

NSGA-SA: 模拟退火增强型多目标优化算法及其热处理应用

陈杰¹, 庄百亮², 杨保华¹, 朱柏崴³, 唐恒耀⁴

- (1. 常州机电职业技术学院 信息工程学院, 江苏 常州 213164;
2. 中国机械总院集团江苏分院有限公司, 江苏 常州 213162;
3. 常州大学 机械与轨道交通学院, 江苏 常州 213164;
4. 江苏红豆工业互联网有限公司, 江苏 无锡 214104)

摘要: 在热处理工艺(淬火等)中, 工艺优化的核心难点在于硬度最大化与能耗最小化之间的目标冲突。传统非支配排序遗传算法(NSGA-II)在处理该问题时, 面临早熟收敛、解集分布不均等问题, 难以满足现场对解集多样性、全局搜索能力及实时决策的需求。为此, 提出一种融合模拟退火(SA)机制的改进算法——NSGA-SA。首先, 将SA的温度衰减机制与Metropolis概率接受准则嵌入NSGA-II的进化流程, 使模型能在高温阶段进行广泛的全局探索, 在低温阶段加速局部收敛, 从而提升解集的多样性和收敛精度; 其次, 引入自适应温度调度策略、混合选择及越界反射修正机制, 达成全局探索与局部精细优化之间的平衡。实验表明, 在标准测试函数和热处理工艺优化案例中, NSGA-SA在超体积(HV)、世代距离(GD)和解集熵(SE)等核心性能指标上, 显著优于原始NSGA-II和基于分解的多目标进化算法(MOEA/D), 所获得的均匀分布的帕累托解集可直接应用于制造执行系统(MES)或数字孪生平台, 为多目标工艺决策提供有效支持。

关键词: 多目标优化; NSGA-II; 模拟退火; 概率接受机制; 热处理工艺优化; 算法融合; 解集多样性

DOI: 10.11907/tj.251404

开放科学(资源服务)标识码(OSID):

中图分类号: TP305

文献标识码: A

文章编号: 1672-7800(2025)009-0087-12



NSGA-SA: Simulated Annealing Enhanced Multi-objective Optimization Algorithm and Its Application in Heat Treatment

CHEN Jie¹, ZHUANG Bailiang², YANG Baohua¹, ZHU Baiwei³, TANG Hengyao⁴

- (1. School of Information Engineering, Changzhou Vocational Institute of Mechatronic Technology, Changzhou 213164, China;
2. Jiangsu Branch of China Academy of Machinery Science and Technology Group Co Ltd, Changzhou 213162, China;
3. School of Mechanical Engineering and Rail Transit, Changzhou University, Changzhou 213164, China;
4. Jiangsu Hongdou Industrial Internet Co., Ltd., Wuxi 214104, China)

Abstract: Core difficulty of process optimization in heat treatment processes (such as quenching) lies in the conflict between maximizing hardness and minimizing energy consumption. The traditional non dominated sorting genetic algorithm (NSGA-II) faces the problems of premature convergence and uneven distribution of solution sets when dealing with this problem, which makes it difficult to meet the requirements of solution set diversity, global search ability, and real-time decision-making in the field. To this end, an improved algorithm called NSGA-SA is proposed, which integrates simulated annealing (SA) mechanism. Firstly, the temperature decay mechanism of SA and the Metropolis probability acceptance criterion are embedded into the evolutionary process of NSGA-II, enabling the model to conduct extensive global exploration and local convergence acceleration in the low temperature stage, thereby improving the diversity and convergence accuracy of the solution set; Secondly, an adaptive temperature scheduling strategy, mixed selection and boundary reflection correction mechanism are introduced to achieve a balance between global exploration and local fine optimization. Experimental results show that in standard test functions and heat treatment process optimization cases, NSGA-SA significantly outperforms the original NSGA-II and decomposition-based multi-objective evolutionary algorithms (MOEA/D) in core performance indicators such as hypervolume (HV), generational distance (GD), and solution set entropy (SE). The obtained uniformly distributed Pareto solution set can be directly applied to manufacturing execution systems (MES) or digital twin platforms, providing effective support for multi-objective process decision-making.

收稿日期: 2025-06-13

扫描二维码阅读全文:



基金项目: 江苏省产学研合作项目(BY20231372); 教育部中外人文交流中心与人工智能与先进制造中外人文交流研究院人文交流专项研究课题(CCIPIERGZN202405); 现代职业教育科教融汇课题(KJ2024Y0015); 常州机电职业技术学院课题(2024KJYB01)

作者简介: 陈杰(1988-), 男, 硕士, 常州机电职业技术学院信息工程学院高级工程师, 研究方向为智能制造。

ration in the high temperature stage and accelerate local convergence in the low temperature stage, thereby improving the diversity and convergence accuracy of the solution set; Secondly, an adaptive temperature scheduling strategy, mixed selection, and out of bounds reflection correction mechanism are introduced to achieve a balance between global exploration and local fine optimization. Experiments have shown that in standard test functions and heat treatment process optimization cases, NSGA-SA significantly outperforms the original NSGA-II and decomposition based multi-objective evolutionary algorithm (MOEA/D) in core performance indicators such as hypervolume (HV), generation distance (GD), and set entropy (SE). The uniformly distributed Pareto solution set obtained can be directly applied to manufacturing execution systems (MES) or digital twin platforms, providing effective support for multi-objective process decision-making.

Key Words: multi-objective optimization; NSGA-II; simulated annealing; probability acceptance mechanism; heat treatment process optimization; algorithm fusion; solution diversity

0 引言

在热处理工艺这种复杂多变的应用场景中,多目标优化已成为提升系统性能、降低综合成本的关键技术之一^[1-3]。本文聚焦热处理工艺中的核心冲突目标——材料硬度偏差最小化与工艺能耗最小化。这两个目标存在本质冲突:提升淬火温度可减少硬度偏差,却会显著增加能耗;延长保温时间能提升材料强度,但会以指数级扩大能耗,同时在由淬火温度、保温时间等高维参数构成的解空间中更复杂。

在此背景下,传统的非支配排序遗传算法(Non-dominated Sorting Genetic Algorithm II, NSGA-II)因其优越的并行群体搜索和精英保留策略,现已广泛应用于多目标优化领域,但仍存在收敛速度慢、解集多样性不足、无法保证 Pareto 前沿的全面性问题^[4,5]。在热处理工艺优化中,现场需要在保证硬度达标的前提下尽可能降低能耗,以降低成本、碳排放,因此对优化算法的鲁棒性和高效性提出了更高的要求。

模拟退火(Simulated Annealing, SA)作为一种经典的全局优化算法,通过 Metropolis 接受准则在全局探索与局部开发之间提供平衡,以有效避免算法陷入局部最优解^[6]。然而,SA 的单点搜索特性在高维目标空间中的效率较低,限制了其在复杂多目标优化问题中的应用。因此,将 NSGA-II 的并行优势与 SA 的全局搜索能力相结合,成为了提升多目标优化性能的重要研究方向^[7-12]。

为此,本文提出一种融合模拟退火机制的改进算法 NSGA-SA。首先,引入基于温度的 Metropolis 接受准则,利用温度衰减机制在高温阶段进行广泛的全局探索,在低温阶段加速局部收敛;其次,保留 NSGA-II 原有的精英保留特性,以提升解集多样性和收敛性^[13]。实验表明,通过进化+退火双机制结构的协同工作,在处理复杂的多目标冲突问题时全局搜索能力更强、实用价值更高,尤其适用于热处理工艺优化、调度、能效优化等应用场景。

本文内容结构安排如下:首先,介绍了热处理工艺场景模型的构建过程;其次,详细阐述了 NSGA-SA 算法的设计原理与实现流程;再次,针对模型进行实验设计,对实验结果进行深入分析;最后,总结全文主要研究成果,对未来研究方向进行展望。该结构设计旨在保持理论深度的同

时,提供一个涵盖算法设计、性能验证到工程应用的全过程框架,为后续多目标优化方法的研究及其在工业领域的应用迁移提供坚实的理论基础。

1 热处理工艺场景模型建设

1.1 模型建设

本文模型针对中碳钢进行建设,以 45 号钢等典型材料为例,该材料因其优良的综合机械性能,在机械制造领域得到了广泛应用。中碳钢适用于多种热处理工艺,例如淬火一回火、正火及调质处理等。本文将重点关注淬火热处理工艺,目的是通过多目标优化方法合理选择工艺参数,从而在材料硬度最大化与能耗最小化之间达到平衡^[14]。

在淬火过程中,钢材先被加热至奥氏体化温度(通常位于特定的范围),此时材料组织会转变为奥氏体结构;再通过保温和快速冷却使钢材形成马氏体组织,从而提升材料硬度和强度,模型曲线如图 1 所示。




Fig. 1 Quenching process curve

图1 淬火工艺曲线

由表 1 可知,淬火温度、保温时间等都是影响淬火工艺效率和钢材性能的关键因素,精确控制和优化参数可大幅提升产品质量和生产效率。

本文模型的优化难点在于:硬度偏差与能耗存在显著冲突(提升淬火温度可提升硬度,但会增加能耗);参数维度高(淬火温度、保温时间等多变量耦合);易陷入局部最优。同时,传统 NSGA-II 因解集分布不均,无法高效生成全面 Pareto 解,而现场的需求为通过多目标优化快速获得低能耗、高硬度的可行方案,以支持生产执行系统(Manufacturing Execution System, MES)进行实时决策或数字孪

Table 1 Key factors of process and physics				
表 1 工艺与物理关键因素				
参数编号	参数名称	参数符号	单位	说明
1	淬火温度	T_{aus}	℃	钢件加热至该温度以形成奥氏体
2	保温时间	t_{hold}	min	保持在奥氏体化温度下的时间
3	冷却时间	t_{cold}	s	从奥氏体化温度冷却至室温所用时间
4	比热容	C_p	kJ/(kg·℃)	代表材料单位质量温度变化所需吸收的热量
5	单件质量	m	kg	表示单个零件的质量,影响总能耗
6	炉效率	η_{fur}		热处理炉能量转换效率,考虑能源损失
7	环境温度	T_{amp}	℃	能耗计算的参考温度基准

生平台正常运行。

1.2 目标函数建模

(1)硬度偏差目标函数。采用经验模型近似硬度(Rockwell Hardness C scale, HRC),基于工艺参数可得:

$$HRC = 55 - 0.02 \times (T_{\text{aus}} - 860) - 0.03 \times t_{\text{hold}} \tag{1}$$

同时,定义硬度偏差为目标函数。

$$f_1 = |HRC - HRC_{\text{target}}| \tag{2}$$

式中: HRC_{target} 为工业需求的硬度标准值,如 50 HRC,确保优化结果符合产品性能要求; T_{aus} 表示淬火时间; t_{hold} 表示保温时间。

(2)能耗目标函数。本文依据热工学基本原理,将工艺能耗近似为加热过程中传递给钢材的热量,以修正实际炉膛效率考虑后的能耗。

$$f_2 = \frac{C_p \times m \times (T_{\text{aus}} - T_{\text{amb}}) \times t_{\text{hold}}}{\eta_{\text{fur}} \times 1000} \tag{3}$$

式中: C_p 为钢的比热容; m 为单件质量; T_{amb} 为环境温度; η_{fur} 为炉膛效率。

通过目标函数反映能耗的大小,单位为兆焦(MJ),目的是尽可能降低能耗以节省成本和减少碳排放。

(3)模型意义。将热处理工艺中的关键变量与物理特性紧密结合,实现物理量化与优化变量的有机统一。在建模过程中,模型以硬度偏差、能耗为目标,为多目标优化算法提供明确的评价标准和优化方向,进一步促进算法在实际工艺参数优化中有效应用。该模型基于关键工艺参数与物理特性进行构建,确保了模型与实际工艺的高度一致

性,还有效实施了多目标优化算法,使模型在保证硬度与能耗平衡的基础上能进一步优化工艺参数。

综上,通过该模型的优化热处理工艺,能在实际生产中实现智能化,不仅提升了工艺优化的科学性、精准性,还为智能制造中的工艺参数优化提供了坚实基础。

2 NSGA-SA 的设计原理与实现流程

2.1 算法总体设计

NSGA-SA 算法通过融合非支配排序遗传算法与模拟退火机制构建双阶段优化框架^[15,16]。首先,将 SA 的 Metropolis 概率接受准则嵌入 NSGA-II 进化流程,利用温度衰减动态平衡探索与开发这两个过程,显著提升了模型跳出局部最优的能力;其次,单一闭环的“进化+退火”双机制协同(区别于传统两层结构),在保证精英保留的同时增强解集多样性和收敛速度。

本文框架适用于多目标冲突严重的工程场景(热处理工艺参数优化、柔性作业调度、能效管理等),通过自适应温度调度直接支持 MES 决策,降低人工调参成本(见图 2)。算法流程包含 7 个核心步骤,温度调制策略贯穿变异操作,以实现全局探索与局部开发的动态平衡。

(1)种群初始化。在 D 维解空间($D = 30$)生成 N 个个体($N = 100$),每个基因位采用均匀分布采样。

$$x_j^{(0)} \sim U(0, 1) \quad i = 1, 2, \dots, N; j = 1, 2, \dots, D \tag{4}$$

式中: i 为个体索引; j 为维度索引; $U(0, 1)$ 表示 $[0, 1]$ 区间的均匀分布。

(2)非支配排序。通过快速非支配排序算法将种群划分为 K 个前沿层 $F_1, F_2, \dots, F_k, F_1$ 为最优前沿,支配关系定义为解 a 支配解 b ,当且仅当式(5)成立。

$$\forall m \in 1, 2, f_m(a) \leq f_m(b) \text{ 且 } \exists m \in 1, 2, f_m(a) < f_m(b) \tag{5}$$

式中: $f_m(a)$ 表示解 a 在目标 m 上的适应度值; a, b 为种群中的两个解,解 a 支配解 b 的条件为对于所有目标 $m \in \{1, 2\}$,解 a 在每个目标上的适应度值都不大于解 b 的适应度值,且至少存在一个目标 m 使得解 a 在该目标上的适应度值严格小于解 b 的适应度值。

(3)拥挤度计算。针对每个前沿层的个体计算拥挤距离,以确保解集分布性。




Fig. 2 Algorithm flow
图 2 算法流程

$$d_i = \sum_{m=1}^2 \frac{f_m^{(i+1)} - f_m^{(i-1)}}{f_m^{\max} - f_m^{\min}} \quad (6)$$

式中: $f_m^{(i)}$ 表示第 i 个个体在第 m 个目标函数上的值, 分母为目标函数的取值范围。

(4) 遗传操作。本文采用模拟二进制交叉 (Simulated Binary Crossover, SBX) 与退火变异混合策略进行处理^[17]。交叉操作生成子代个体为:

$$x_{child} = \begin{cases} 0.5[(1+\beta)x_p + (1-\beta)x_q] & \text{if rand} \leq 0.5 \\ 0.5[(1-\beta)x_p + (1+\beta)x_q] & \text{else} \end{cases} \quad (7)$$

$$\beta = (2u)^{1/(\eta+1)} \quad (8)$$

式中: $u \in [0, 1]$ 为随机数; $\eta = 20$ 为分布指数; x_p, x_q 分别为父代个体 p, q 的基因值; β 为分布因子; 随机数 rand 取值在 $[0, 1]$; η 为控制搜索空间宽度的分布指数, 通常设置为 20; u 为在 $[0, 1]$ 范围内的随机数。

(5) 退火变异。模拟退火变异操作中, 针对每个变异体计算适应度差 Δ 。

$$\Delta = \Sigma(f_{mut} - f_{orig}) \quad (9)$$

式中: f_{mut}, f_{orig} 分别为变异体和原解的适应度值。

计算每个变异解的适应度差, 并根据差值的正负决定是否接受变异解, 接受概率的公式为^[18]:

$$P_{accept} = \begin{cases} 1 & \Delta \leq 0 \\ \exp\left(-\frac{\Delta}{T(t)}\right) & \Delta > 0 \end{cases} \quad (10)$$

式中: Δ 表示变异后解与原始解的适应度差, 若 $\Delta \leq 0$ 则直接接受变异解; 若 $\Delta > 0$ 则通过 Metropolis 概率接受机制决定是否接受变异解。

Metropolis 概率接受机制随着温度 $T(t)$ 的变化调整变异接受概率。

$$T(t) = T_0 \cdot \exp\left(-\frac{t}{50}\right) \quad t \in [0, 200] \quad (11)$$

式中: $T(t)$ 表示温度随迭代次数 t 的变化情况; t 在 $[0, 200]$ 的范围内取值, 温度初始值 T_0 从 1 000 开始, 根据时间逐渐衰减, 直至收敛。

(6) 环境选择。在合并父代与子代种群后, 按非支配等级、拥挤度筛选新一代种群, 选择标准优先保留低前沿个体, 再将同层个体按拥挤度进行排序。

(7) 终止判断。算法达到最大代数 $\text{MAX_GEN}=200$ 时终止迭代, 输出 Pareto 最优解集。

2.2 关键算子设计

在 NSGA-SA 算法中, 关键算子为算法的高效性和稳定性提供了保证, 主要的关键算子包括: 自适应退火温度调度、混合选择策略及越界反射修正机制, 协同工作可优化算法的多目标性能。

(1) 自适应退火温度。自适应退火温度的设计对平衡全局探索与局部开发至关重要, 算法采用指数衰减的温度调度函数 (见式 (9)~(11)) 控制温度在每一代中的变化。初始阶段温度较高, 可增强全局搜索能力; 不断迭代后温

度逐渐降低, 可促进局部精细化收敛。如此, 该机制能使 NSGA-SA 有效避免在复杂目标空间中发生早熟收敛, 提升了解集多样性与全局搜索能力。

(2) 混合选择策略。混合选择策略结合了 NSGA-II 的非支配排序和拥挤度计算, 确保了算法在选择过程中的多样性和精确性。通过锦标赛选择可优先选择支配层次较低的个体, 再依据拥挤度在同层次个体间进行选择, 以保留解集中的多样性, 确保最优解传递给下一代^[19]。如此, 该策略可增强种群多样性, 有助于提升最终的解集质量。

(3) 约束处理机制。越界反射修正机制用于解决可能出现的越界问题, 确保每个解始终保持在可行解空间内。对于越界的个体, 反射修正策略将解值调整回可行域内以避免产生无效解, 并保证优化过程满足约束。上述操作对处理约束优化问题尤其重要, 确保了算法在复杂约束条件下的可行性和可靠性。

NSGA-SA 通过 3 种关键算子协同作用, 既保证了解集多样性, 又加速了收敛过程, 可有效应对高维目标空间中的优化挑战, 在处理复杂目标冲突的工程问题时优势突出, 例如热处理工艺优化、调度问题、能效优化等应用场景。

2.3 理论分析

2.3.1 马尔可夫链收敛性

首先, 定义马尔可夫链状态空间 S 为所有可能种群集合, 转移概率矩阵 P 需满足式 (12)^[20]。当温度调度满足时, 计算公式如式 (13) 所示。

$$\forall s \in S, \exists n \geq 1, P^n(s, s^*) > 0 \quad (12)$$

$$\sum T(t) = \infty \ \& \ \sum e^{-1/T(t)} < \infty \quad (13)$$

式中: s^* 为包含全局 Pareto 最优解的种群状态; $P^n(s, s^*) > 0$ 表示经过一定的迭代后, 状态 s 会有一定的概率转换到全局最优解状态 s^* 。

温度函数 $T(t)$ 通过逐渐下降的方式控制全局搜索与局部优化的平衡。

$$T(t) = 1000e^{-t/50} \quad (14)$$

式 (14) 保证了温度在模拟退火过程中逐渐降低, 使算法在初期阶段可保持较强的全局搜索能力; 后期温度逐步下降将加快局部优化收敛速度, 以提升解集质量, 避免算法早熟收敛。

2.3.2 时间复杂度分析

本文将分析 3 种算法的时间复杂度, 以揭示算法随输入规模增长的趋势, 相关参数如表 2 所示。具体的, NSGA-SA 的时间复杂度包括: 非支配排序时间复杂度 $O(MN^2)$ 、退火变异时间复杂度 $O(N \cdot D \cdot K)$ 、环境选择时间复杂度 $O(N \log N)$ 。

$$O(MN^2) = O(2 \times 100^2) = 2 \times 10^4 \quad (15)$$

$$O(N \cdot D \cdot K) = O(100 \times 30 \times 1) = 3 \times 10^3 \quad (16)$$

$$O(N \log N) = O(100 \times \log 100) \approx 2 \times 10^2 \quad (17)$$

综上, NSGA-SA 的时间复杂度公式为:

$$O(G(MN^2 + NDK)) = O(200 \times (2 \times 10^4 + 3 \times 10^3)) \\ = 4.6 \times 10^6 \quad (18)$$

此外, 标准 NSGA-II 的时间复杂度 $O(GMN^2)$ 、MOEA/D 的时间复杂度 $O(GNTD)$ 为:

$$O(GMN^2) = 4 \times 10^6 \quad (19)$$

$$O(GNTD) = 1.2 \times 10^7 \quad (20)$$

由此可知, NSGA-SA 算法引入模拟退火变异机制, 相较于 NSGA-II 增加了约 15% 的计算负担, 但优化增益显著增加 (见 3.5 节); MOEA/D 的复杂度最高 (NSGA-SA 的 2.6 倍), 解集质量也低于 NSGA-SA (见 3.5 节), 突显了 NSGA-SA 在计算效率与优化性能间达到了良好的平衡。

Table 2 Time complexity parameter

表 2 时间复杂度参数

序号	符号	含义	取值	来源
1	M	目标函数数量	2	问题定义 (1.2 节)
2	N	种群规模	100	实验设置 (3.1 节)
3	D	决策变量维度	30	ZDT1 问题定义 (3.1 节)
4	G	最大进化代数	200	实验设置 (3.1 节)
5	T	MOEA/D 邻居规模	20	算法对比基准

3 实验结果与分析

3.1 实验设计

本文研究构建了一个层级化的实验验证体系, 以系统




Fig. 3 Experimental procedure

图 3 实验流程

3.2 ZDT1 问题定义与数据来源

3.2.1 问题背景与重要性

ZDT1 问题是经典的多目标优化问题之一, 被广泛用于验证多目标优化算法的性能, 其目标函数之间存在冲突, 即优化一个目标通常会导致另一个目标退化, 因此能有效测试优化算法在解决目标中存在的权衡问题。此外, ZDT1 的简洁性与目标间的冲突, 具有典型的多目标优化特性, 使其成为多目标优化研究中的基准问题, 尤其适用于评估算法在解空间的收敛性和解集多样性方面的表现, 已广泛应用于各类优化算法的比较和性能评估中。

3.2.2 目标函数之间的冲突

ZDT1 问题的两个目标函数 f_1, f_2 存在显著冲突, f_1 为决策变量 x_1 的值, f_2 则依赖于 $g(x)$ 的加权与 f_1 的值, 优化 f_1 会

评估 NSGA-SA 算法的综合性能。实验框架以标准测试函数 1 号 (Zitzler-Deb-Thiele Test Function 1, ZDT1) 为基准起点, 通过比较实验全面分析算法在收敛性、解集多样性和鲁棒性等核心维度的表现^[21]。同时, 进一步将验证场景延伸至 45 号钢淬火工艺这一典型工业应用场景, 从而实现从理论验证到工程实践的无缝衔接。

实验采用 NSGA-SA、原始 NSGA-II 和 MOEA/D 等 3 组对照算法进行平行比较, 通过超体积 (Hypervolume, HV)、世代距离 (Generation Distance, GD)、解集熵 (Spread Entropy, SE) 等指标, 衡量算法在高温广搜阶段的探索能力和低温精收阶段的收敛特性^[22-24]。

在工业验证环节, 基于建立的淬火工艺多目标优化模型, 将 ZDT1 的前沿特性映射至硬度—能耗目标空间, 以深入分析工艺参数优化解集的工程实用价值。同时, 为标准测试函数与实际工艺的联系, 定义 ZDT1 函数与淬火工艺目标空间的映射关系:

$$\begin{cases} f_1(x) \rightarrow |HRC - 50| \\ f_2(g) \rightarrow \text{能耗目标} \end{cases} \quad (21)$$

式中: $f_1(x)$ 对应硬度偏差目标 (见式 (2)); $f_2(g)$ 对应能耗目标 (见式 (3))。

为了验证算法的性能差异, 结合三维帕累托前沿可视化、热力图等多元呈现方式, 全方位展示 NSGA-SA 在保持解集均匀分布、加速收敛速率及提升工艺参数优化质量等方面的突破性优势, 实验流程图如图 3 所示。

导致 $g(x)$ 的变化, 从而影响 f_2 。在多目标优化中, 由于目标函数之间的冲突, 无法同时优化两个目标, 因此可有效测试算法在处理目标冲突间的权衡能力。

3.2.3 目标函数与变量定义

ZDT1 问题具有两个目标函数和多个决策变量。

$$f_1(x) = x_1 \quad (22)$$

$$g(x) = 1 + 9 \cdot \frac{\sum_{i=2}^n x_i}{n-1} \quad (23)$$

$$f_2(x) = g(x) \cdot \left(1 - \sqrt{\frac{f_1(x)}{g(x)}}\right) \quad (24)$$

式中: f_1 为目标函数 1, 等于第一个决策变量 x_1 , 取值范围为 $[0, 1]$; $g(x)$ 为决策变量的累加函数, 表示 $x_2, x_3, \dots, x_n$ 的加权和, 取值范围为 $[0, 1]$, 为目标函数 2 计算的中介;

$f_2(x)$ 为目标函数2,通过 $g(x)$ 与 $f_1(x)$ 计算得到的函数,以体现两个目标函数之间的冲突。

3.2.4 数据生成

本文实验的测试数据由ZDT1问题公式生成,设定了每个个体的决策变量数量 $n_variables = 30$,即每个个体由30个决策变量构成,并使用 $np.random.uniform(0, 1, n_variables)$ 生成了一个在 $[0, 1]$ 范围内均匀分布的随机决策向量,以计算目标函数 f_1, f_2 的值。通过该方式生成的随机决策向量被用于计算多个样本,使每个样本都有对应的目标函数值,进而为多目标优化算法提供测试数据。

3.3 参数敏感性分析

为了确定NSGA-SA的最优参数组合,针对初始温度 T_0 、衰减系数 α 设计控制变量实验,结果如表3所示。同时,通过实验全面评估参数组合对优化性能的影响,以直观展示不同配置下的指标差异,结果如表4所示。表4的定量结果揭示了参数选择的本质特征,由参数敏感性分析显示:当初始温度 $T_0=1\ 000$ 时,HV达到峰值0.865 3,相较于 $T_0=800$ 的配置提升1.7%;当衰减系数 $\alpha=0.02$ 时,GD达到最低值0.006 1,相较于 $\alpha=0.03$ 时降低15.3%;在高温阶段接受率接近40%时解集多样性表现最优,SE达3.412 6。

综上, $T_0=1\ 000$ 与 $\alpha=0.02$ 为最优参数组合,在高HV、低GD和优SE方面取得了平衡,显著提升了NSGA-SA在ZDT1函数上的性能。

Table 3 Testing configuration

表3 实验设置

序号	内容	参数	备注
1	测试函数	ZDT1	D=30
2	对比参数	$T_0 \in \{800, 1\ 000, 1\ 200\}, \alpha \in \{0.01, 0.02, 0.03\}$	
3	评估指标	HV、GD、SE	同3.1节定义
4	基准配置	种群 $N=100$, 迭代 $G=200$	

Table 4 Parameter sensitivity analysis experiment

表4 参数敏感分析实验

序号	参数组合	超体积 (HV)	世代距离 (GD)	解集熵 (SE)	收敛代数
1	$T_0=800, \alpha=0.02$	0.851 2	0.007 5	3.352 1	182
2	$T_0=1\ 000, \alpha=0.02$	0.865 3	0.006 1	3.412 6	175
3	$T_0=1\ 200, \alpha=0.02$	0.863 1	0.006 3	3.401 2	189
4	$T_0=1\ 000, \alpha=0.01$	0.859 7	0.006 9	3.428 9	192
5	$T_0=1\ 000, \alpha=0.03$	0.856 4	0.007 2	3.332 7	180

3.4 ZDT1实验数据下的解集分布

3.4.1 NSGA-SA算法解集分布

为了直观展示算法的优化效果,通过Python绘制了NSGA-SA算法在ZDT1问题上的帕累托前沿图(见图4),以便更好地理解解集分布情况及其收敛性。由此可见,NSGA-SA算法在解集前端、后端区域分布较好。

为了进一步深入分析解集的分布情况,对前25个解和后25个解进行了详细采样,以展示这些点的具体情况(见表5),包括目标函数值的分布和他们在帕累托前沿中的位置。由此可见,NSGA-SA算法在解集前端(前25个




Fig. 4 NSGA-SA Pareto front

图4 NSGA-SA帕累托前沿

解)和后端(后25个解)区域分布较均匀,表明算法在收敛性和解集多样性上能力较强。在前段解集中, f_1 从0.000 1上升至0.180 0, f_2 从0.990 0下降到0.580 0,证明了算法在前端区域能有效覆盖目标空间,并保持解集广泛分布。

同时,解集在前端的均匀性反映了NSGA-SA的强大全局搜索能力,可避免解集过早聚集在某个区域,从而保证算法具有较好的收敛性和解集多样性;在后段解集中, f_1 从0.700 0上升至0.990 0, f_2 从0.170 0降到0.003 5,尽管 f_2 的值变化较集中,但算法仍能保持解集多样性,避免了其过度集中在某个区域,证明了NSGA-SA能有效探索目标空间的其他部分,确保解集在整个目标空间内的覆盖程度,在处理多个冲突目标时优势明显。

总体来看,NSGA-SA在解集前端和后端均展现了较好的分布特征,既保证了算法的收敛性,又保持了解集多样性,在复杂多目标优化问题中的性能优势明显。

Table 5 Solution set sampling (first 25 solutions and last 25 solutions)

表5 解集采样(前25个解和后25个解)

序号	Objective1(f_1)	Objective2(f_2)	Position (位置)
1	0.000 118 067	0.996 543 024	Front (前段)
2	0.002 193 445	0.976 482 32	Front (前段)
3	0.002 492 509	0.956 640 072	Front (前段)
4	0.004 975 494	0.936 897 207	Front (前段)
5	0.008 254 509	0.915 733 109	Front (前段)
6	0.012 723 382	0.894 075 031	Front (前段)
7	0.016 605 169	0.879 602 859	Front (前段)
8	0.022 238 172	0.856 180 692	Front (前段)
9	0.026 479 051	0.845 288 822	Front (前段)
10	0.034 489 7	0.820 252 461	Front (前段)
11	0.045 619 053	0.793 788 339	Front (前段)
12	0.046 492 054	0.793 168 146	Front (前段)
13	0.053 250 462	0.778 824 622	Front (前段)
14	0.062 257 696	0.756 439 137	Front (前段)
15	0.076 958 504	0.728 295 714	Front (前段)
16	0.087 477 278	0.710 953 845	Front (前段)
17	0.095 697 918	0.697 759 15	Front (前段)
18	0.107 410 392	0.689 321 303	Front (前段)
19	0.111 750 663	0.674 090 207	Front (前段)
20	0.118 978 185	0.661 202 339	Front (前段)
21	0.121 989 629	0.656 498 88	Front (前段)
22	0.121 989 629	0.656 498 88	Front (前段)

续表			
序号	Objective1(f_1)	Objective2(f_2)	Position (位置)
23	0.140 938 667	0.629 866 493	Front (前段)
24	0.157 881 676	0.617 127 611	Front (前段)
25	0.182 088 702	0.578 879 375	Front (前段)
26			
27	0.703 671 37	0.165 318 052	End (后段)
28	0.727 980 227	0.150 926 428	End (后段)
29	0.728 311 217	0.150 212 648	End (后段)
30	0.742 461 559	0.142 985 206	End (后段)
31	0.753 757 813	0.135 946 157	End (后段)
32	0.769 131 857	0.127 989 042	End (后段)
33	0.769 902 192	0.126 637 675	End (后段)
34	0.783 251 722	0.118 668 054	End (后段)
35	0.793 089 252	0.113 005 067	End (后段)
36	0.817 921 931	0.101 462 943	End (后段)
37	0.827 406 761	0.094 636 916	End (后段)
38	0.832 659 258	0.091 577 611	End (后段)
39	0.851 338 688	0.084 006 676	End (后段)
40	0.852 109 023	0.081 192 377	End (后段)
41	0.873 720 167	0.069 093 108	End (后段)
42	0.884 796 556	0.063 937 543	End (后段)
43	0.895 883 983	0.059 696 953	End (后段)
44	0.909 501 409	0.049 285 641	End (后段)
45	0.925 367 314	0.041 583 51	End (后段)
46	0.938 277 899	0.034 874 64	End (后段)
47	0.955 781 868	0.025 936 044	End (后段)
48	0.977 983 438	0.014 822 407	End (后段)
49	0.988 336 57	0.010 206 488	End (后段)
50	0.999 936 492	0.003 545 321	End (后段)

3.4.2 多目标优化算法帕累托前沿性能比较分析

本文基于标准测试函数 ZDT1,对 NSGA-SA、NSGA-II 与 MOEA/D 等 3 种多目标优化算法的帕累托前沿表现进行系统比较,评估其在收敛性和解集多样性方面的性能差

异,如图 5 所示。由此可知,NSGA-SA 在解集均匀性和覆盖范围上具有明显优势,能更均匀、广泛地分布于目标空间,全局搜索能力更好。




Fig. 5 Pareto front of three algorithms
图 5 3 种算法的帕累托前沿

进一步,通过图 6 对帕累托前沿末端区域进行局部放大分析,以体现 NSGA-SA 在目标函数极值附近表现出的优异性能,包括更优的局部探索 and 更精准的收敛。结合表 10 的末端采样点数据可清晰地观察到: NSGA-SA 在 f_1 、 f_2 上的数值均优于 NSGA-II、MOEA/D,尤其在 f_2 的极小值处更明显,显示了该算法的优化精度、稳定性较强。同时,表 6 中后 20 个采样点的数据进一步验证了上述结论,NSGA-SA 在 f_2 的最小值达到 0.003 545,显著优于 NSGA-II 的 0.004 221、MOEA/D 的 0.023 983,且 f_1 的值接近理想最优点 1,表明了 NSGA-SA 在保证多样性的同时,具有优秀的极值解发现能力,能有效提升多目标优化问题的解决效率和质量。

由表 6 可见,NSGA-SA 在解集的后 20 个采样点中优势较强,特别是在 f_2 的最小值上达到了 0.003 545,显著优于 NSGA-II 的 0.004 221、MOEA/D 的 0.023 983,表明 NSGA-SA 在寻找 f_2 的极值解方面能力更强,能更好地逼近真




Fig. 6 Pareto front end data analysis
图 6 帕累托前沿末端数据分析

实 Pareto 前沿,该算法的收敛性更优、解集质量更高。同时,NSGA-SA 在 f_1 的值接近理想最优点 1,证明了该算法在平衡收敛性与多样性方面的能力更优。

通过上述数据可知,NSGA-SA 的优势源于融合了模拟退火机制与遗传算法的优点。模拟退火的全局搜索能力能使算法有效跳出局部最优,更好地探索解空间,特别

是在极值解的发现上表现优异,相较于 NSGA-II、MOEA/D 在解集分布上的均匀性更好,能保证解集在目标空间内广泛覆盖。综上,NSGA-SA 不仅在收敛性与极值解发现能力上优于 NSGA-II、MOEA/D,还能保持解集的多样性和均匀分布,在处理复杂、多冲突等多目标问题时能提供更高效、高质量的解,具有较高的实用价值和推广潜力。

Table 6 Pareto front solution set sampling points (last 20) for NSGA-SA, NSGA-II, and MOEA/D

表 6 NSGA-SA、NSGA-II、MOEA/D 的帕累托前沿解集采样点(后 20 个)

算法	NSGA-SA_f1	NSGA-SA_f2	NSGA-II_f1	NSGA-II_f2	MOEA/D_f1	MOEA/D_f2
1	0.753 757 81	0.135 946 16	0.780 133 23	0.123 700 13	0.731 816 49	0.171 668 82
2	0.769 131 86	0.127 989 04	0.798 995 94	0.112 263 26	0.739 150 16	0.161 631 07
3	0.769 902 19	0.126 637 68	0.824 986 24	0.107 219 69	0.753 165 45	0.154 953 04
4	0.783 251 72	0.118 668 05	0.830 502 58	0.095 449 15	0.768 596 21	0.143 788 81
5	0.793 089 25	0.113 005 07	0.855 220 08	0.084 337 51	0.786 391 71	0.133 428 43
6	0.817 921 93	0.101 462 94	0.864 606 84	0.076 169 36	0.798 347 47	0.129 907 21
7	0.827 406 76	0.094 636 92	0.873 264 48	0.070 645 77	0.813 153 24	0.122 041 21
8	0.832 659 26	0.091 577 61	0.889 385 88	0.061 605 14	0.829 918 20	0.111 750 31
9	0.851 338 69	0.084 006 68	0.894 074 54	0.059 828 05	0.842 711 24	0.104 175 09
10	0.852 109 02	0.081 192 38	0.908 270 40	0.053 073 66	0.862 222 07	0.095 296 11
11	0.873 720 17	0.069 093 11	0.919 213 02	0.044 821 64	0.872 944 75	0.086 043 17
12	0.884 796 56	0.063 937 54	0.923 337 10	0.044 293 23	0.894 067 16	0.072 528 51
13	0.895 883 98	0.059 696 95	0.937 500 24	0.041 442 20	0.907 258 09	0.067 846 12
14	0.909 501 41	0.049 285 64	0.947 452 69	0.039 315 92	0.926 143 05	0.058 194 33
15	0.925 367 31	0.041 583 51	0.953 449 58	0.029 374 29	0.946 318 55	0.049 538 61
16	0.938 277 90	0.034 874 64	0.967 408 09	0.021 229 17	0.972 869 84	0.039 727 94
17	0.955 781 87	0.025 936 04	0.975 284 52	0.017 768 64	0.980 498 77	0.027 959 84
18	0.977 983 44	0.014 822 41	0.986 479 14	0.011 340 80	0.994 422 84	0.025 597 88
19	0.988 336 57	0.010 206 49	0.999 559 33	0.004 221 46	0.994 422 84	0.023 983 42
20	0.999 936 49	0.003 545 32	0.999 559 33	0.004 221 46	0.994 422 84	0.023 983 42

3.5 性能指标

3.5.1 超体积

超体积衡量解集的覆盖范围,越大的超体积表示解集覆盖了目标空间更多区域,体现了解集的全面性和优越性。 HV 越大解集对目标空间的覆盖程度越高,也就意味着算法具有更好的收敛性和广度。由于在高维目标问题中超体积的计算复杂度较高,因此需要设置参考点,通过近似算法来加速计算。

$$HV = \int_S \min(f_1, f_2) df \quad (25)$$

式中: S 为解集所在区域; f_1, f_2 为目标函数。

3.5.2 世代距离

世代距离度了解集与真实前沿之间的距离,值越小表示解集越接近真实的 Pareto 前沿,可有效反映算法的收敛精度。然而,世代距离并不关注解集的多样性,因此在评估时需要配合其他指标(如解集熵)一同考虑。为了优化该指标,常见做法是调整选择策略、交叉策略和变异率,避免算法陷入局部最优解。

$$GD = \frac{1}{N} \sum_{i=1}^N \min |f_i - f_j^*| \quad (26)$$

式中: f_i 为解集中的解; f_j^* 为真实前沿中的解。

3.5.3 解集熵

解集熵衡了解集的多样性,熵值越高表示解集在目标空间的分布越均匀,意味着解集多样性较好,有助于避免算法陷入局部最优解,从而提升解集的全局性。然而,过高的解集熵可能会影响收敛速度,因此需要与其他指标共同评估。同时,采取更灵活的交叉与变异策略增加解集多样性。

$$SE = -\sum_{i=1}^N p_i \log(p_i) \quad (27)$$

式中: p_i 为解集中每个点的概率。

3.6 不同算法的性能比较

3.6.1 收敛性

为了直观展示 3 种算法在收敛性上的表现,绘制了 NSGA-SA、NSGA-II 和 MOEA/D 等 3 种算法的超体积收敛曲线,如图 7 所示。由此可见,NSGA-SA 在早期迭代中超体积迅速增长,能更快找到优质解,并在后期保持稳定的收敛趋势,达到更高的超体积值,证明了 NSGA-SA 在多目标优化中具有更强的收敛能力和解集覆盖能力,相较于其他两种算法能更高效地解决优化问题。

3.6.2 世代距离

为了更直观地展示这些算法在该指标上的优劣,通过




Fig. 7 Supervolume convergence curves of NSGA-SA, NSGA-II and MOEA/D

图7 NSGA-SA、NSGA-II、MOEA/D的超体积收敛曲线

Python 给出了 3 种算法的比较图(见图 8)。由此可见,NSGA-SA 算法在世代距离指标上的表现明显优于 NSGA-II、MOEA/D,NSGA-SA 的解集距离真实前沿的距离较小,表明其在多目标优化过程中可有效逼近理想解,验证了 NSGA-SA 在解集质量和收敛性方面的优势明显。




Fig. 8 Polar coordinate circular bar chart of generation distance for NSGA-SA, NSGA-II and MOEA/D

图8 NSGA-SA、NSGA-II、MOEA/D的世代距离极坐标环状图

3.6.3 解集熵

解集熵是衡量解集在目标空间分布均匀性的指标,较大的解集熵值表明解集分布均匀,在多目标优化中具有更强的多样性,如图 9 所示。由此可见,NSGA-SA 算法的解集熵值最大,解集在目标空间中的分布最均匀,有助于避免在多目标优化中产生解集聚集现象,而 NSGA-II 与 MOEA/D 的解集熵值较低,算法在解集多样性方面较差,尤其在优化过程中容易陷入局部最优解。

3.6.4 时间复杂度

为了全面评估算法计算效能,构建了多维度时间分析仪表盘,从绝对时长、分布占比与相对速度 3 个方面比较 NSGA-SA、NSGA-II 及 MOEA/D 在 ZDT1 问题上的时间复杂度,如图 10 所示。由此可见,NSGA-SA 的优化耗时(4.16 s)相较于 NSGA-II(3.95 s)提升 5.3%,主要是模拟退火机制引入的邻域深度探索开销;NSGA-SA 的优化耗时




Fig. 9 Distribution of solution set entropy for NSGA-SA, NSGA-II, and MOEA/D




Fig. 10 Comparison of calculation time for NSGA-SA, NSGA-II and MOEA/D

图10 NSGA-SA、NSGA-II、MOEA/D 的计算时间比较

(4.16 s)相较于 MOEA/D(5.55 s)提升 25.0%。

综上,NSGA-SA 在适度增加计算负担的同时,通过增强解的多样性和收敛精度,为工业优化提供了更优的解决方案集,即计算成本增量投入可产生显著的实际回报。

3.6.5 综合分析

表 7 为 3 种算法的性能指标。由此可知,NSGA-SA 的计算时间(4.16 s)相较于 NSGA-II 增加 5.3%,即通过抑制早熟收敛并维持种群多样性,在相同迭代规模下搜索覆盖范围更广、收敛速率更快。

NSGA-SA 在超体积、世代距离、解集熵等 3 项核心指标上优势明显。在超体积方面,NSGA-SA 相较于 NSGA-II

Table 7 Performance indicators of NSGA-SA, NSGA-II and MOEA/D

表 7 NSGA-SA、NSGA-II、MOEA/D 的性能指标					
序号	算法	超体积	世代距离	解集熵	计算时间 (时间复杂度)
1	NSGA-SA	0.865 3	0.006 1	3.412 6	4.160 8
2	NSGA-II	0.864 6	0.006 8	3.366 2	3.950 1
3	MOEA/D	0.836 9	0.022 7	3.311 1	5.548 3

的 0.864 6 和 MOEA/D 的 0.836 9 更优秀,表明 NSGA-SA 得到的帕累托前沿覆盖域更广;在世代距离方面,NSGA-SA 仅为 0.006 1,相较于 NSGA-II 缩小了约 10%,相较于 MOEA/D 下降了一个数量级,表明 NSGA-SA 在逼近理论前沿的速度和精度上优势明显;NSGA-SA 的解集熵达到 3.412 6,解集分布更均匀、信息量更大,显著优于另外两种算法。

综上,上述指标共同验证了退火概率接受机制能补强 NSGA-II,既抑制了早熟收敛,又维持了种群多样性。在相同的迭代规模下,NSGA-SA 能获得更大的搜索覆盖范围和更快的收敛速率。同时,本文实验基于 ZDT1 基准函数,表示该混合框架在面对高维、冲突目标的实际工程问题时,具备更稳健的全局搜索潜力。后续,可在约束处理与并行加速方向进行优化。

3.7 热处理工艺优化应用与分析

本文以 45 号钢淬火工艺为典型应用案例,基于构建的热处理工艺场景模型和目标函数(见式(1)一(3)、式(21)),验证并展示 NSGA-SA 算法在实际工程优化中的应用效果及其研究价值。45 号钢因优异的综合机械性能在机械制造领域被广泛应用,特别适合淬火等热处理工艺。

表 8 为 45 号钢淬火工艺的关键参数及物理属性,包括淬火温度、保温时间、冷却时间、比热容、单件质量、炉效率及环境温度等。通过合理设计淬火温度、保温时间和冷却时间等关键参数,实现材料硬度最大化与能耗最小化的双目标平衡,为多目标优化奠定坚实基础。

Table 8 Key parameters and physical properties of quenching process for 45 # steel

表 8 45 号钢淬火工艺关键参数与物理属性			
参数编号	参数名称	取值范围	单位
1	淬火温度	820~880	°C
2	保温时间	10~60	min
3	冷却时间	30~120	s
4	比热容	0.46	kJ/(kg·°C)
5	单件质量	12	kg
6	炉效率	0.72	
7	环境温度	25	°C

图 11 为淬火工艺温度—时间优化曲线。由此可见,该曲线清晰描绘了加热、保温、冷却 3 等个关键阶段的时间区间与温度区间的变化情况,体现了工艺参数的动态演化过程,充分反映了实际生产工艺的物理规律和控制重点。

45号钢淬火工艺参数优化曲线




Fig. 11 Optimization curve of quenching process parameters for 45 # steel

图 11 45 号钢淬火工艺参数优化曲线


图 12 为 3 种算法在硬度偏差与能耗上的优化效果(彩图扫 OSID 可见,下同)。将关键工艺参数(见表 8)应用于热处理工艺场景模型后,图 12(a)热力图展示了 NSGA-SA 算法在硬度偏差与能耗之间的关系,颜色深浅反映了不同硬度偏差和能耗区间下的解集表现。

图中较深区域为“优势区”,NSGA-SA 算法的优势明显,能在较小的硬度偏差与较低的能耗之间寻找最佳平衡,优化工艺参数配置。图中低能耗区域(硬度偏差小、能耗低)显示了 NSGA-SA 的优化能力,通过优化参数组合可减少能耗,保持较小的硬度偏差。在热处理工艺的双目标优化中,能在实际工艺限制下最大化材料硬度、最小化能耗,体现了算法在处理多目标冲突问题中的优势。


此外,热力图的颜色变化清晰地展示了硬度偏差与能耗之间的变化趋势,为实际生产中选择最优的淬火工艺参数提供了科学依据,尤其对如何优化能耗并保证硬度提供了明确的指导。

图 12(b)展示了 NSGA-SA、NSGA-II 和 MOEA/D 等 3 种算法的三维帕累托结果。由此可见,NSGA-SA 的解集分布更均匀且接近理论最优前沿,展现了该算法在平衡硬度与能耗优化方面的出色能力,能更好地同时优化两个目标,使最终解集在目标空间内的分布更均匀,全局搜索能力与收敛性更强。

NSGA-SA 算法通过结合模拟退火机制,尽管增加了少许计算负担,但显著提升了多目标优化中的收敛性和解



(a) NSGA-SA's low energy region advantageous thermal map
(a) NSGA-SA的低能耗区域优势热力图



(b) Three-dimensional pareto
(b) 三维帕累托

Fig. 12 Optimization effects of three algorithms on hardness deviation and energy consumption

图 12 3 种算法在硬度偏差与能耗上的优化效果

集多样性,尤其在硬度偏差最小化与能耗最优化方面表现突出。在 45 号钢淬火工艺的优化应用中,NSGA-SA 不仅能精准优化工艺参数,还能为实际生产中降低能耗、提升产品硬度提供科学依据。图 12(a)清晰展示了 NSGA-SA 在硬度与能耗之间的优化效果,表明该算法能为智能制造提供有效的技术支持。

未来,NSGA-SA 有望进一步结合实时数据,实现更深层次的动态工艺调控,推动智能工厂进一步发展。

4 结语

本文针对热处理工艺优化中的多目标决策问题,提出

一种 NSGA-SA 算法。首先,结合模拟退火的 Metropolis 接受准则与 NSGA-II 的进化框架,形成了一种新的混合优化方法;其次,通过自适应温度衰减机制平衡解集的多样性与收敛性,有效避免了传统 NSGA-II 算法中的早熟收敛问题。

实验表明,NSGA-SA 在标准测试问题与热处理工艺优化场景中优势明显,在硬度、能耗之间实现了有效的平衡。此外,NSGA-SA 通过黑盒接口设计能灵活对接物理模型或数据驱动代理,并与实际的制造执行系统或数字孪生模型衔接,为工业应用提供可迁移的优化方案。

尽管,现有研究主要集中于二维目标空间的优化问题,但 NSGA-SA 在高维目标空间中的适应性同样值得关注。在实际工业应用中,目标数通常超过两个且涉及多个约束条件,NSGA-SA 的退火接受机制依然适用于高维冲突强化场景。具体为,通过调控温度衰减速度和变异操作频率保持算法全局探索与局部开发之间的平衡,避免了多目标优化中常见的局部最优问题。此外,NSGA-SA 能在目标维度较高时保持较好的解集多样性,可适用于工业应用中目标冲突较严重的场景,因此具有较强的扩展性和实际应用潜力。

未来,将集中优化算法在高维和大规模场景中的性能,探索参考向量、 R^2 指标等方法来减轻算法计算负担,并利用并行计算来提升算法实时性。同时,将进一步发展自适应温度调度策略减少算法对人工超参数的依赖,增强算法的适应性。在复杂约束的处理上,将结合可行性优先策略与退火概率机制,提升算法在实际生产中的可行性与精度。随着算法与实时生产数据的深度集成,NSGA-SA 有望在智能制造、能源管理等领域成为核心优化工具,推动工业生产的进一步智能化与精益化。

参考文献:

- [1] YANG D, ZHOU X, YANG Z, et al. Multi-objective optimization model for flexible job shop scheduling problem considering transportation constraints: a comparative study [C]// Glasgow: Proceedings of 2020 IEEE Congress on Evolutionary Computation, 2020.
- [2] KAUR A, NARANG N. Multi-objective generation scheduling of integrated energy system using hybrid optimization technique [J]. Neural Computing and Applications, 2024, 36: 1215-1236.
- [3] PETROVIĆ M, JOKIĆ A, MILJKOVIĆ Z, et al. Multi-objective scheduling of a single mobile robot based on the grey wolf optimization algorithm [J]. Applied Soft Computing, 2022, 131: 109784.
- [4] JIA C C, MA C, ZHANG Y B, et al. Research on path optimization for intelligent trackless auxiliary scheduling in underground coal mine based on improved NSGA-II [J]. Journal of China University of Mining & Technology, 2025, 34(5): 137-143.
贾纯纯, 马超, 张亚邦, 等. 基于改进 NSGA-II 的煤矿井下智能无轨辅助调度路径优化方法研究 [J]. 中国矿业, 2025, 34(5): 137-143.
- [5] LI J, LI H, HE P B, et al. Flexible job shop scheduling optimization for green manufacturing based on improved multi-objective wolf pack algo-

- rithm[J]. *Applied Sciences*, 2023, 13(14): 8535.
- [6] JIANG F G, LIANG S, LI Y, et al. Structural reliability optimization design based on improved monkey algorithm[J]. *Journal of Heilongjiang University of Science and Technology*, 2024, 34(6): 942–948.
姜封国, 梁爽, 李勇, 等. 改进猴群算法的结构可靠性优化设计[J]. *黑龙江科技大学学报*, 2024, 34(6): 942–948.
- [7] CHI P, LIU C, ZHAO J, et al. Dynamic effect Web generation for heterogeneous UAV cluster using DQN-Based NSGA-II: methods and applications [J]. *Chinese Journal of Aeronautics*, 2025, 38 (7) : 103351–103351.
- [8] ZHAO L, FAN L, LU J, et al. Multi-objective optimization of gas storage compressor units based on NSGA-II[J]. *Energies*, 2025, 18(13): 3377.
- [9] WANG J, WANG G, WEI M, et al. Optimization design and performance analysis of a rotary vane magnetorheological damper for vehicle suspension based on NSGA-II[J]. *Mechanics Based Design of Structures and Machines*, 2025, 53(6): 4761–4785.
- [10] GU J, CHEN Y, DU Y F, et al. Drag reduction analysis of wheel deflector based on adaptive simulated annealing optimization algorithm[J]. *Automotive Technology*, 2025(6): 54–62.
古静, 陈亿, 杜亚非, 等. 基于自适应模拟退火优化算法的车轮阻风板降阻分析[J]. *汽车技术*, 2025(6): 54–62.
- [11] LI X, JIN D, YU Q, et al. Simulated annealing algorithm-assisted SCAPS-1D design enables 27.04% efficiency in dual-absorber perovskite solar cells[J]. *Journal of Physics and Chemistry of Solids*, 2025, 207: 112953.
- [12] GAO C, WANG Z W, FENG Y H, et al. Research on transformer fault diagnosis model based on simulated annealing and multilayer perceptron and its generalization performance[J]. *High Voltage Apparatus*, 2024, 60(11): 77–85.
高超, 王志武, 冯玉辉, 等. 基于模拟退火法与多层感知机的变压器故障诊断模型及其泛化性能研究[J]. *高压电器*, 2024, 60(11): 77–85.
- [13] DENG W, ZHANG X X, ZHOU Y Q, et al. An enhanced fast non-dominated solution sorting genetic algorithm for multi-objective problems[J]. *Information Sciences*, 2022, 585: 441–453.
- [14] XU Y M, LI Q, LUO X M, et al. Progress in heat treatment technology [J]. *Heat Treatment of Metals*, 2015, 40(9): 1–15.
徐跃明, 李俏, 罗新民, 等. 热处理技术进展[J]. *金属热处理*, 2015, 40(9): 1–15.
- [15] MIRJALILI S, DONG J S. Multi-objective optimization using artificial intelligence techniques[M]. Berlin: Springer, 2019: 37–45.
- [16] DELAHAYE D, CHAIMATANAN S, MONGEAU M. Handbook of meta-heuristics[M]. Berlin: Springer, 2019.
- [17] DEB K, SINDHYA K, OKABE T. Self-adaptive simulated binary crossover for real-parameter optimization [C]// London: 9th Annual Conference on Genetic and Evolutionary Computation, 2007.
- [18] BÉDARD M. Optimal acceptance rates for metropolis algorithms: moving beyond 0.234 [J]. *Stochastic Processes and their Applications*, 2008, 118(12): 2198–2222.
- [19] HE C, ZHONG P, LI M, et al. An evolutionary many-objective algorithm based on a novel tournament selection strategy[J]. *Journal of Computer and Communications*, 2021, 9(6): 238–248.
- [20] LIU Z J. Fuzzy Markov chain state value and its chance measure function [J]. *Statistics & Decision*, 2021, 37(14): 29–32.
刘兆君. 模糊马尔可夫链状态取值及其机会测度函数[J]. *统计与决策*, 2021, 37(14): 29–32.
- [21] WANG Z Y, YAN Y Q, ZENG X Y, et al. Joint multi-objective optimization based on multitask and multi-fidelity Gaussian processes for flapping foil[J]. *Ocean Engineering*, 2024, 294: 116862.
- [22] ZHANG J J, CUI Z H. Survey of high-dimensional multi-objective integrated algorithms [J]. *Journal of Nanchang Institute of Technology*, 2021, 40(4): 67–76.
张江江, 崔志华. 高维多目标集成算法研究综述[J]. *南昌工程学院学报*, 2021, 40(4): 67–76.
- [23] LIU Y, WEI J X, LI X, et al. Generational distance indicator-based evolutionary algorithm with an improved niching method for many-objective optimization problems[J]. *IEEE Access*, 2019, 7: 63881–63891.
- [24] ZHANG X Y. Improved multi-objective cross-entropy optimization algorithm and its application [D]. Chengdu: Southwest Jiaotong University, 2021.
张夏颖. 改进的多目标交叉熵优化算法及其应用[D]. 成都: 西南交通大学, 2021.

(责任编辑: 刘嘉文)