶 k 的缓冲时间, φ_{ki} 为船舶 k 停泊在船舶 i 之前。

船舶 i 与船舶 k 位置约束为

$$\varphi_{ik} + \varphi_{ki} \leq 1, \forall i, k \in V, i \neq k, \quad (18)$$

$$\omega_{ik} + \omega_{ki} \leq 1, \forall i, k \in V, i \neq k, \quad (19)$$

$$1 \leq \varphi_{ik} + \varphi_{ki} + \omega_{ik} + \omega_{ki} \leq 2, \forall i, k \in V, i \neq k. \quad (20)$$

表示任意两艘船舶在靠泊时间和靠泊位置上不会发生冲突。 φ_{ik} 为船舶 i 停泊在船舶 k 之前, ω_{ik} 为船舶 i 在船舶 k 离港后靠泊。

船舶 i 岸桥约束为

$$\text{query}_{i \min} \leq \text{query}_i \leq \text{query}_{i \max}, \quad (21)$$

$$\sum_i \text{query}_{it} \leq \text{query}. \quad (22)$$

表示船舶 i 分配岸桥数量的取值范围以及同一时刻下港口使用的岸桥数量不能超过港口总数。 query_i 为船舶 i 分配的岸桥数量, $\text{query}_{i \min}$ 为船舶 i 分配最小岸桥数量, $\text{query}_{i \max}$ 为船舶 i 分配最大岸桥数量, query_{it} 在 t 时刻下的岸桥数, query 为港口总的岸桥数量。

船舶 i 参数约束为

$$S_{\min} \leq S_i \leq S_{\max}, \forall i \in V, \quad (23)$$

$$tb_i, p_i, \theta_i \geq 2, \forall i \in V, \quad (24)$$

$$\varphi_{ik}, \varphi_{ki}, \omega_{ik}, \omega_{ki} \in \{0, 1\}, \forall i, k \in V, i \neq k. \quad (25)$$

表示船舶 i 靠泊时间和决策变量的取值范围。

4 模型求解

4.1 实例求解流程

本文采用了 INSGA-II 算法对低碳泊位岸桥调度模型进行求解。整体的求解流程如算法 2 所示。

算法 2: 改进多目标遗传算法

输入: 佳点集生成初始种群 pop; 种群大小 N ; 迭代次数 Gen; 决策变量维度 nvar; 目标函数个数 M ; 船舶数量 n , 码头岸桥数量 query, 岸桥装卸效率 r

输出: 最优解集 pop

1: 初始化算法参数: 交叉概率 pC, 最大变异概率 maxMP, 最小变异概率 minMP, 参考点 Z_r 。

2: 按照 FCFS 生成 N 个可行解, 将初始解按照到港时间依次插入船舶时空图中, 当船舶与船舶发生重叠时进行约束调整。

3: 计算可行解的目标函数值, 按照非支配排序和拥挤距离选择初始种群。

4: for $i=1$: Gen

5: popc=Crossoverpop, nCrossover, popc, pC;

popm=Mutation(pop, minMP, maxMP, popm); % 对初始种群进行进化操作

6: 对不满足约束的个体进行约束处理。

7: 合并初始种群与子代种群, 并计算目标函数值。

8: if $i \leq \text{Gen}/2$ % 两阶段选择: 参考点选择和拥挤距离选择

9: [pop, F, params]=SortAndSelectPopulation(pop, params); % 个体标准化, 非支配排序, 建立参考点关联

10: 根据参考点进行选择。

11: else

12: [pop, F]=NonDominatedSorting(pop); % 非支配排序

pop=CalcCrowdingDistance(pop, F); %

计算拥挤距离

13: 根据拥挤距离选择。

14: end

15: end

16: pop←popgen

首先介绍算法根据先来先服务 (first-come-first-served, FCFS) 原则生成初始可行解; 对初始种群进化操作, 当进化操作后不满足约束的个体进行重叠调整和岸桥调整; 然后对产生的子代种群计

算其目标函数值;最后进行两阶段选择策略更新种群,参考点选择策略,拥挤距离选择策略;当达到终止条件时,输出最优解集 pop。

4.2 约束处理策略

(1) 重叠调整。针对船舶与船舶发生重叠的约束,本文采用的策略是对后到港的船舶进行约束处理。具体而言,通过对后到港的船舶进行多次调整,每次调整随机选择向上、向下或者向右3种策略之一,直到所有船舶满足时空不重叠约束的要求。重叠调整策略如图4所示,当船舶*i*与船舶*j*发生重叠时,对后到港的船舶*j*进行约束调整,红色虚线为船舶*j*调整后3种新的调度方案。

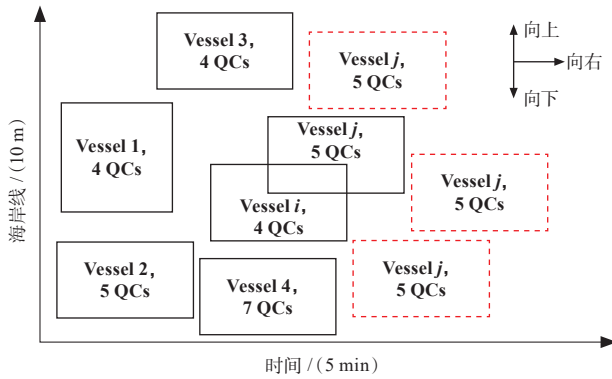


图4 船舶重叠约束处理策略

Fig. 4 Vessel overlap constraint handling strategy

(2) 岸桥调整。同一时刻下码头使用的岸桥数量不能超过码头拥有岸桥最大数量,否则后到港的船舶进行向右移动操作,等待有足够的岸桥后才能进行靠泊(见图5)。

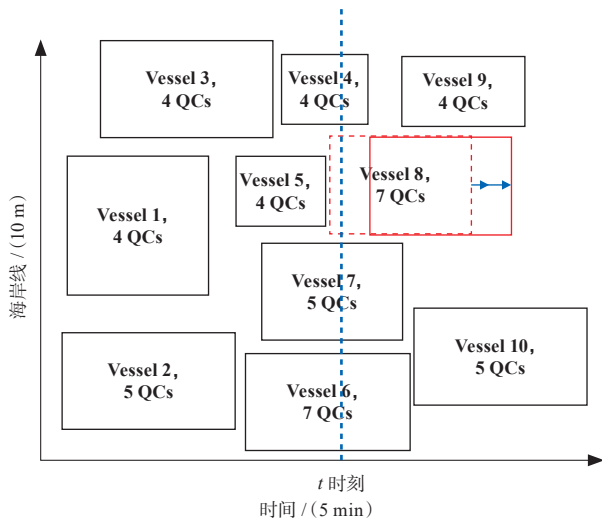


图5 船舶岸桥约束处理策略

Fig. 5 Quay crane constraint adjustment strategy

假设港口岸桥数量为20台,在*t*时刻,岸桥使用数量为16台,此时船舶8进行靠泊使用的岸桥数量超过码头岸桥数量,因此,将船舶8进行靠泊时间向右移动。

5 实验分析

为系统验证本文提出的 INSGA-II 算法的综合性能,本研究设计了层次化的对比实验方案。首先,采用消融实验思路分别将 NSGA-II 算法与3种改进策略相结合,在基准函数上与传统 NSGA-II 进行对比,以验证各改进策略对算法性能提升的独立贡献。其次,将 INSGA-II 与传统 NSGA-II、NSGA-III、多目标粒子群算法(MOPSO)、基于分解的多目标进化算法(MOEA/D)和多目标布谷鸟算法(MOCS)5个算法进行对比,验证其算法的有效性。最后,为了检验算法在复杂实际工程场景中的适用性,将 INSGA-II 应用于低碳泊位岸桥调度问题上验证其解决实际问题的有效性。本文实验在 Win10 Intel (R) Core (TM) i5-8300 CPU@2.30 GHz, 24 GB 内存机器上,由 MATLAB R2022a 编程实现。

5.1 基准函数上测试和分析

5.1.1 基准函数

为了测试本文提出的 INSGA-II 算法的有效性,选取 ZDT1~ZDT3^[28] 为基准函数。ZDT1 是经典的多目标测试函数,其 Pareto 前沿为连续凸集,为算法提供基础测试环境。ZDT2 将前沿改为非凸结构,提高了问题复杂度,用于检验算法处理非凸前沿的能力。ZDT3 进一步采用不连续前沿,对算法维持解集多样性提出了更高挑战。

5.1.2 参数设置

(1) 公共参数:两目标优化问题中,决策变量维度 $nVar=10, 20, 30$,迭代次数 $MaxIt=200, 300, 400$,种群大小 $pop=100$ 。

(2) INSGA-II 参数设置:交叉概率为 0.5;最大变异概率为 0.4,最小变异概率为 0.2;参考点维数 $nDivision=nVar$; $MaxIt/2$ 之前采用基于参考点关联进行选择, $MaxIt/2$ 之后采用非支配排序和拥挤距离进行选择。

(3) NSGA-III 参数设置:交叉概率为 0.5;变异概率为 0.4,变异的步长为 0.1;参考点维数 $nDivision=nVar$;采用基于参考点关联进行选择。

(4) NSGA-II 参数设置:交叉概率为 0.8;变异概率为 0.2,变异的步长为 0.1;采用非支配排序和拥挤距离进行选择。

(5) MOEA/D 参数设置: 领域大小 $T=0.15 \text{ pop}$, 交叉概率为 0.5, 变异概率为 0.2。

(6) MOCS 参数设置: 发现率 $pa=0.25$; 采用非支配排序和拥挤距离进行选择。

5.1.3 性能指标

本实验采用如下 3 个性能指标评价算法的性能^[28]: ① 世代距离 GD 用来衡量算法所得解集与真实 Pareto 前沿之间的逼近程度。GD 值越小, 表明所得解集在目标空间中的分布越贴近真实的 Pareto 前沿, 算法的收敛性能也越优。② 反世代距离 IGD 用于衡量真实 Pareto 前沿与算法所得解集的最短距离的平均值, 来评估算法解集的收敛性与分布性。IGD 值越小, 表明算法求得的解集在目标空间中越能逼近并覆盖真实 Pareto 前沿。③ 超体积 HV 指标用来衡量多目标解集所能覆盖的目标空间的“体积”。双目标问题的超体积的参考点为 $[1, 1]$, 超体积越大, 说明解集越接近理想的 Pareto 前沿。

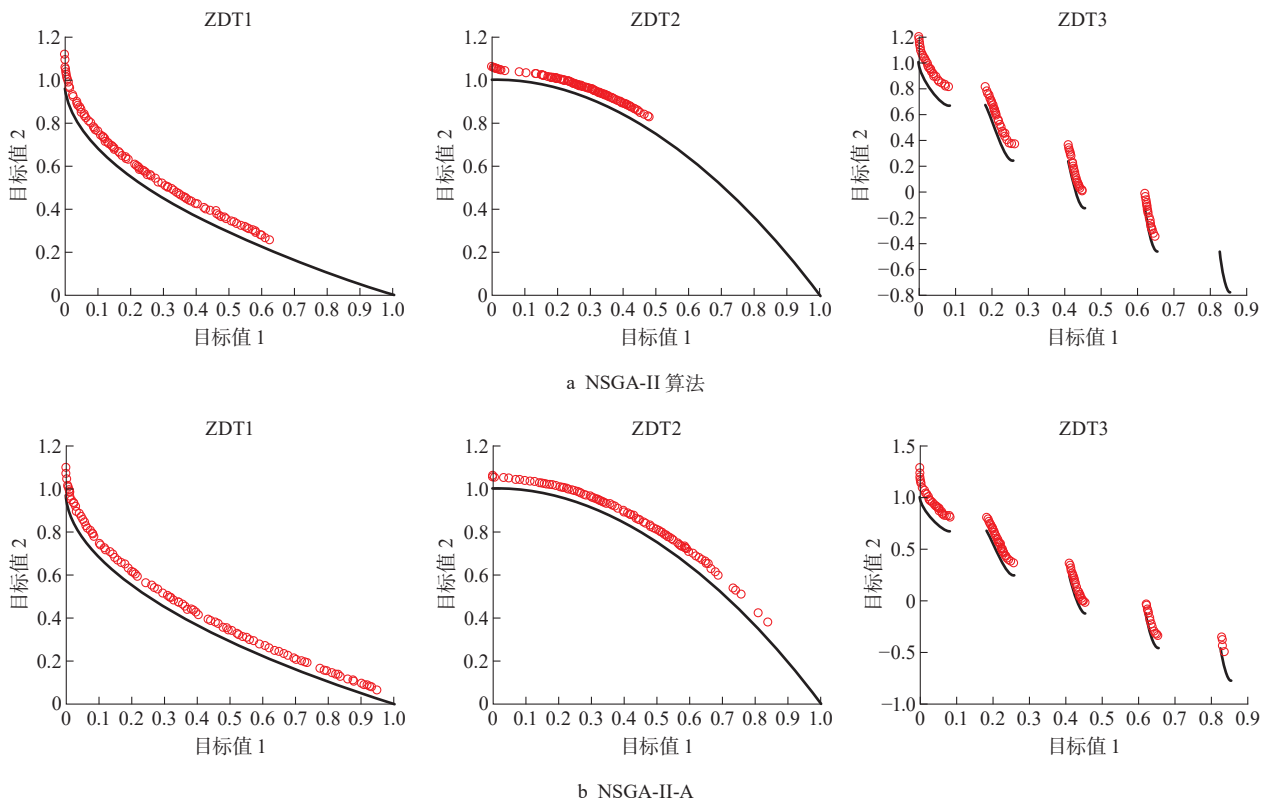
5.1.4 实验结果与分析

实验分为两组, 第一组验证本文提出的佳点集初始化、改进交叉变异和两阶段选择策略的有效性。第二组检验本文所提算法的有效性。

(1) 改进策略的有效性分析。为了验证佳点集初始化、改进交叉变异和两阶段选择策略的有效性, 将 NSGA-II 算法结合 3 种策略的算法, 记为

NSGA-II-A, NSGA-II-B 和 NSGA-II-C, 并与 NSGA-II 算法作对比。在 ZDT1~ZDT3 上进行测试, 迭代次数为 400, 决策变量维度为 30。实验分为 5 部分, 结果如图 6 所示, 图 6a 为 NSGA-II 算法求解基准函数的前沿图; 图 b~d 分别为 NSGA-II-A, NSGA-II-B 和 NSGA-II-C 算法求解基准函数的前沿图; e 为 INSGA-II 算法所求前沿图。

图 6 给出了 5 种算法求得基准函数近似 Pareto 前沿的对比图, 从图 6 可以看出, 在 ZDT1~ZDT3 测试函数上, 引入改进操作的 NSGA-II 算法在收敛性和多样性方面均表现出显著优势, 尤其当测试函数 Pareto 前沿呈现凹函数特性时, 其性能提升更为显著。具体而言, 图 6b 显示, 佳点集初始化有效地增加了种群的多样性, 但在收敛性方面表现欠佳; 图 6c 和 d 证实改进交叉变异策略和两阶段选择策略显著提升了种群在 Pareto 前沿上的收敛性; 图 6e 为本文所提算法在基准函数上求得 Pareto 前沿。与图 6a NSGA-II 算法相比, INSGA-II 算法所获得的 Pareto 前沿在收敛性和多样性方面均表现出显著优势, 其解集更逼近真实 Pareto 前沿, 充分验证了所提算法的有效性。综上所述, 本文提出的佳点集初始化策略、改进交叉变异策略和两阶段选择策略能够提升算法的种群多样性和收敛性能, INSGA-II 算法为多目标优化问题提供了有效的解决方案。



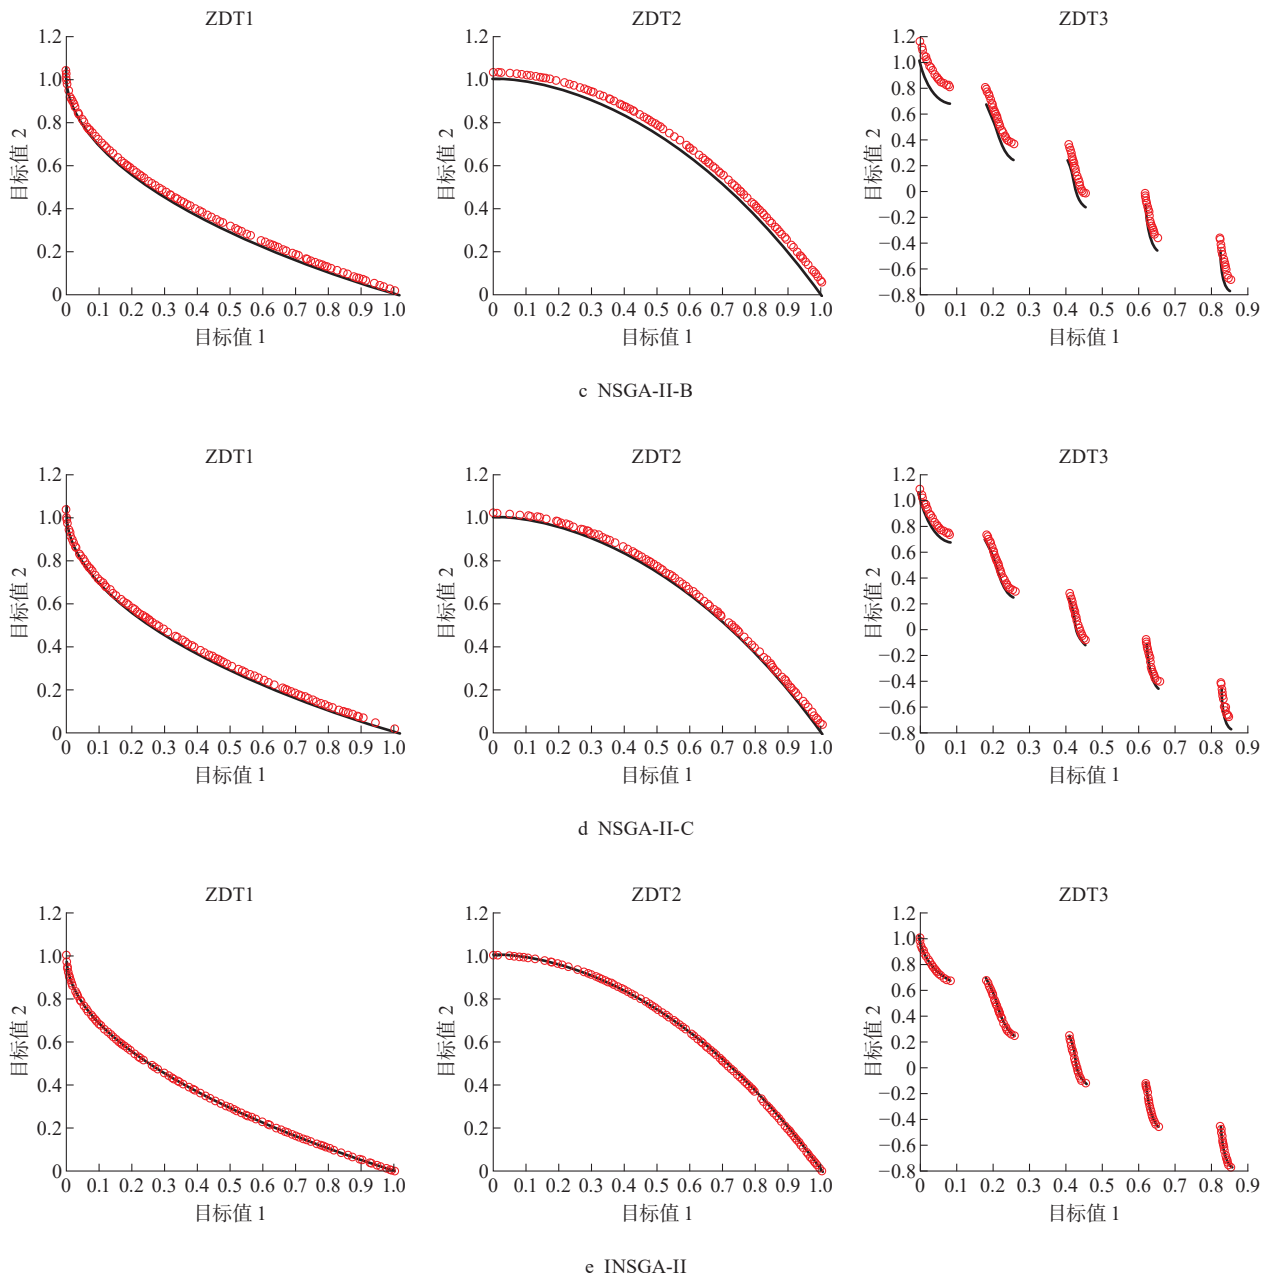


图 6 5种算法求解基准函数的前沿对比图

Fig. 6 Frontier comparison chart of five algorithms solving benchmark functions

(2) 算法有效性分析。将本文所提 INSGA-II 算法与 NSGA-III, NSGA-II, MOPSO, MOEAD 和 MOCS 算法对比, 体现本算法的有效性。在 3 个基准函数上进行测试, 算法分别独立运行 30 次。最终实验结果如图 7、表 2~4 所示。为了避免偶然性, 算法的评价指标采用均值进行比较, 最优结果加粗显示。

图 7 展示了 6 种算法在不同维度下求解基准函数的前沿对比。从图 7 中可以看出, 相较于其他算法, 本文提出的 INSGA-II 算法在低维及高维问题

上均展现出明显优势: 其前沿图不仅具有更好的收敛性与分布性, 而且解集更贴近真实 Pareto 前沿, 分布也更加均匀。值得注意的是, 随着决策变量维度的增加, INSGA-II 仍能保持稳定的优化性能, 而其他对比算法的收敛性和多样性则呈现下降趋势, 其解集与真实前沿的偏差逐渐增大。这一结果充分验证了 INSGA-II 算法在处理高维优化问题时的鲁棒性和有效性, 表明其在解决多目标优化问题方面具有显著优势。

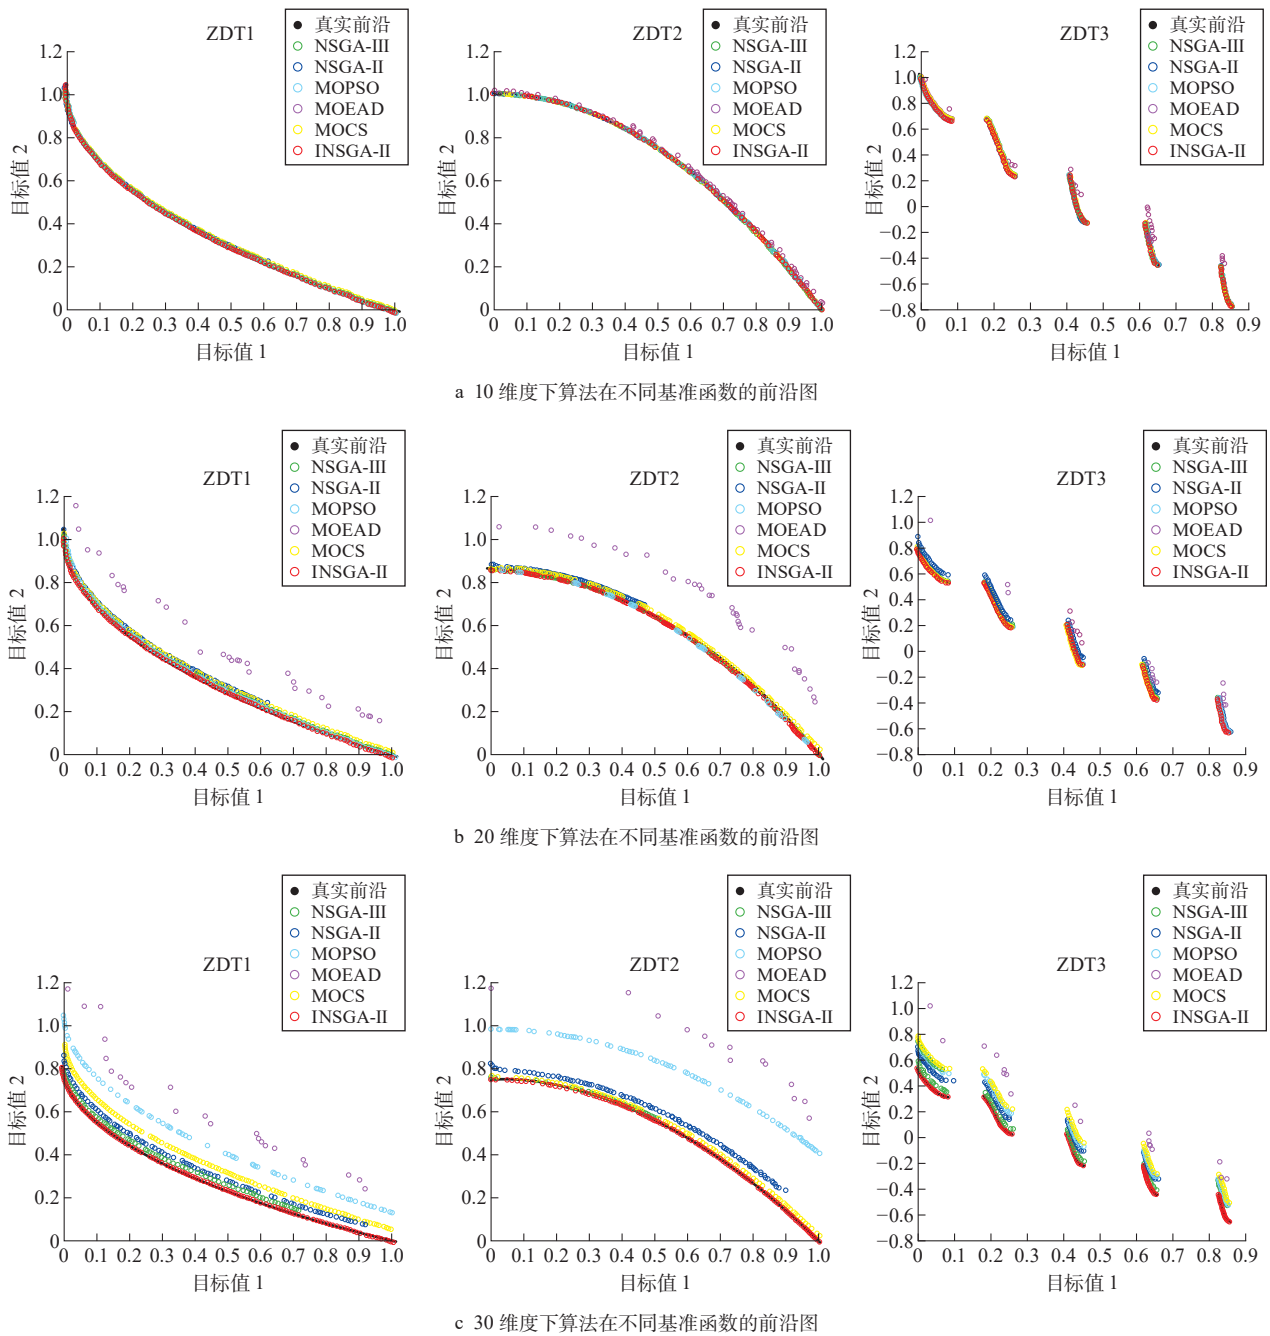


图 7 6 种算法在不同维度下求解基准函数的前沿图

Fig. 7 Frontier chart of six algorithms solving benchmark functions in different dimensions

表 2 6 种算法的世代距离指标比较

Table 2 Comparison of GD indicator of six algorithms

函数	维度	INSGA-II	NSGA-III	NSGA-II	MOPSO	MOEAD	MOCS
ZDT1	10	0.000 120	0.000 121	0.000 307	0.000 223	0.007 117	0.000 532
	20	0.000 133	0.000 823	0.001 652	0.002 679	0.011 740	0.002 075
	30	0.000 128	0.002 102	0.003 852	0.003 358	0.028 927	0.004 417
ZDT2	10	0.000 047	0.000 057	0.000 247	0.042 194	0.000 972	0.004 076
	20	0.000 047	0.000 529	0.001 809	0.268 143	0.017 042	0.007 777
	30	0.000 082	0.001 326	0.007 086	0.446 699	0.046 096	0.013 013
ZDT3	10	0.000 164	0.000 156	0.000 307	0.000 223	0.007 117	0.000 532
	20	0.000 172	0.000 605	0.002 002	0.000 897	0.017 494	0.001 403
	30	0.000 173	0.001 766	0.006 711	0.005 997	0.029 477	0.001 789

由表2可以看出,在世代距离GD指标上,除了在ZDT3的10维度方面,INSGA-II与NSGA-III算法无显著差异,在基准函数ZADT1~ZDT3的其他维度下,本文所提算法在所有指标上均优于对比算法。随着问题维度的增加,其他对比算法的GD值呈现明显上升趋势,表明其收敛性能逐渐下降。此外,图7a进一步验证了INSGA-II和NSGA-III

算法在ZDT3测试函数10维情况下均能收敛至基准函数的真实Pareto前沿。

由表3可以看出,在反世代距离IGD指标方面,本文提出的INSGA-II算法在所有基准函数的各个维度上均优于对比算法,这表明该算法不仅能够生成接近真实Pareto前沿的解集,而且其性能不受问题维度增加的影响,展现出良好的鲁棒性。

表3 6种算法的反世代距离指标比较

Table 3 Comparison of IGD indicator of six algorithms

函数	维度	INSGA-II	NSGA-III	NSGA-II	MOPSO	MOEAD	MOCS
ZDT1	10	0.004 557	0.011 723	0.029 066	0.008 792	0.121 727	0.008 650
	20	0.004 514	0.016 375	0.081 074	0.031 382	0.107 613	0.022 761
	30	0.004 490	0.041 566	0.121 190	0.038 061	0.263 063	0.044 767
ZDT2	10	0.004 732	0.081 644	0.013 328	0.480 787	0.016 980	0.159 865
	20	0.004 653	0.156 808	0.175 893	0.884 312	0.178 067	0.137 228
	30	0.004 941	0.172 060	0.309 311	1.093 265	0.465 440	0.169 803
ZDT3	10	0.007 496	0.013 370	0.029 066	0.008 792	0.121 727	0.008 650
	20	0.006 687	0.018 570	0.078 538	0.013 851	0.208 974	0.016 566
	30	0.005 650	0.040 563	0.132 318	0.060 285	0.294 243	0.020 532

表4 6种算法的超体积指标比较

Table 4 Comparison of HV indicator of six algorithms

函数	维度	INSGA-II	NSGA-III	NSGA-II	MOPSO	MOEAD	MOCS
ZDT1	10	0.719 825	0.711 280	0.711 430	0.657 723	0.634 074	0.657 207
	20	0.719 843	0.702 321	0.658 479	0.686 897	0.567 673	0.694 983
	30	0.719 878	0.677 959	0.618 740	0.677 382	0.375 725	0.666 149
ZDT2	10	0.444 355	0.372 232	0.426 460	0.215 229	0.422 897	0.334 437
	20	0.444 495	0.294 342	0.270 215	0.094 937	0.225 865	0.327 716
	30	0.443 920	0.274 830	0.166 267	0.039 054	0.052 170	0.326 720
ZDT3	10	0.661 132	0.663 432	0.711 430	0.657 723	0.634 074	0.657 207
	20	0.658 590	0.673 737	0.741 577	0.654 415	0.562 575	0.651 375
	30	0.658 798	0.690 933	0.711 408	0.627 253	0.505 084	0.648 549

由表4可以看出,在超体积HV指标方面,本文算法INSGA-II在ZDT1和ZDT2测试函数上均优于对比算法,表明其能够获得分布性和收敛性更近似Pareto前沿。然而,在ZDT3测试函数上,INSGA-II的HV值略低于NSGA-II算法。通过分析图7可知,这是由于NSGA-II算法在高维情况下未能收敛至真实Pareto前沿,但其解集分布性较好,从而导致HV值较高。这一现象进一步凸显了INSGA-II算法在收敛性和分布性之间的平衡能力。

5.2 低碳泊位岸桥调度仿真

5.2.1 参数设置

算法参数与“5.1.2”设置相同,在实例中船舶数量为30艘,港口岸桥数量20台,海岸线长度1 200 m,装卸效率3.33 TEU/(5 min),船舶参数设置如表5所示。 c_i^1 为1 000 l_i^1 (2 760元), c_i^2 为2 000 l_i^1 (2 760元),

c_i^3 为100 l_i^1 (230元), r_i^0 为2 t/d, r_i^1 为[0.12, 0.2] t/d, m_i 为[30, 2 000] n mile, PQ_i 为1.45 L/(5 min), EN_i 为[2, 4]台。

表5 船舶参数设置

Table 5 Ship parameter settings


船舶等级	船长	集装箱数量	行驶速度	岸桥数量
小船	[10, 15]	[800, 1 500]	[12, 18]	[3, 5]
中船	[15, 25]	[1 500, 2 500]	[14, 20]	[4, 6]
大船	[25, 30]	[2 500, 4 000]	[16, 22]	[5, 7]

5.2.2 结果分析


本文参照文献[29]中的实例生成规则随机生成实例,考虑在一周内到达的船只数量。为了验证3种改进策略和算法在解决实验问题的有效性,将实验分为两组,第一组是本文所提算法结合3种改进策

略在低碳泊位岸桥调度应用的有效性, 第二组是本文所提算法在低碳泊位岸桥调度应用的有效性。

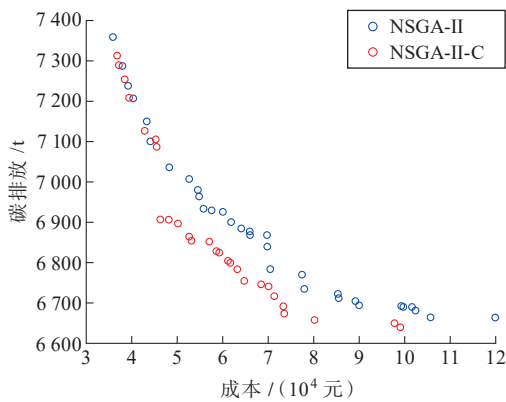
(1) 改进策略在低碳泊位岸桥调度应用的有效性。同“5.1.4”, 将 NSGA-II-A, NSGA-II-B 和 NSGA-II-C 与 NSGA-II 算法作对比 (见图 8a~c)。在低碳泊位岸桥调度问题上进行测试, 迭代次数为 400, 决策变量维度为 30。



a NSGA-II-A 与 NSGA-II




b NSGA-II-B 与 NSGA-II




c NSGA-II-C 与 NSGA-II

图 8a~c 分别为 NSGA-II-A, NSGA-II-B, NSGA-II-C 与 NSGA-II 算法在实例上的前沿对比图。从图 8a 可以看出, 使用佳点集初始化能够增强算法的多样性, 因为佳点集初始化的种群分布更加均匀, 为后续进化提供了更多的信息。从图 8b 可以看出, 采用改进交叉变异策略的算法具有更好的收敛性和多样性。从图 8c 可以看出, 采用两阶段选择策略可以选择出更优的调度方案。综上, 采用改进策略能够有效地提升算法性能, 在求解低碳泊位岸桥调度问题时能够得到更优的调度方案。


(2) 本文算法在低碳泊位岸桥调度应用的有效性。为了验证算法的有效性, 采用 INSGA-II 与 5 种对比算法求解低碳泊位分配和岸桥调度问题多目标优化模型 (见图 9a~d)。



a 6 种算法前沿图 (二维)



b 6 种算法前沿图 (三维)



c 本文算法前沿图

图 8 算法求解低碳泊位岸桥调度问题的前沿对比图
Fig. 8 Frontier comparison diagram for algorithm-based solution of low-carbon berth allocation and quay crane assignment

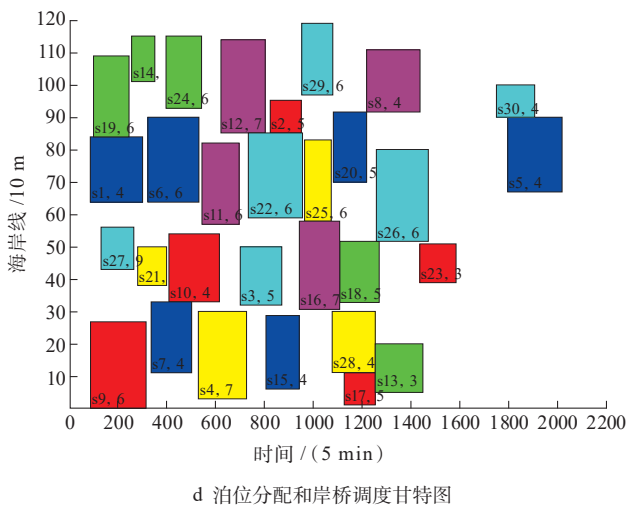


图9 低碳泊位分配和岸桥调度应用实例

Fig. 9 Practical application of the low-carbon berth allocation and quay crane assignment

图9a和b为6种算法求得低碳泊位分配和岸桥调度问题的Pareto前沿图,可以看出INSGA-II算法所求的Pareto前沿最好,NSGA-III的多样性表现最佳但其收敛性不及INSGA-II和MOPSO算法,所得前沿最不理想。综上所述,本文算法在实际问题中求得的解集具有较好的收敛性和分布性。图9c为本文算法求得的Pareto前沿图以及最优调度方案,其中最优调度方案是基于所得到的帕累托前沿对目标函数值进行归一化处理加权求和得出。图9d为最优调度方案的甘特图。

6 结论

本文提出了一种改进的多目标遗传算法,用于解决泊位分配和岸桥调度问题中高维决策变量问题。该算法结合了佳点集初始化、二项交叉、自适应变异和两阶段选择策略,显著提升了种群的多样性和算法的收敛性。佳点集初始化有助于算法在搜索初期就能更好地覆盖目标空间,而二项交叉和自适应变异则增强了算法的探索能力,避免了早期收敛的问题。两阶段选择策略在选择操作中引入了不同阶段的重点,从而提高了寻优过程中的稳定性和全局优化能力,且在求解高维决策变量问题时寻优性能不受影响。实验结果表明,本文算法在解决高维决策变量问题时,具备较强的鲁棒性和竞争力,展现了较好的实用价值。

在后续研究中,将考虑泊位分配和岸桥调度过程中可能存在的各种不确定性以及设备故障等问

题,调整调度模型更加贴近码头的实际情况。

参考文献:

- [1] 董明望,黄麟富,辜勇. 集装箱码头绿色作业调度优化研究综述[J]. 重庆交通大学学报(自然科学版), 2022, 41(11): 7-14.
- [2] CHARGUI K, ZOUADI T, SREEDHARAN V R. Berth and quay crane allocation and scheduling problem with renewable energy uncertainty: a robust exact decomposition[J]. Computers & Operations Research, 2023, 156: 106251.
- [3] 陆后军,张淞博,陆肖. 考虑碳排放的潮汐港泊位与岸桥联合分配方法研究[J]. 中国航海, 2024, 47(4): 97-104.
- [4] 闵德权,张志铎,张伟航. 基于港口环境效益的岸电与泊位联合分配优化研究[J]. 重庆交通大学学报(自然科学版), 2023, 42(1): 83-90.
- [5] MA Xiaomeng, PU Xujun. Low-carbon berth allocation: an analysis of the effectiveness of an enhanced multi-objective artificial bee colony algorithm based on a case study[J]. Ocean & Coastal Management, 2025, 261: 107529.
- [6] DEB K, PRATAP A, AGARWAL S, et al. A fast and elitist multiobjective genetic algorithm: NSGA-II[J]. IEEE Transactions on Evolutionary Computation, 2002, 6(2): 182-197.
- [7] ZHANG Tianyi, CHEN Lei, WANG Jin. Multi-objective optimization of elliptical tube fin heat exchangers based on neural networks and genetic algorithm[J]. Energy, 2023, 269: 126729.
- [8] 戴迎春,徐子瑞,蔡明明,等. 差分克隆选择算法在多机器人任务分配中的应用[J]. 江苏海洋大学学报(自然科学版), 2023, 32(1): 18-26.
- [9] 刘意杨,李浩,于洪霞,等. 基于自适应粒子群算法的园区能源互联网调度优化[J]. 江苏海洋大学学报(自然科学版), 2020, 29(4): 47-53.
- [10] WANG Xiaodong, HIRSCH C, KANG Shun, et al. Multi-objective optimization of turbomachinery using improved NSGA-II and approximation model[J]. Computer Methods in Applied Mechanics and Engineering, 2011, 200(9/10/11/12): 883-895.
- [11] LV Mengzheng, WANG Jianzhou, WANG Shuai, et al. Developing a hybrid system for stock selection and

- portfolio optimization with many-objective optimization based on deep learning and improved NSGA-III [J]. *Information Sciences*, 2024, 670: 120549.
- [12] LIU Tan, YUAN Qingyun, DING Xiaoming, et al. Multi-objective optimization for greenhouse light environment using Gaussian mixture model and an improved NSGA-II algorithm [J]. *Computers and Electronics in Agriculture*, 2023, 205: 107612.
- [13] 李鑫, 张亚丽, 李松, 等. 基于改进NSGA-II的混合储能系统容量优化配置[J]. *热力发电*, 2024, 53(12): 49-56.
- [14] 陈仁胜, 吴斌, 闫飞一. 基于混合学习策略的可变速AGV与机器绿色集成调度[J]. *控制与决策*, 2024, 39(12): 3955-3963.
- [15] YUAN Minghai, LI Yadong, ZHANG Lizhi, et al. Research on intelligent workshop resource scheduling method based on improved NSGA-II algorithm [J]. *Robotics and Computer-Integrated Manufacturing*, 2021, 71: 102141.
- [16] HAO Jian, YANG Xu, WANG Chen, et al. An improved NSGA-II algorithm based on adaptive weighting and searching strategy [J]. *Applied Sciences*, 2022, 12(22): 11573.
- [17] MA Haiping, ZHANG Yajing, SUN Shengyi, et al. A comprehensive survey on NSGA-II for multi-objective optimization and applications [J]. *Artificial Intelligence Review*, 2023, 56(12): 15217-15270.
- [18] VERMA S, PANT M, SNASEL V. A comprehensive review on NSGA-II for multi-objective combinatorial optimization problems [J]. *IEEE Access*, 2021, 9: 57757-57791.
- [19] 徐明, 王凤富, 龙文. 多策略改进的徒步优化算法及其应用[J]. *电子测量技术*, 2025, 48(3): 60-73.
- [20] HE Guang, LU Xiaoli. Good point set and double attractors based-QPSO and application in portfolio with transaction fee and financing cost [J]. *Expert Systems with Applications*, 2022, 209: 118339.
- [21] 程宪宝. 基于二项式交叉改进的人工蜂群算法[J]. *山东理工大学学报(自然科学版)*, 2016, 30(5): 74-78.
- [22] 王冠, 高尚, 房思佳. 基于自适应的NSGA-II多目标柔性作业车间调度[J]. *机床与液压*, 2022, 50(18): 129-135.
- [23] DAI Guangming, ZHOU Chong, WANG Maocai, et al. Indicator and reference points co-guided evolutionary algorithm for many-objective optimization problems [J]. *Knowledge-Based Systems*, 2018, 140: 50-63.
- [24] 王万良, 陈忠馥, 吴菲, 等. 基于个体预测的动态多目标优化算法[J]. *浙江大学学报(工学版)*, 2023, 57(11): 2133-2146.
- [25] DEB K, JAIN H. An evolutionary many-objective optimization algorithm using reference-point-based nondominated sorting approach, part I: solving problems with box constraints [J]. *IEEE Transactions on Evolutionary Computation*, 2013, 18(4): 577-601.
- [26] 魏光艳, 叶春明. 考虑转移时间的多目标双资源柔性作业车间节能调度[J]. *计算机集成制造系统*, 2025, 31(1): 67-88.
- [27] YU Feifei, SHAN Qihe, XIAO Yang, et al. Robust low-carbon discrete berth allocation under uncertainty [J]. *International Transactions on Electrical Energy Systems*, 2022, 2022(1): 5310004.
- [28] 宋小涛, 安斯光, 邹国平, 等. 基于改进灰狼优化算法的滤波天线优化设计[J]. *激光与光电子学进展*, 2025, 62(1): 322-330.
- [29] DAI Hongwei, MA Jinhui, YANG Yu, et al. A bi-layer model for berth allocation problem based on proactivereactive strategy [J]. *Computers & Industrial Engineering*, 2023, 179: 109200.