

基于 CGSOA-BPNN 优化 AlCoCrNiFe 高熵合金涂层等离子喷涂工艺参数

李赞^a, 张长胜^a, 马涛^b, 王卓^a

(昆明理工大学 a.信息工程与自动化学院 b.材料科学与工程学院, 昆明 650093)

摘要: **目的** 解决等离子喷涂工艺参数耦合导致的参数选取困难问题, 提高 AlCoCrNiFe 高熵合金涂层力学性能。**方法** 提出全局混沌高斯融合的海鸥算法 (CGSOA), 优化权值和阈值, 使 BP (Back Propagation, 反向传递) 神经网络训练输出理想控制参数。利用改进 logistic 混沌序列实现网络参数初始化种群的全局搜索, 提高权值和阈值初始质量。引入改进 logistic 映射跳出局部最优, 通过加强局部搜索能力, 以提高算法收敛精度。引入高斯变异增加种群多样性, 提高全局搜索能力。选取 6 个基准函数, 对 BAS、PSO、ACO、SOA 及 CGSOA 算法进行测试, 仿真结果表明, 所提算法具有较快收敛速度、较高寻优精度和稳定性。**结果** CGSOA 算法优化 BP 神经网络得出最佳控制量为: 喷涂距离 99.7 mm, 喷涂电流 649.6 A, 喷涂电压 56.3 V, 送粉载气 203.1 L/h, 送粉电压 5.1 V。以其进行喷涂试验, 涂层结合强度和显微硬度分别为 25.2 MPa 和 616.8HV, 与模型预测值的相对误差分别为 3.02% 和 2.91%, 验证了 CGSOA-BPNN 应用到实际喷涂过程的可行性。**结论** CGSOA-BPNN 对 AlCoCrNiFe 高熵合金涂层等离子喷涂工艺参数进行优化, 进而提高涂层力学性能, 具有一定的现实指导意义。

关键词: 等离子喷涂; 高熵合金涂层; 工艺参数优化; BP 神经网络; 海鸥优化算法; 改进 logistic 混沌; 高斯变异

中图分类号: TG174.442; TP391.9 文献标识码: A 文章编号: 1001-3660(2022)01-0311-14

DOI: 10.16490/j.cnki.issn.1001-3660.2022.01.034

Optimization of Plasma Spraying Process Parameters of AlCoCrNiFe High Entropy Alloy Coating Based on CGSOA-BPNN

LI Zan^a, ZHANG Chang-sheng^a, MA Tao^b, WANG Zhuo^a

(a. Faculty of Information Engineering and Automation, b. Faculty of Materials Science and Engineering,
Kunming University of Science and Technology, Kunming 650093, China)

收稿日期: 2021-04-22; 修订日期: 2021-10-12

Received: 2021-04-22; Revised: 2021-10-12

基金项目: 国家自然科学基金 (61963022, 51665025)

Fund: Supported by National Natural Science Foundation of China (61963022, 51665025)

作者简介: 李赞 (1996—), 男, 硕士研究生, 主要研究方向为智能优化算法、工业建模及参数优化。

Biography: LI Zan (1996—), Male, Master, Research focus: intelligent optimization algorithm, industrial modeling and parameter optimization.

通讯作者: 张长胜 (1970—), 男, 博士, 副教授, 主要研究方向为智能优化算法、复杂工业建模及图像处理。

Corresponding author: ZHANG Chang-sheng (1970—), Male, Doctor, Associate professor, Research focus: intelligent optimization algorithms, complex industrial modeling and image processing.

引文格式: 李赞, 张长胜, 马涛, 等. 基于 CGSOA-BPNN 优化 AlCoCrNiFe 高熵合金涂层等离子喷涂工艺参数[J]. 表面技术, 2022, 51(1): 311-324.

LI Zan, ZHANG Chang-sheng, MA Tao, et al. Optimization of Plasma Spraying Process Parameters of AlCoCrNiFe High Entropy Alloy Coating Based on CGSOA-BPNN[J]. Surface technology, 2022, 51(1): 311-324.

ABSTRACT: The aim is to solve the problem of difficult parameter selection caused by the coupling of plasma spraying process parameters to improve the mechanical properties of the AlCoCrNiFe high entropy alloy coating. An algorithm which seagull optimization algorithm based on global chaotic and Gaussian fusion (CGSOA) is proposed to optimize the weights and thresholds so that BP (Back Propagation) neural network training outputs ideal control parameters. The improved logistic chaotic sequence is used to realize the global search of the initial population of network parameters, and the initial quality of weights and thresholds is improved; the improved logistic mapping is introduced to jump out of the local optimum, and the local search capability is strengthened to improve the accuracy of the algorithm convergence; the introduction of Gaussian mutation increases the diversity of the population, improve the global search capability; select 6 benchmark functions to test the BAS, PSO, ACO, SOA and CGSOA algorithms. The simulation results show that the proposed algorithm had faster convergence speed, higher optimization accuracy and stability. CGSOA algorithm optimizes the BP neural network to obtain the best control amount: spraying distance 99.7 mm, spraying current 649.6 A, spraying voltage 56.3 V, powder feeding carrier gas 203.1 L/h, powder feeding voltage 5.1 V. The spraying test with this parameter shows that the bonding strength and microhardness of the coating were 25.2 MPa and 616.8HV, respectively, and the relative errors with the predicted value of the model were 3.02% and 2.91%, respectively. This result verifies the feasibility of applying the CGSOA algorithm to actual projects. CGSOA-BPNN has a certain guiding significance for optimizing the plasma spraying process parameters of AlCoCrNiFe high-entropy alloy coating, thereby improving the coating performance.

KEY WORDS: plasma spraying; high entropy alloy coating; process parameter optimization; BP neural network; seagull optimization algorithm; improved logistic chaos; gaussian mutation

由于基体与陶瓷层热膨胀系数相差较大,大气等离子喷涂过程中会产生较大的热应力,导致二者粘结性降低,加速涂层失效,故选用一种热膨胀系数介于二者的金属合金作为粘结层,降低陶瓷层内部的热应力,可延长涂层的服役寿命^[1]。高熵合金由于其组成元素之间的相互作用而具有高强度、高断裂韧性、高硬度、高耐磨等优异性能^[2-3]。AlCoCrNiFe 作为一种典型的高熵合金体系,目前已被制成涂层用于各研究领域,有望成为一种产业化应用的高性能涂层材料^[4]。

传统试错法在选择热喷涂工艺参数以提升涂层性能方面,具有周期长、成本高等缺点^[5]。近年来,随着 AI 技术的发展,神经网络逐渐应用到参数优化^[6-7]、质量预测^[8-9]、材料配方预测^[5]等材料喷涂工艺的研究领域。BECKER 等^[10]利用人工神经网络对碳化铬二元涂层的抗空蚀和浆体磨损性能进行建模预测,缩短了试验时间,降低了成本,但模型的预测误差较大。针对喷涂过程中呈现出的复杂性和非线性,PATURI 等^[11]对表面涂层工艺进行建模与参数优化,预测基体表面形成更好沉积涂层的条件,但输入参数较多而影响收敛速度。HUEN 等^[12]建立热喷涂涂层的纳米力学性能预测模型,提出一种材料应力应变弹性参数分析的新方法,但单一神经网络易过早收敛,导致预测精度不高。LIU 等^[13]分析 HVOF 喷涂工艺参数与涂层性能之间的关系,并且首次引入 MIV 分析评价热喷涂过程中人工神经网络模型输入变量的重要性,该模型预测的准确性和可靠性较好,但也存在因神经网络陷入局部问题,而导致预测误差波动大的缺陷。ZHU 等^[14]利用卷积神经网络(CNN),预测了大气等

离子喷涂中飞行粒子的控制参数,大大节约了计算资源和降低了时间成本,但因数据量少使 CNN 模型过拟合,导致预测效果不佳。综上所述,在对材料涂层性能的研究分析中,神经网络作为一种新的工具,代替传统数值分析、数学模型等方法对材料进行研究,加速了材料科学领域的发展,但单一神经网络建立的模型拟合度高,对非线性、多输入多输出等复杂系统,存在收敛速度慢、精度不高、预测误差波动较大等问题。

为解决以上缺陷,除充分利用神经网络优势外,还需要将群智能优化算法与神经网络结合,以提高模型的分析能力和精度。在涂层工艺参数优化过程中,以 BP 神经网络建立的模型为基础,将遗传算法^[15-17](Genetic Algorithm, GA)及粒子群算法^[18](Particle Swarm Optimization, PSO)加入到工艺参数优化模型中,相比于单一神经网络建立的模型,多工艺参数优化效果较好,优化性能明显提高,但遗传算法和粒子群算法在迭代过程中,容易出现陷入局部最优及收敛过早等问题,导致预测误差过大。为了更好地利用群智能算法,还需要在其基础上对群智能算法进行改进,以解决此弊端。为了解决群智能算法陷入局部最优,避免“早熟”现象,许多学者对标准算法进行改进。帅茂杭等^[19]对骨干粒子群的位置采用搜索权值非线性递减策略进行位置更新,并对不同搜索阶段的最差粒子进行位置更新,以平衡算法全局和局部的搜索能力,提出改进多目标骨干粒子群优化算法,降低了陷入局部最优的概率,从而增加了种群多样性。张强等^[20]将多策略进化概率变异方式引入到人工蜂群优化算法中,避免了陷入局部最优解。马小陆等^[21]在蚁群算

法中引入势场合力递减系数,避免了势场蚁群算法因势场而陷入局部最优的问题。柳长源等^[22]在萤火虫算法中提出一种驱散机制,同时对进化过程中的萤火虫种群引入变异操作,解决了优化精度不高和容易陷入局部最优的问题。崔雪婷等^[23]将改进 logistic 映射引入蝙蝠优化算法,提出全局混沌蝙蝠优化算法,丰富了种群,有效避免了算法早熟,提高了算法的全局搜索能力。汤安迪等^[24]利用 cubic 映射初始化种群,并融入正余弦算法,提出混沌多精英鲸鱼优化算法,克服了算法陷入局部最优的缺点,同时增加了种群多样性。ZHANG 等^[25]在麻雀算法中引入 logistic 映射、自适应超参数和变异算子,提出混沌麻雀搜索算法,克服了迭代后期容易陷入局部最优的缺陷。

海鸥优化算法 (Seagull Optimization Algorithm, SOA) 是 DHIMAN 等^[26]在 2018 年提出的新型生物启发式智能算法,其算法具有探索和开发能力较强、收敛速度快、精度高、鲁棒性强、适应性好及调参少等优点。然而,SOA 算法也面临着和其他群智能算法一样的不足,在搜索接近最优解时,容易“早熟”,陷入局部最优和种群多样性减少等问题。针对 SOA 算法收敛性能低、偶尔早熟收敛等问题,CAO 等^[27]和 LEI 等^[28]将 levy 随机游走机制加入算法中,缓解了算法早熟收敛问题。虽然在一定程度上改善了陷入局部最优解问题,提高了勘探和开发的能力,但是依然存在搜索精度不高、收敛精度不足和种群多样性减少等问题。

所以,针对标准海鸥优化算法的不足,提出一种全局混沌高斯融合的海鸥优化算法(Seagull Optimization Algorithm based on global Chaos and Gaussian fusion, CGSOA),利用 CGSOA 算法对 6 个基准函数进行仿真验证,结果表明,CGSOA 算法克服了陷入局部最优问题,收敛速度和精度明显提高,具有更高的寻优精度和稳定性,证明了该算法具有一定的有效性。在大气等离子喷涂实验中,影响 AlCoCrNiFe 涂层性能的因素有喷涂距离、喷涂电压、喷涂电流、送粉载气、送粉电压等,由于各影响因素间耦合导致喷涂工艺参数难选取,从而对结合强度、显微硬度等涂层性能具有一定影响。本文将 CGSOA 算法加入到以 BP 神经网络建立的模型上,进行最佳工艺参数寻优,解决参数选取困难问题,使 AlCoCrNiFe 涂层性能达到更优水平。该模型具有一定的自适应性和较好的鲁棒性。

1 海鸥优化算法仿生原理

海鸥在迁移过程中,成群结队飞行,为避免碰撞,每只海鸥的初始位置不同,海鸥朝着更适应生存的方向前进,其他海鸥根据更适应生存的海鸥路径来更新它们的初始位置。海鸥攻击海面上的猎物时,做出螺旋形状的运动,锁定并对其猎物发动攻击,猎物所在位置为最优位置,此时的适应度值最优。海鸥优化算

法主要由迁徙和攻击行为组成,利用海鸥的迁徙行为进行全局搜索,利用攻击行为进行局部搜索,如图 1 所示。海鸥优化算法的主要步骤包含迁移和攻击。




图 1 海鸥迁移和攻击行为
Fig.1 Migration and attacking behaviors of seagulls

1.1 迁移

海鸥迁移是一个含勘测的多元化全局搜索过程,需满足以下条件。

条件 1: 为避免碰撞,需加入变量因子 A 计算海鸥的新位置 $N(t)$, 如式(1)、式(2)所示。

$$A = c \times (1 - t / \max\text{Gen}), t = 1, 2, 3, \dots, \max\text{Gen} \quad (1)$$

$$N(t) = A \times P(t) \quad (2)$$

式(1)中: $c=2$; 控制变量 A 的频率从 2 线性递减到 0; t 为当前迭代次数, $\max\text{Gen}$ 为最大迭代次数。式(2)中: P 为海鸥的初始化位置, $P(t)$ 为第 t 代海鸥所在位置。

条件 2: 在条件 1 的基础上, 海鸥朝着更佳适合生存的位置 $M(t)$ 方向移动, 如式(3)、式(4)所示。

$$B = 2 \times A^2 \times \text{rand} \quad (3)$$

$$M(t) = B \times (P_best(t) - P(t)) \quad (4)$$

式(3)中: B 为平衡全局勘探和局部开发的平衡因子; rand 为 $(0, 1)$ 之间的随机数。式(4)中: P_best 为当前最佳适应度值的位置。

条件 3: 在条件 1 和条件 2 的基础上, 海鸥迁移到达新位置 $X(t)$, 如式(5)所示。

$$X(t) = |N(t) + M(t)| \quad (5)$$

1.2 攻击

海鸥在迁徙过程中, 当发现猎物时, 会不断地调整角度和速度, 以螺旋形状的运动方式攻击猎物。在攻击捕食过程中, 不断调整 x 、 y 、 z 三个平面上的运动轨迹方程, 如式(6)所示。

$$\begin{cases} r = u \times e^{\theta v} \\ x = r \times \cos(\theta) \\ y = r \times \sin(\theta) \\ z = r \times \theta \end{cases} \quad (6)$$

式中: r 为螺旋运动的半径; u 和 v 为常数, 通常为 1; e 为自然对数底数; θ 为 $[0, 2\pi]$ 之间的随机数。根据式(5)和(6)计算得到海鸥的攻击位置 $P_N(t)$, 如式(7)所示。

$$P_N(t) = X(t) \times x \times y \times z + P_best(t) \quad (7)$$

2 CGSOA 算法

改进 logistic 混沌具有均匀性和遍历性等特性, 用其初始化海鸥种群, 增加种群多样性的同时, 可提高初始解的质量, 达到全局搜索的目的。引入改进 logistic 混沌和高斯变异, 以更新位置帮助算法跳出局部最优解, 可加快收敛速度, 提高收敛精度, 平衡开发和探索能力, 同时也增加了种群多样性。

2.1 改进 logistic 混沌

混沌是一种具有非线性、遍历性、随机性等特性的运动, 对初始条件和参数极为敏感。比较常用的混沌映射方法有 sine 映射、tent 映射和 logistic 映射, 本文采用的是 logistic 映射。logistic 映射^[29]产生混沌序列的数学表达式如式(8)所示, 当 $\alpha=4$ 时, 标准 logistic 映射产生的混沌量分布不均匀, 而且在搜索空间变大之后, logistic 混沌优化的时间复杂度会变大, 寻优效率会降低^[30]。为了解决这个问题, 本文提出一种新的 logistic 映射, 改进后的 logistic 映射的数学表达式如式(9)所示。

$$x(t+1) = \alpha \times x(t) \times (1 - x(t)) \quad (8)$$

$$p(t+1) = \begin{cases} \alpha \times p(t) \times (1 - p(t)) \times \text{rand}, & 0 < p(t) \leq 0.5 \\ 1 - p(t)^2 \times \text{rand}, & 0.5 < p(t) \leq 1 \end{cases} \quad (9)$$

式(8)中: $x \in [0, 1]$, $\alpha \in [0, 4]$ 。当 $\alpha=4$ 时, logistic 映射处于完全混沌状态。式(9)中: rand 为 0 到 1 之间的随机数。

当 $\alpha=4$ 时, 迭代 2000 次, 标准 logistic 和改进 logistic 的混沌序列分布图及直方图如图 2 所示。由图 2a 和图 2c 可以看出, 标准 logistic 混沌绝大部分映射在 $[0.9, 1]$ 之间, 超出映射到其他范围段内数量的 3 倍左右, 显得较不均匀; 相反, 由图 2b 和图 2d 可看出, 改进后的 logistic 混沌映射到每个范围段的数量相对均匀。由此可知, 改进后的 logistic 混沌的遍历性及均匀性明显优于常规 logistic, 这不仅保证了该混沌的结构属性, 还保留了混沌特性的遍历性。本文将改进 logistic 映射产生的混沌序列作为海鸥种群的初始解, 保证了初始解的均匀性和遍历性, 提高了种群初始解的质量, 加强了全局搜索的能力。

通过式(10)将式(9)产生的混沌序列映射到 $[lb, ub]$, 作为海鸥优化算法的初始解 $y(t)$ 。

$$y(t) = lb + (ub - lb) \times p(t+1) \quad (10)$$

为了避免“早熟”现象, 提高局部搜索能力和收敛精度, 在当前最优位置引入改进 logistic 混沌映射,




图 2 标准 logistic 和改进 logistic 的混沌序列分布图及直方图

Fig.2 Standard logistic and improved logistic chaotic sequence distribution diagram and histogram: a) distribution of logistic chaotic sequence; b) distribution of improved logistic chaotic sequence; c) distribution histogram of logistic chaotic sequence; d) distribution histogram of improved logistic chaotic sequence

按式(11)对当前最优个体进行混沌产生新解 $P'(t)$ 。

$$P'(t) = P_best + (X(t) - P_best) \times p(t+1) \quad (11)$$

引入混沌理论完成两个目标: 1) 利用改进 logistic 混沌映射生成混沌序列作为初始解, 提高算法初始解质量, 在搜索阶段保持了较好的协调性, 进而提高了搜索效率和搜索质量; 2) 将改进 logistic 混沌映射引入到局部最优位置附近, 有助于算法跳出局部最优, 提高局部搜索能力。

2.2 高斯变异

为了解决算法在后期迭代过程中种群多样性减少的问题, 加入高斯变异操作^[31], 如式(12)。

$$P_t^{n^d} = P_{bad}^d + (P_t^d - P_{bad}^d) \times g \quad (12)$$

式中: g 为一个高斯分布的随机变量, 其均值为 0, 方差为 1; P_t^d 为当前种群在第 d 维的位置信息; P_{bad}^d 为当前代中适应度值最差的个体在第 d 维的位置信息; $P_t^{n^d}$ 为高斯变异后种群在第 d 维的位置信息, 其中, $d \in D$ 。

选取当前最差位置进行变异操作, 不仅能降低计算维度和复杂度, 还能增加种群多样性, 此外, 这也增强了算法的全局搜索能力。

2.3 CGSOA 算法

全局混沌高斯融合的海鸥优化算法具体实现伪代码如下:

1) 设置种群数量 popsize、规模 (维度) D 、最大迭代次数 maxGen、初始值的上下界 (ub 和 lb)、 $c=2$ 、 $u=1$ 、 $v=1$ 等参数;

2) 利用改进 logistic 混沌初始化海鸥种群, 并映射到解空间的取值范围内;

%以目标函数为适应度值, 计算初始种群中每只海鸥的适应度值 %;

3) for $i = 1$: popsize

{计算每只海鸥的适应度值; }

输出当前海鸥最优适应度值 (f_best) 及对应的位置 (x_{best}), 和当前海鸥最差适应度值 (f_bad) 及对应位置 (x_{bad});

4) while($t < \maxGen$)

{rand $\in (0, 1)$; $\theta \in [0, 2\pi]$;

利用式(1)—(7)计算海鸥位置;

计算海鸥位置的适应度值 $f(i)$;

在当前最优位置利用式(11)计算新位置 (混沌);

在当前最差位置利用式(12)计算新位置 (高斯);

计算引入混沌或者高斯的海鸥新位置的适应度值 $f(p_new)$ 和对应位置 p_new ;

%更新最优适应度值及位置 %

if ($f(p_new) < f(x_{best})$)

$x_{best} = p_new$;

$f_best = f(p_new)$;

end

$t = t + 1$;

}

5) 判断是否达到最大迭代次数, 若是, 则输出全局最优适应度值及对应位置; 否则, 返回到 4)。

3 算法测试与仿真结果分析

为了验证 CGSOA 算法的有效性和寻优能力, 将该算法与天牛须算法^[32] (Beetle Antennae Search, BAS)、PSO 算法^[33]、蚁群算法^[34] (Ant Colony Optimization, ACO) 和常规 SOA 算法进行实验分析。利用 6 个不同类型的基准函数进行仿真测试, 函数如表 1 所示。

其中, f_1 、 f_2 为高维单峰基准函数, f_3 、 f_4 为高维多峰基准函数, f_5 、 f_6 为固定维多峰基准函数。利用不同类型的基准函数测试, 可验证本文算法的局部搜索能力、种群多样性, 尤其是多峰函数中, 存在多个

表 1 6 个测试函数
Tab.1 6 test functions

Function expression	Range	Dimension	The best	Optimal value
$f_1(x) = \sum_{i=1}^D x_i^2$	$[-100, 100]$	30	0^D	0
$f_2(x) = \sum_{i=1}^D (x_i + 0.5)^2$	$[-100, 100]$	30	0^D	0
$f_3(x) = 1 + \sum_{i=1}^D \frac{x_i^2}{4000} + \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right)$	$[-600, 600]$	30	0^D	0
$f_4(x) = \sum_{i=1}^D (x_i^2 - 10 \cos(2\pi x_i) + 10)$	$[-5.12, 5.12]$	30	0^D	0
$f_5(x) = 3(x_1 - 1)^2 \exp(-(x_1 + 1)^2 - x_2^2) - 10\left(\frac{1}{5}x_1 - x_1^3 - x_2^5\right) \exp(-x_1^2 - x_2^2) - \frac{1}{3} \exp(-(x_1 + 1)^2 - x_2^2)$	$[-4, 4]$	2	(0.0287, -1.5875)	-8.0393
$f_6(x) = 4x_1^2 - 2.1x_1^4 + \frac{x_1^6}{3} + x_1x_2 - 4x_2^2 + 4x_2^4$	$[-5, 5]$	2	(-0.089 83, 0.7126) (0.089 83, -0.7126)	-1.0316

局部最优,可验证本文算法跳出局部最优的能力和全局搜索的能力。 D 为维度, 0^D 表示为 $(0^1, 0^2, 0^3, \dots, 0^D)$ 。

3.1 参数设置

本文中所比较算法的参数设置如表 2 所示。其中,在 BAS 算法中, e 表示步长衰减因子, d 表示天牛须两须之间的距离或感知长度,step 表示搜索步长;PSO 算法中, c_1 和 c_2 为加速因子, w 为惯性权重;ACO 算法中, r 表示信息素挥发系数, p 表示转移概率;SOA 算法中, c 为控制系数, u 和 v 为螺旋形状的相关系数。

表 2 各算法主要参数设置
Tab.2 Main parameters setting of each algorithm

Algorithm	Parameter setting
BAS	$e=0.95, d=3, \text{step}=3$
PSO	$c_1=c_2=2, w=0.7$
ACO	$r=0.8, p=0.2$
SOA	$c=2, u=v=1$
CGSOA	$c=2, u=v=1$

3.2 仿真结果及分析

对 f_1 — f_6 (等同于下文 f_1 — f_6) 进行函数测试时,

各算法的迭代次数设置为 1000 次,种群数量为 30 个,各算法独立运行 30 次的实验结果如表 3 所示 (mean 为均值,SD 为标准差)。函数在不同算法优化下的收敛曲线如图 3—8 所示。

从表 3 中可以看出,在 6 个测试函数上,本文所提出的 CGSOA 算法的测试结果相对较优。 f_1 、 f_2 的理想值都为 0,故均值 mean 越接近 0 越好,且 SD 越接近 0,说明算法越稳定,寻优性能越好。由结果可知,CGSOA 算法的寻优结果最接近 0,SOA 算法次之,BAS 算法最差,表明 CGSOA 算法在高维单峰函数上具有很强的局部搜索能力。在 f_3 、 f_4 中,理想值均为 0,对 f_3 函数寻优时,CGSOA 算法与 PSO 算法和 ACO 算法的寻优结果相差不大,但也是最优,对 f_4 寻优时,CGSOA 算法比其他算法表现出更好的性能,其中 BAS 算法的寻优效果最差。以上结果表明,CGSOA 算法具有很好的全局搜索能力。在固定低维函数 f_5 、 f_6 中,理想值分别为 -8.0393 和 -1.0316,从表 3 中可看出,PSO 算法、ACO 算法和 CGSOA 算法均能寻得最优值,但 SD 有差异,其中 CGSOA 算法相对于 ACO 算法和 PSO 算法略差,但优于 BAS 算法和常规 SOA 算法。在高维函数寻优中,CGSOA 算法有明显的优势,在低维函数中,PSO 算法和 ACO 算法较优。从图 3—8 的函数收敛

表 3 各算法实验结果对比
Tab.3 Comparison of experimental results of each algorithm

Algorithm and function		f_1	f_2	f_3	f_4	f_5	f_6
BAS	mean	3.38	6.61	0.87	101.78	-7.50	-0.92
	SD	1.07	2.05	8.70×10^{-2}	16.53	2.04	0.27
PSO	mean	8.33×10^{-2}	9.96×10^{-2}	5.43×10^{-3}	28.46	-8.0393	-1.0316
	SD	3.50×10^{-2}	4.90×10^{-2}	1.80×10^{-3}	10.69	3.70×10^{-15}	6.60×10^{-16}
ACO	mean	2.01	2.03	9.57×10^{-1}	260.39	-8.0393	-1.0316
	SD	0.14	0.29	1.10×10^{-1}	16.72	1.50×10^{-15}	2.20×10^{-16}
SOA	mean	5.20×10^{-3}	1.28	2.10×10^{-2}	0.48	-8.0393	-1.0311
	SD	1.20×10^{-2}	0.80	6.30×10^{-2}	1.67	8.10×10^{-3}	9.80×10^{-4}
CGSOA	mean	2.50×10^{-28}	1.00×10^{-4}	5.60×10^{-3}	0.24	-8.0393	-1.0316
	SD	1.20×10^{-27}	2.20×10^{-4}	2.90×10^{-3}	0.96	2.10×10^{-6}	3.30×10^{-7}




图 3 函数 f_1 收敛曲线
Fig.3 Function f_1 convergence curve

曲线中可以看出，SOA 算法在迭代初期的表现最差。图 3 的 f_1 函数中，CGSOA 算法在迭代初期就逐渐收敛于最优值。图 4 的 f_2 函数中，CGSOA 算法在迭代 10 次之前只比常规 SOA 算法强，但第 10 次之后，比其他算法表现出更强的寻优能力。从图 5、图 6 中可以看出，对 f_3 和 f_4 函数寻优时，在迭代后期，CGSOA 算法都能比其他算法更早收敛于最优值。而从图 7、图 8 中可以看出，CGSOA 算法

的收敛效果略差于 PSO 算法和 ACO 算法，但优于其他算法。

函数测试结果表明，CGSOA 算法在高维函数上的收敛速度、收敛精度和稳定性优于其他算法，低维函数上略逊于 PSO 算法和 ACO 算法，但也比常规 SOA 算法性能好。说明针对局部最优、收敛过早、高维等问题，本文算法具有较好的收敛性、寻优性、稳定性，且搜索能力和开发能力较强。




图 4 函数 f_2 收敛曲线
Fig.4 Function f_2 convergence curve




图 5 函数 f_3 收敛曲线
Fig.5 Function f_3 convergence curve




图 6 函数 f_4 收敛曲线
Fig.6 Function f_4 convergence curve




图7 函数 f_5 收敛曲线
Fig.7 Function f_5 convergence curve




图8 函数 f_6 收敛曲线
Fig.8 Function f_6 convergence curve

4 AlCoCrNiFe 涂层制备

4.1 实验设计

在大气等离子喷涂实验中,喷涂距离过短,会导致粉末熔融效果不好,不利于粉末沉积在基体上,且距离较短时,粉末获得动能较小,基体受到的冲击力较小,使得基体过热,发生过烧现象,导致粘结性降低。喷涂距离过大时,喷枪的焰流温度降低,熔融粉末获得的动能降低,导致粉末在沉积过程中粘结性降低,即结合强度降低。

喷涂电流主要影响焰流能量密度及气焰流速。喷涂电流过小,焰流能量密度低,粉末熔融较差,降低涂层的力学性能。喷涂电流过大,会对基体产生过烧现象,使得结合处产生气孔及氧化物等缺陷,降低涂层质量。当电流变化时,配合电压的使用,能适当调节喷涂功率,以得到相应的焰流温度,提高涂层质量。

送粉载气过小时,每次到达枪口的熔融粉末较少,基体沉积较薄,且多次喷涂更容易影响已喷涂上的涂层,增加涂层内部气孔及金属氧化物夹杂,导致涂层性能降低。送粉载气过大时,焰流量大,粉末熔融不好或只有部分粉末熔融较好,熔融不充分的粉末沉积在基体上,会降低涂层质量。送粉电压对涂层的影响与送粉载

气一致,过低时,送粉量小,易产生气孔及夹渣的缺陷;过高时,粉末熔融效果不理想,从而降低涂层力学性能。

在本次实验中,采用由广州三鑫金属科技有限公司生产的 SX-80 等离子喷涂设备。选取喷涂距离、喷涂电流、喷涂电压、送粉载气、送粉电压作为输入,主压力恒定,机械手轨迹参数一定,即除喷涂距离、功率(电流、电压)、送粉载气、送粉电压外,其他参数恒定。机械手的喷涂轨迹设置呈“Z”字形,每步的跨度为 0.5 cm,为了保证喷涂的均匀性,每次编程控制机械手运行轨迹超出样品边缘一定距离,机械手运行轨迹如图 9 所示。喷涂相关预备材料如表 4 所示。




图9 机械手运行轨迹
Fig.9 Manipulator running track

表 4 喷涂相关预备材料
Tab.4 Preparation materials for spraying

Spraying substrate	Spraying materials	Spray gas	Powder feeding gas
Low carbon steel Q235(13 mm×13 mm×2 mm)	AlCoCrNiFe high entropy alloy	First gas: Ar, Secondary gas: H ₂	Ar

采用 X 射线衍射仪 (XRD, Bruker, D8-Advance 2009, Germany) 对 AlCoCrNiFe 高熵合金粉末及所制备的涂层进行物相分析, 测试的 2θ 角范围为 $10^{\circ}\sim90^{\circ}$ 。为了分析粉末元素分布, 使用配备 EDS 的扫描电子显微镜 (SEM, FEI-Quanta 600) 对粉末进行表征。拉伸强度在万能拉伸机上 (WDW-100) 测试, 以 2 mm/min 的拉伸速率进行实验, 直到涂层断裂。显微硬度在显微维氏硬度计 (HVM-2T) 下测量,

在室温下对样品的横截面进行维氏硬度测试, 试验压头的载荷设置为 200 g, 保压时间为 10 s, 然后让维氏硬度压头沿着基体向 AlCoCrNiFe 涂层方向进行测试, 每个位置保证至少 5 个压痕, 最终求平均值。试验所购的高熵合金粉各元素是等比分布的, EDS 元素分布图如图 10 所示, 可看出, 粉末大多呈球形分布, 各元素近似均匀分布于粉末颗粒中。高熵合金的粉末粒径通过相关电镜图像的定量分析图像 (Image J) 测量得到, 如图 11 所示, 可以看出粉末粒径主要集中在 15~45 μm 。

在 BP 神经网络上, 输入层节点数为 5, 输出层节点数为 2, 隐藏层节点数为 10。其中训练集为 20 组, 测试集为 5 组 (样本 5、10、15、20、25)。工艺参数优化模型及喷涂流程如图 12 所示, 通过正交试验法^[35]获取样本数据参数及实验结果如表 5 所示。




图 10 AlCoCrNiFe 高熵合金粉末的 SEM 形貌图和元素分布图
Fig.10 SEM morphology (a) and element distribution (b—g) of AlCoCrNiFe high entropy alloy powder




图 11 AlCoCrNiFe 高熵合金粉末粒径分布

Fig.11 Particle size distribution of AlCoCrNiFe high entropy alloy powder

4.2 适应度评价函数

在本试验中,以结合强度和显微硬度作为涂层性能的评价指标,为了兼顾这两个指标,本文采用式(13)作为适应度评价函数。

$$f(x_i) = \frac{a \left(\frac{q(x_i)}{q_{\max}} \right) + b \left(\frac{y(x_i)}{y_{\max}} \right)}{2} \quad (13)$$

式中: a 和 b 为权重因子。当 $a=1$ 、 $b=0$ 时,为单一结合强度优化;当 $a=0$ 、 $b=1$ 时,为单一显微硬度优化。以上两种情况为单目标优化。在本文中,为了平衡两个涂层性能指标的权重,即多目标优化,取 $a=b=1$ 。 $q(x_i)$ 和 $y(x_i)$ 分别为模型输出的结合强度和显微硬度, q_{\max} 和 y_{\max} 分别为最大拉伸结合强度和最大

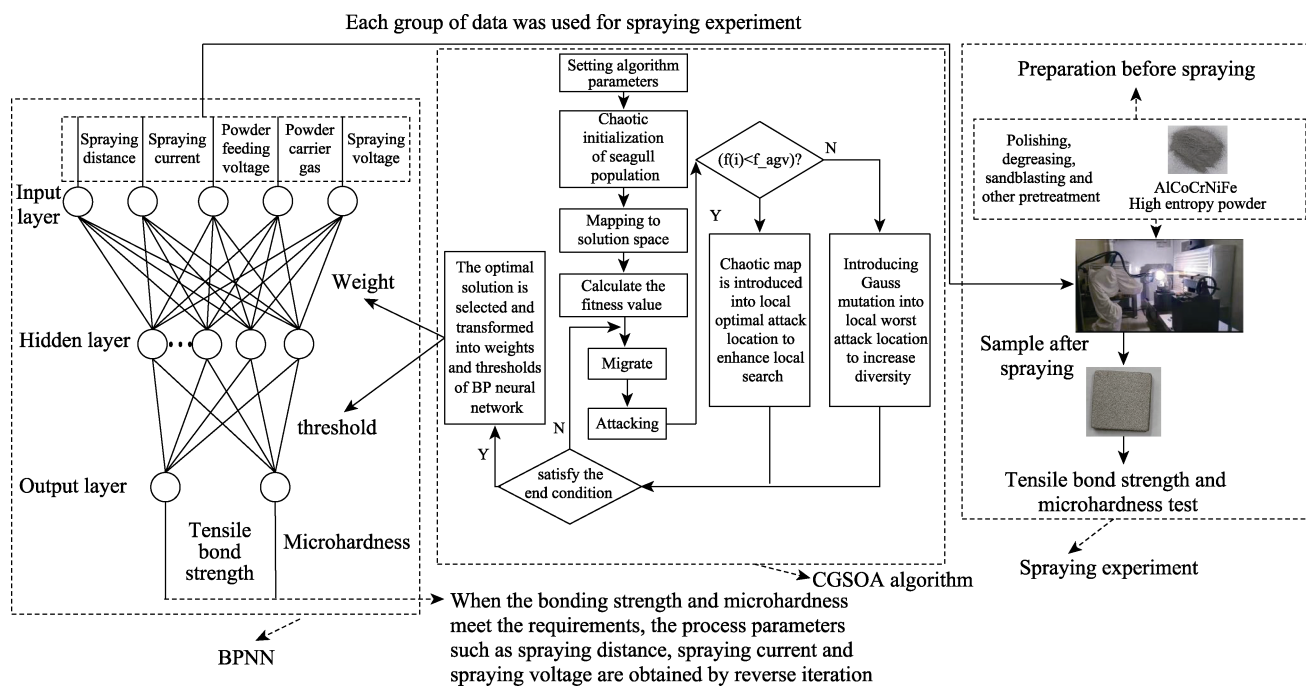


图 12 工艺参数优化模型及喷涂流程

Fig.12 Process parameter optimization model and spraying process

表 5 样本数据参数及实验结果

Tab.5 Sample data parameters and experimental results

Serial number	Process parameters					Coating properties	
	Spraying distance/mm	Spraying current/A	Spraying voltage/V	Powder carrier gas/(L·h ⁻¹)	Powder feeding voltage/V	Bonding strength/MPa	Microhardness (HV)
1	80	610	45	180	2	12.903	284.4
2	80	630	50	190	3	13.605	319.2
3	80	650	55	200	4	15.203	362.5
4	80	670	60	210	5	16.895	393.2
5	80	690	65	220	6	14.267	381.1
6	90	610	50	200	5	17.069	467.6
7	90	630	55	210	6	15.164	478.9
8	90	650	60	220	2	18.127	459.7
9	90	670	65	180	3	19.885	524.2
10	90	690	45	190	4	14.036	478.3

Serial number	Process parameters					Coating properties	
	Spraying distance/mm	Spraying current/A	Spraying voltage/V	Powder carrier gas/(L·h ⁻¹)	Powder feeding voltage/V	Bonding strength/MPa	Microhardness (HV)
11	100	610	55	220	3	17.496	528.5
12	100	630	60	180	4	22.547	596.7
13	100	650	65	190	5	24.021	615.1
14	100	670	45	200	6	15.862	509.6
15	100	690	50	210	2	14.179	487.1
16	110	610	60	190	6	13.291	529.9
17	110	630	65	200	2	16.436	583.4
18	110	650	45	210	3	13.870	512.5
19	110	670	50	220	4	23.462	576.8
20	110	690	55	180	5	21.583	527.6
21	120	610	65	210	4	24.185	572.2
22	120	630	45	220	5	14.813	503.8
23	120	650	50	180	6	14.065	458.6
24	120	670	55	190	2	15.430	405.1
25	120	690	60	200	3	17.196	473.5

显微硬度。为了使两个性能指标均能达到较优状态，则保证 $0.95 \leq \frac{q(x_i)}{q_{\max}} \leq 1.05$ ， $0.95 \leq \frac{y(x_i)}{y_{\max}} \leq 1.05$ ，在此约束条件下，结合强度和显微硬度可达到较优性能。

4.3 实验结果及分析

利用 CGSOA 算法优化 BP 神经网络的训练模型预测值与实际喷涂值的结果如图 13 所示，测试模型预测值与实际喷涂值结果如图 14 所示。从图 13 可以看出，训练模型的预测值与实际喷涂值非常接近；从图 14 看出，将 5 组数据输入到模型中，测试表明，预测值与实际值很接近，说明该模型的预测性能较好。

将影响变量在变化范围内的参数随机组合，作为该模型的输入，通过 50 次迭代计算，CGSOA 算法优化 BP 神经网络模型的适应度值曲线如图 15 所示。

当适应度值达到最大值 1.0316 时，反向迭代得出的最佳工艺参数为：喷涂距离 99.7 mm，喷涂电流 649.6 A，喷涂电压 56.3 V，送粉载气 203.1 L/h，送粉电压 5.1 V。预测结合强度和显微硬度分别为 24.44 MPa、598.85 HV。根据优化后的工艺参数制备 AlCoCrNiFe 高熵合金涂层，对喷涂 AlCoCrNiFe 粉末和制备的涂层进行 XRD 分析，如图 16 所示。由 XRD 图可以看出，涂层和高熵粉末都由无序 BCC（A2）和有序 BCC（B2）组成，相结构未发生改变，但所制备涂层的衍射峰强明显增加。对制备的涂层样品进行拉伸及显微硬度测试，结合强度和显微硬度的平均值分别为 25.2 MPa、616.8HV，与预测出的结合强度与显微硬度的相对误差分别为 3.02%、2.91%。综上，在该工艺参数下制备的 AlCoCrNiFe 涂层性能较好。




图 13 训练模型预测值与实际喷涂值
Fig.13 Predicted value of training model and actual spraying value




图 14 测试模型预测值与实际喷涂值
Fig.14 Predicted value of test model and actual spraying value




图 15 CGSOA 算法优化得到的适应度值曲线
Fig.15 Fitness value curve optimized by CGSOA algorithm




图 16 涂层和喷涂高熵粉末的 XRD 分析
Fig.16 XRD analysis of coating and sprayed high-entropy powder

5 结论

1) 全局混沌高斯混合的海鸥优化算法解决了基本海鸥优化算法“早熟”、种群多样性减少等问题,具有收敛性能好、寻优精度高、局部和全局搜索能力强等优点。

2) 利用全局混沌高斯融合的海鸥优化算法优化

BP 神经网络获得的喷涂工艺参数为:喷涂距离 99.7 mm,喷涂电流 649.6 A,喷涂电压 56.3 V,送粉载气 203.1 L/h,送粉电压 5.1 V。预测结合强度和显微硬度分别为 24.44 MPa、598.85HV。在该工艺参数下制备 AlCoCrNiFe 高熵合金涂层,得到结合强度和显微硬度分别为 25.2 MPa、616.8HV,相对误差分别为 3.02%、2.91%,在一定误差范围内,该涂层性能较好。CGSOA-BPNN 为等离子喷涂工艺参数的选取提供了科学的指导性。

3) 在材料性能预测、工艺参数寻优等方面,利用群智能优化算法与神经网络结合的模型,预测精度更高,可靠性更强,解决了多工艺参数寻优中单一 BP 神经网络过拟合导致预测误差大的问题。

4) 影响涂层性能的因素较多,在后期的研究中,将先对影响因素进行分析或降维处理,再利用智能算法或模型或机器学习等工具对其进行深入的研究。

参考文献:

- [1] LI Qiao-lei, SONG Peng, LV K, et al. Fracture Behaviour of Ceramic-Metallic Glass Gradient Transition Coating[J]. Ceramics International, 2019, 45(5): 5566-5576.
- [2] WANG Liang-quan, ZHANG Fan-yong, YAN Shu, et al. Microstructure Evolution and Mechanical Properties of Atmosphere Plasma Sprayed AlCoCrFeNi High-entropy Alloy Coatings under Post-annealing[J]. Journal of Alloys and Compounds, 2021, 872: 159607.
- [3] CALVO-DAHLBORG M, MEHRABAN S, LAVERY N P, et al. Prediction of Phase, Hardness and Density of High Entropy Alloys Based on Their Electronic Structure and Average Radius[J]. Journal of Alloys and Compounds, 2021, 865: 158799.
- [4] MEGHWAL A, ANUPAM A, LUZIN V, et al. Multiscale Mechanical Performance and Corrosion Behaviour of Plasma Sprayed AlCoCrFeNi High-entropy Alloy Coatings[J]. Journal of Alloys and Compounds, 2021, 854: 157140.

- [5] 康靓, 米晓希, 王海莲, 等. 人工神经网络在材料科学中的研究进展[J]. 材料导报, 2020, 34(21): 21172-21179.
KANG Jing, MI Xiao-xi, WANG Hai-lian, et al. Research Progress of Artificial Neural Networks in Material Science[J]. Materials Review, 2020, 34(21): 21172-21179.
- [6] 吴艳鹏, 魏剑辉, 李文戈, 等. 铝合金表面等离子喷涂 Al_2O_3 -3% TiO_2 复合涂层工艺参数优化的研究[J]. 表面技术, 2019, 48(6): 322-331.
WU Yan-peng, WEI Jian-hui, LI Wen-ge, et al. Optimization of Plasma Spraying Process Parameters for Al_2O_3 -3% TiO_2 Composite Coating on Aluminum Alloy[J]. Surface Technology, 2019, 48(6): 322-331.
- [7] 路广明, 乌日开西·艾依提. 等离子喷涂 TiO_2 基涂层工艺参数优化研究[J]. 表面技术, 2018, 47(4): 73-80.
LU Guang-ming, WURIKAIXI·Aiyiti. Process Parameter Optimization of Plasma Sprayed TiO_2 -based Coatings[J]. Surface Technology, 2018, 47(4): 73-80.
- [8] 夏卫生, 张海鸥, 王桂兰, 等. 神经网络在预测等离子喷涂 Ni 合金涂层质量中的应用[J]. 机械科学与技术, 2010, 29(8): 1008-1011.
XIA Wei-sheng, ZHANG Hai-ou, WANG Gui-lan, et al. Application of Artificial Neural Network to Quality Prediction of Ni Alloy Coatings Fabricated by Plasma Spraying[J]. Mechanical Science and Technology for Aerospace Engineering, 2010, 29(8): 1008-1011.
- [9] MOJENA M A R, ROCA A S, ZAMORA R S, et al. Neural Network Analysis for Erosive Wear of Hard Coatings Deposited by Thermal Spray: Influence of Microstructure and Mechanical Properties[J]. Wear, 2017, 376-377: 557-565.
- [10] BECKER A, FALS H D C, ROCA A S, et al. Artificial Neural Networks Applied to the Analysis of Performance and Wear Resistance of Binary Coatings Cr_3C_2 -37WC-18M and WC-20 Cr_3C_2 -7Ni[J]. Wear, 2021, 477: 203797.
- [11] PATURI U M R, CHERUKU S, GEEREDDY S R. Process Modeling and Parameter Optimization of Surface Coatings Using Artificial Neural Networks (ANNs): State-of-the-Art Review[J]. Materials Today: Proceedings, 2021, 38: 2764-2774.
- [12] HUEN W Y, LEE H, VIMONSATIT V, et al. Nano-mechanical Properties of Thermal Arc Sprayed Coating Using Continuous Stiffness Measurement and Artificial Neural Network[J]. Surface and Coatings Technology, 2019, 366: 266-276.
- [13] LIU Mei-mei, YU Ze-xin, ZHANG Yi-cha, et al. Prediction and Analysis of High Velocity Oxy Fuel (HVOF) Sprayed Coating Using Artificial Neural Network[J]. Surface and Coatings Technology, 2019, 378: 124988.
- [14] ZHU Jin-wei, WANG Xin-zhi, KOU Lu-yao, et al. Prediction of Control Parameters Corresponding to In-Flight Particles in Atmospheric Plasma Spray Employing Convolutional Neural Networks[J]. Surface and Coatings Technology, 2020, 394: 125862.
- [15] 汪刘应, 王汉功, 华绍春, 等. 用 GA-BP 算法研究超音速电弧喷涂 JCW-S-AM 涂层显微硬度与工艺参数间的关系[J]. 稀有金属材料与工程, 2006, 35(4): 634-637.
WANG Liu-ying, WANG Han-gong, HUA Shao-chun, et al. Study on Relation between the Microhardness of JCW-S-AM Coatings Prepared by High Velocity Arc Spray and the Process Parameters Using GA-BP Arithmetic[J]. Rare Metal Materials and Engineering, 2006, 35(4): 634-637.
- [16] 华绍春, 王汉功, 汪刘应, 等. 微弧等离子喷涂 AT13 纳米涂层的工艺优化[J]. 无机材料学报, 2007, 22(3): 560-564.
HUA Shao-chun, WANG Han-gong, WANG Liu-ying, et al. Optimization of the Process Parameters of Nano-structured AT13 Coatings Prepared by Micro-Plasma Spraying[J]. Journal of Inorganic Materials, 2007, 22(3): 560-564.
- [17] 王东生, 杨斌, 田宗军, 等. 基于遗传神经网络的等离子喷涂纳米 ZrO_2 -7% Y_2O_3 涂层工艺参数优化[J]. 焊接学报, 2013, 34(3): 10-14.
WANG Dong-sheng, YANG Bin, TIAN Zong-jun, et al. Process Parameters Optimization of Nanostructured ZrO_2 -7% Y_2O_3 Coating Deposited by Plasma Spraying Based on Genetic Algorithms and Neural Networks[J]. Transactions of the China Welding Institution, 2013, 34(3): 10-14.
- [18] 杨振凯, 王海军, 刘明, 等. 基于 BP 神经网络的 Fe 合金粉末喷涂工艺参数优化[J]. 表面技术, 2015, 44(9): 1-6.
YANG Zhen-kai, WANG Hai-jun, LIU Ming, et al. Optimization of Spraying Process Parameters for Fe-based Alloy Based on BP Neural Network Model[J]. Surface Technology, 2015, 44(9): 1-6.
- [19] 帅茂杭, 熊国江, 胡晓, 等. 基于改进多目标骨干粒子群算法的电力系统环境经济调度[J/OL]. 控制与决策, 2021: [2021-03-04]. https://kns.cnki.net/kcms/detail/detail.aspx?dbcode=CAPJ&dbname=CAPJLAST&filename=KZYC2021030300F&uniplatform=NZKPT&v=OKAgri6ShmPluCvjAxDaV_oERjlgUjIQSSLkVqEDCDeN7wEvf3rSqkYxAev7cHUC
SHUAI Mao-hang, XIONG Guo-jiang, HU Xiao, et al. Economic Emission Dispatch of Power System Based on Improved Bare-Bone Multi-Objective Particle Swarm Optimization Algorithm[J/OL]. Control and Decision, 2021: [2021-03-04]. https://kns.cnki.net/kcms/detail/detail.aspx?dbcode=CAPJ&dbname=CAPJLAST&filename=KZYC2021030300F&uniplatform=NZKPT&v=OKAgri6ShmPluCvjAxDaV_oERjlgUjIQSSLkVqEDCDeN7wEvf3rSqkYxAev7cHUC
- [20] 张强, 李盼池, 王梅. 基于自适应进化策略的人工蜂群优化算法[J]. 电子科技大学学报, 2019, 48(4): 560-566.
ZHANG Qiang, LI Pan-chi, WANG Mei. Artificial Bee Colony Optimization Algorithm Based on Adaptive

- Evolution Strategy[J]. Journal of University of Electronic Science and Technology of China, 2019, 48(4): 560-566.
- [21] 马小陆, 梅宏. 基于改进势场蚁群算法的移动机器人全局路径规划[J]. 机械工程学报, 2021, 57(1): 19-27.
MA Xiao-lu, MEI Hong. Mobile Robot Global Path Planning Based on Improved Ant Colony System Algorithm with Potential Field[J]. Journal of Mechanical Engineering, 2021, 57(1): 19-27.
- [22] 柳长源, 任宇艳, 毕晓君. 基于改进萤火虫算法的区域交通信号配时优化[J]. 控制与决策, 2020, 35(12): 2829-2834.
LIU Chang-yuan, REN Yu-yan, BI Xiao-jun. Timing Optimization of Regional Traffic Signals Based on Improved Firefly Algorithm[J]. Control and Decision, 2020, 35(12): 2829-2834.
- [23] 崔雪婷, 李颖, 范嘉豪. 全局混沌蝙蝠优化算法[J]. 东北大学学报(自然科学版), 2020, 41(4): 488-491.
CUI Xue-ting, LI Ying, FAN Jia-hao. Global Chaotic Bat Optimization Algorithm[J]. Journal of Northeastern University (Natural Science), 2020, 41(4): 488-491.
- [24] 汤安迪, 韩统, 徐登武, 等. 混沌多精英鲸鱼优化算法[J]. 北京航空航天大学学报, 2021, 47(7): 1481-1494.
TANG An-di, HAN Tong, XU Deng-wu, et al. Chaotic Multi-Leader Whale Optimization Algorithm[J]. Journal of Beijing University of Aeronautics and Astronautics, 2021, 47(7): 1481-1494.
- [25] ZHANG Cheng-long, DING Shi-fei. A Stochastic Configuration Network Based on Chaotic Sparrow Search Algorithm[J]. Knowledge-Based Systems, 2021, 220: 106924.
- [26] DHIMAN G, KUMAR V. Seagull Optimization Algorithm: Theory and Its Applications for Large-Scale Industrial Engineering Problems[J]. Knowledge-Based Systems, 2019, 165: 169-196.
- [27] CAO Yan, LI Yi-qing, ZHANG Geng, et al. Experimental Modeling of PEM Fuel Cells Using A New Improved Seagull Optimization Algorithm[J]. Energy Reports, 2019, 5: 1616-1625.
- [28] LEI Gang, SONG He-qing, RODRIGUEZ D. Power Generation Cost Minimization of the Grid-Connected Hybrid Renewable Energy System Through Optimal Sizing Using the Modified Seagull Optimization Technique[J]. Energy Reports, 2020, 6: 3365-3376.
- [29] 陈志刚, 梁涤青, 邓小鸿, 等. Logistic 混沌映射性能分析与改进[J]. 电子与信息学报, 2016, 38(6): 1547-1551.
CHEN Zhi-gang, LIANG Di-qing, DENG Xiao-hong, et al. Performance Analysis and Improvement of Logistic Chaotic Mapping[J]. Journal of Electronics & Information Technology, 2016, 38(6): 1547-1551.
- [30] XU Yue-ting, CHEN Hui-ling, HEIDARI A A, et al. An Efficient Chaotic Mutative Moth-Flame-Inspired Optimizer for Global Optimization Tasks[J]. Expert Systems with Applications, 2019, 129: 135-155.
- [31] 卢青波, 张学良, 温淑花, 等. 高斯变异差分进化算法及其应用研究[J]. 工程设计学报, 2012, 19(5): 372-378.
LU Qing-bo, ZHANG Xue-liang, WEN Shu-hua, et al. Research on Differential Evolution Algorithm Based on Gauss Mutation and Its Application[J]. Journal of Engineering Design, 2012, 19(5): 372-378.
- [32] JIANG X, LI S. BAS: Beetle Antennae Search Algorithm for Optimization Problems[J]. International Journal of Robotics and Control. 2018, 1(1): 1-5.
- [33] KENNEDY J, EBERHART R. Particle Swarm Optimization[C]//In Proceedings of the 1995 IEEE International Conference. USA: IEEE, 1995: 1942-1948.
- [34] PAN M Z, LI C, GAO R, et al. Photovoltaic Power Forecasting Based on A Support Vector Machine with Improved Ant Colony Optimization[J]. Journal of Cleaner Production, 2020, 277: 123948.
- [35] 刘贵民, 杨忠须, 张一帆, 等. 基于正交试验法的超音速等离子喷涂钨涂层组织及性能研究[J]. 兵工学报, 2016, 37(8): 1489-1496.
LIU Gui-min, YANG Zhong-xu, ZHANG Yi-fan, et al. Research on Microstructure and Properties of Supersonic Plasma Sprayed Mo Coating Based on Orthogonal Experiment[J]. Acta Armamentarii, 2016, 37(8): 1489-1496.