

DOI: 10.20189/j.cnki.CN/61-1527/E.202501006

基于双变异策略差分进化算法的 稀疏线阵优化方法

王 莉

(火箭军工程大学, 陕西 西安 710025)

摘 要: 针对稀疏线阵天线优化中如何有效降低峰值旁瓣电平的问题, 提出了一种基于柯西-高斯双变异策略的改进差分进化算法。该算法通过 Tent 混沌映射生成初始值, 增加了种群多样性; 随迭代和适应值变化, 对缩放因子进行动态调整, 有助于算法更好地进行寻优; 当算法出现早熟迹象时, 采用双变异策略助力跳出局部最优, 实现全局最优解搜索。通过与经典算法进行对比, 利用标准函数测试验证了算法的优化性能。通过 3 种天线实例的仿真实验结果表明: 所提改进算法能够有效降低峰值旁瓣电平, 提升天线效能, 与对比算法中的最优算法相比较, 所提算法 50 次实验的最优峰值旁瓣电平分别降低了 0.11 dB、0.62 dB 和 2.42 dB, 平均峰值旁瓣电平分别降低了 0.04 dB、0.28 dB 和 1.5 dB。

关键词: 阵列天线; 峰值旁瓣电平; 差分进化算法; 双变异策略

中图分类号: TN820

文献标志码: A

开放科学标识码(OSID):

文章编号: 2097-2741(2025)01-050-10



听语音
与作者互动
聊科研

Sparse Linear Array Optimization Based on Differential Evolution Algorithm with Dual Mutation Strategies

WANG Li

(Rocket Force University of Engineering, Xi'an 710025, China)

ABSTRACT: To effectively reduce the peak sidelobe level in a sparse linear array antenna, an improved differential evolution algorithm based on a dual mutation strategy combining Cauchy and Gaussian mutations was proposed. The initial value of the proposed algorithm was generated through Tent chaotic mapping to increase the population diversity. Simultaneously, it was dynamically adjusted using iterations and fitness values, which improved the optimization of the algorithm. When the algorithm showed signs of prematurity, a dual mutation strategy was introduced to escape from local optima and achieve a global optimal solution search. By comparing with those of classical algorithms, the optimized performance of the proposed algorithm was verified.

收稿日期: 2024-10-24

基金项目: 国家自然科学基金资助项目 (62201606)

第一作者: 王莉 (1986—), 女, 副教授, 主要从事无线通信研究。E-mail: wangli0511@163.com

引用格式: 王莉. 基于双变异策略差分进化算法的稀疏线阵优化方法[J]. 火箭军工程大学学报, 2025, 39 (1): 50-59. WANG Li. Sparse linear array optimization based on differential evolution algorithm with dual mutation strategies[J]. Journal of Rocket Force University of Engineering, 2025, 39 (1): 50-59.

through standard function tests. Results of simulation experiments on three antenna examples showed that the proposed algorithm can effectively reduce the peak sidelobe level and enhance antenna efficiency. Compared with the peak sidelobe levels of the optimal algorithm among the comparison algorithms, the optimal peak sidelobe levels of the proposed algorithm in 50 experiments are reduced by 0.11 dB, 0.62 dB, and 2.42 dB respectively, while the average peak sidelobe levels are reduced by 0.04 dB, 0.28 dB, and 1.5 dB respectively.

KEYWORDS: array antenna; peak sidelobe level; differential evolution algorithm; dual mutation strategy

天线阵列是由多个天线单元(阵元)按照一定规则排列构成的,线阵是一种常见的结构简单的天线阵列。国内外学者针对线阵的研究提出了许多方法,总体上可以归为两类。一类是以迭代傅里叶变换方法为代表的稀疏线阵(Thinned Linear Array, TLA)综合方法,另一类是以随机优化方法为代表的稀布线阵(Sparse Linear Array, SLA)优化方法。其中,稀布线阵提高了阵元分布的自由度,能以更少的阵元数量满足天线性能要求,因此应用更加广泛。正是由于稀布线阵在空间上阵元分布的自由度高,应用时要想实现良好的方向性,关键是通过调整阵元的间距进行旁瓣抑制,有效压制系统在主瓣方向以外方向上产生的天线振荡能量,否则旁瓣能量过强会导致信号的失真和接收性能的下降。

针对如何对稀布线阵阵元间距进行合理分布来降低峰值旁瓣电平(Peak Sidelobe Level, PSL)的问题,研究者提出了很多优化算法^[1-12],如差分进化(Differential Evolution, DE)算法、布谷鸟算法、粒子群优化算法和遗传算法等。DE算法是基于群体智能理论具有代表性的优化算法,基本原理是通过种群内所有个体之间的不断合作及相互竞争,生成依托于种群的全局搜索机制。此算法通用性强,因此DE及其改进算法广泛应用于阵列天线优化中。但随着进化代数的增加,基本DE算法会使种群的多样性变小、过早地收敛到局部极小值或者导致算法停滞。文献[13]提出自适应策略控制差分进化算法中的交叉概率,并应用于多约束稀布矩形面阵的优化,有效降低了天线的峰值旁瓣电平。但当算法陷入局部最优后很难跳出局部极值,同时算法比较复杂,计算耗时长。文献[14]提出结合差分进化算法与和声搜索算法应用于稀布同心圆环阵列,引入随机噪声来达到提升种群多样性的目的,对种群保留概率以及变异概率动态变化建立了模型,提高了优化算

法的全局搜索能力,有效提升了阵列天线的优化性能。但由于和声搜索算法的参数调整不灵敏,导致算法在优化过程中收敛性会变差,容易陷入局部最优。文献[15]提出一种基于莱维飞行的差分进化算法,充分利用阵元分布的自由度来提高天线性能。适用于稀疏率较高的阵列天线,但其缩放因子固定不变,在算法迭代后期,如果缩放因子仍取较大值,会使种群中的个体在最优值附近振荡,不利于局部探索。以上算法都对DE算法进行了改进并应用于阵列天线优化,取得了一定成效,但仍有提升空间。

为进一步降低稀布线阵峰值旁瓣电平,本文提出一种基于柯西-高斯双变异策略的差分进化(Dual Mutation Differential Evolution, DMDE)算法。首先,由Tent混沌映射生成初始值,变异策略的缩放因子随迭代次数和适应值动态变化,使搜索更加精确高效。其次,当算法陷入停滞时,对整个群体采用柯西-高斯变异策略,令群体跳出局部最优,寻得全局最优解。最后,通过标准函数的测试和多约束稀布线阵仿真实验证明了该方法的有效性。

1 稀布线阵的阵列模型

设稀布线阵的结构为对称线阵,阵元全部相同。若阵元数为奇数,则记为 $2N+1$ 个, N 为正整数,布阵示意如图1所示。




图1 稀布线阵的布阵示意

Fig. 1 Schematic of sparse linear array layout

此时天线阵的方向图可表示为

$$E(u) = \sum_{n=-N}^N I_n \exp(jkux_n) = 2 \sum_{n=1}^N \cos(kux_n) + 1$$

式中: $k = 2\pi/\lambda$; $u = \sin \theta$, θ 为扫描角, 且 $0 \leq \theta \leq \pi$; I_n 为第 n 个天线单元的激励, 阵元的激励在优化模型中不予考虑, 令 $I_n = 1$, x_n 为第 n 个天线单元的位置。天线阵列孔径为 $2L$, 对称线阵中, $x_n = -x_{-n}$, $x_N = L$, $x_{-N} = -L$ 。

若阵元数为偶数, 记为 $2N$ 个, N 为正整数, 原点位置不设阵元, 此时天线阵的方向图可表示为

$$E(u) = \sum_{n=-N}^N I_n \exp(jkux_n) = 2 \sum_{n=1}^N \cos(kux_n)$$

峰值旁瓣电平越低, 则阵列天线的主瓣方向性能越好。因此, 最优目标设定为峰值旁瓣电平的最小化, 阵列天线的峰值旁瓣电平可表示为

$$f(x) = \max_{u_s \in \text{sidelobe}} \left| \frac{E(u_s)}{E_{\max}} \right|$$

式中: $E(u_s)$ 为天线方向图中的旁瓣区域的电平值; $E_{\max}$ 为主瓣区域的最大电平值; $x = [x_1, x_2, \dots, x_N]$ 为各个阵元的位置。对于稀布阵列天线而言, 其布阵的约束条件为: 满足阵列孔径的尺寸, 满足阵元的数量条件, 满足阵元之间的间隔不小于 d_c , 建立稀布线阵的优化模型可表示为

$$\begin{cases} \min \{f(x)\} \\ \text{s.t. } x_i - x_j \geq d_c > 0 \\ i, j \in \mathbf{Z}, 1 \leq j < i \leq N \\ x_1 = 0, x_N = L \end{cases}$$

式中: d_c 为阵元最小间隔。

2 DMDE 算法

标准 DE 算法由 3 个步骤组成: 一是“变异”, 由种群中随机 2 个个体得到加权差向量, 再加到第三个个体上从而产生新的变异向量; 二是“交叉”, 将变异向量和目标向量中的某一分量按一定规则传递到试验向量里; 三是“选择”, 对于最小化问题, 比较试验向量和目标向量的适应值, 若试验向量适应值更低, 则用其替代目标向量^[12]。在算法的每一次迭代过程中, 所有个体仅能作为目标个体一次, 保留适应值低的个体, 淘汰适应值高的个体, 促使搜索点不断向全局最优点逼近。DMDE 算法主要有以下 3 点改进。

2.1 基于 Tent 混沌映射的初始值生成

在原始的 DE 算法中, 种群初始值是随机生成

的, 个体的初始位置不能保证在搜索空间中均匀分布, 影响了算法的搜索速度和优化性能。因此, 对 DE 算法的初始化进行改进, 引入 Tent 混沌映射, 如图 2 所示, 其在空间内具有遍历性和随机性, 可增加种群多样性。种群初始值生成基于 Tent 混沌映射, 系统方程可表示为

$$z_{j+1} = \begin{cases} \frac{z_j}{a}, & z_j \in [0, a) \\ \frac{1-z_j}{1-a}, & z_j \in [a, 1) \end{cases}$$

式中: z 为混沌序列; $j = 1, 2, \dots, D$, D 为优化变量的维度; a 为常数, 在此取值为 0.5。初始位置向量生成

$$y = l_b + (u_b - l_b) \cdot z$$

式中: y 为差分进化个体的初始位置向量; l_b 为位置的边界下限; u_b 为位置的边界上限。




图 2 Tent 映射初始化种群

Fig. 2 Initialized population through Tent mapping

2.2 缩放因子动态调整的变异策略

DMDE 采用 DE/best/1 变异策略, 变异个体和试验个体按照式 (1) 和式 (2) 产生:

$$v_i^t = x_{\text{best}}^t + F \times (x_{r_1}^t - x_{r_2}^t) \quad (1)$$

式中: v_i^t 为迭代到第 t 代时, 第 i 个变异个体分量; x_{best}^t 为第 t 代种群中的最优个体; F 为缩放因子; $x_{r_1}^t$ 、 $x_{r_2}^t$ 为第 t 代种群中随机的 2 个不同个体。

v_i^t 与 x_i^t 由式 (2) 进行交叉运算。

$$u_{i,j}^t = \begin{cases} v_{i,j}^t, & \text{rand}j \leq CR \\ x_{i,j}^t, & \text{其他} \end{cases} \quad (2)$$

式中: $u_{i,j}^t$ 为第 t 代第 i 个试验个体分量; $x_{i,j}^t$ 为第 t 代第 i 个个体分量; CR 为交叉概率; $\text{rand}j$ 表示在 $[0, 1]$ 之间产生的随机数。

缩放因子 F 是调节差分向量缩放比例的参数, 对算法的寻优能力尤其是全局寻优起到至关重要的作用。较小的缩放因子有助于局部寻优, 但容

易造成早熟收敛。较大的缩放因子有助于算法跳出局部最优，但容易使收敛速度变慢。为了实现更精确高效寻优，DMDE 对传统 DE 算法变异策略中缩放因子 F 固定不变的情况进行改进，让缩放因子 F 自适应变化。

首先，将 F 分成 2 种取值范围

$$\begin{cases} F_{\min} = 0.65, F_{\max} = 0.9, & t \leq (Iter/2) \\ F_{\min} = 0.4, F_{\max} = 0.65, & \text{其他} \end{cases} \quad (3)$$

式中： $F_{\min}$ 为 F 下限； $F_{\max}$ 为 F 上限； t 为进化代数； $Iter$ 为迭代总次数。

算法前半迭代时，每个个体的缩放因子 F 的最小值和最大值选用式 (3) 的上式，即取值范围为 0.65~0.9；算法后半迭代时，每个个体的缩放因子 F 的最小值和最大值选用式 (3) 的下式，即取值范围为 0.4~0.65。迭代前期缩放因子值相对设置大些，使种群多样性增强；迭代后期缩放因子值相对设置小些，使小范围搜索更加精确高效；整体来说有助于算法更好地进行寻优。

其次，让每个个体的缩放因子 F 随上代适应值进行自适应变化。第 t 代迭代过程中保存种群所有个体的适应值 $fit^t = [fit_1^t, fit_2^t, \dots, fit_{NP}^t]^t$ ，则 $t+1$ 代的第 i 个个体变异时，其缩放因子 F_i^{t+1} 可表示为

$$F_i^{t+1} = \left| \frac{fit_i^t - fit_{\min}^t}{fit_{\max}^t - fit_{\min}^t + \rho} \right| \cdot \Delta F + F_{\min} \quad (4)$$

式中： fit_i^t 为第 t 代第 i 个个体的适应值； $fit_{\min}^t = \min(fit^t)$ 为第 t 代所有适应值中的最优值，即取值最小的适应值； $fit_{\max}^t = \max(fit^t)$ 为第 t 代所有适应值中的最差值，即取值最大的适应值； ρ 为调节因子，取值为 10^{-18} ，以避免分母值为 0； $\Delta F = F_{\max} - F_{\min}$ ，可由式 (1) 得到。

式 (4) 所示的缩放因子计算方法中，当 $fit_i^t = fit_{\min}^t$ 时， F_i^{t+1} 取值为 $F_{\min}$ ，当 $fit_i^t = fit_{\max}^t$ 时，则 $F_i^{t+1} \rightarrow F_{\max}$ 。当第 t 代个体的适应值越接近最小适应值，说明与最优点逼近，则在第 $t+1$ 代设置的缩放因子 F_i^{t+1} 较小，让其在最优点附近小范围内搜索，提高算法的寻优能力。当第 t 代个体的适应值越远离最小适应值，说明与最优点相差较远，则在第 $t+1$ 代设置的缩放因子 F_i^{t+1} 较大，让其在接下来的搜索中扰动范围增大，提高算法的全局寻优能力。

2.3 柯西、高斯双变异策略跳出局部最优

柯西分布、高斯分布均是常见的概率分布，两者均值为 0 的折线图与散点图如图 3 所示。




图 3 高斯分布和柯西分布折线和散点图

Fig. 3 Line charts and scatter plots of Gaussian and Cauchy distributions

高斯分布的点分散在坐标原点附近范围,柯西分布的点大部分集中在坐标原点附近,还有少部分分布在坐标较远的两端范围。联合柯西和高斯分布的概率密度函数为

$$f(x) = \beta_1 \text{Cauchy}(0, 1) + \beta_2 \text{Gauss}(0, 1)$$

式中: β_1 和 β_2 分别为柯西和高斯系数, 满足 $\beta_1 + \beta_2 = 1$ 。

柯西-高斯联合分布概率密度函数曲线如图 4 所示, 4 条曲线分别为 100% 高斯分布 ($\beta_1 = 0, \beta_2 = 1$), 100% 柯西分布 ($\beta_1 = 1, \beta_2 = 0$), 60% 柯西-40% 高斯分布 ($\beta_1 = 0.6, \beta_2 = 0.4$), 40% 柯西-60% 高斯分布 ($\beta_1 = 0.4, \beta_2 = 0.6$)。由图 4 可以看出, 高斯分布占的比例越大, 曲线在坐标原点的峰值越大, 两侧分布的范围更窄; 柯西分布占的比例越大, 曲线在两端分布的范围更宽。




图 4 柯西-高斯联合分布概率密度函数曲线

Fig. 4 Cauchy-Gaussian joint distribution probability density function curves

在应对多峰值优化问题时, DE 算法也容易陷入局部最优, 当检测到算法陷入停滞时 (即连续多代种群的最优适应值没有明显改进), 对整个种群采用柯西-高斯双变异策略, 以增强算法的全局搜索能力并帮助跳出局部最优, 提升算法的寻优精度。具体方法是在每次算法迭代更新后, 判断群体是否早熟, 判断条件为: 若经历 5 次迭代后种群最优适应值仍保持不变, 则判定算法陷入停滞, 对整个种群采用柯西-高斯双变异扰动, 令种群跳出局部最优解, 表达式为

$$x_{\text{new}_i}(t) = x_{\text{best}}(t) \cdot [1 + \beta_1 \text{Cauchy}(0, 1) + \beta_2 \text{Gauss}(0, 1)] \quad (5)$$

式中: $\beta_1 = 1 - \frac{t}{\text{Iter}}$; $\beta_2 = \frac{t}{\text{Iter}}$ 。

式 (5) 的变异扰动意味着: 在迭代前期, 柯

西分布占比较大, 变异扰动范围更大, 有利于搜索到全局最优值; 随着迭代次数的增加, 高斯分布的占比越来越大, 可实现在最优值 x_{best} 附近重点搜索优秀极值。

2.4 算法的基本流程

基于标准 DE 算法, DMDE 算法的具体步骤如下:

Step1 设置 NP 、 Iter 、 CR 等参数的初始值, 通过 Tent 混沌映射生成初始值, 包含 NP 个个体 $[x_1, x_2, \dots, x_{NP}]$ 。

Step2 计算初始种群个体适应值 $\text{fit}(x^i)$, $i \in [1, NP]$, 其中 $x^i = [x_1^i, x_2^i, \dots, x_D^i]^T$ 表示第 i 个个体, D 是优化变量的维度。

Step3 当前种群的缩放因子 F 由式 (3) 和式 (4) 计算, 基于式 (1) 得到变异个体 v^i 。

Step4 基于式 (2), 依据交叉概率 CR 对 v^i 和 x^i 进行交叉操作, 得到试验向量 u^i 。

Step5 整体对种群进行更新。如果 $\text{fit}(u^i) < \text{fit}(x^i)$, 则用 u^i 代替 x^i , 更新种群个体及最新适应值, 否则保留原来种群。

Step6 判断近 5 次迭代得到的最优适应值是否相同。若相同, 说明近 5 次种群没有更新, 判定算法陷入停滞, 出现“早熟”迹象, 则对种群每个个体都采取式 (5) 的柯西-高斯变异扰动, 再计算扰动后个体的适应值, 若个体适应值小于 $\text{fit}(x^i)$, 更新种群个体及最新适应值, 否则不更新。

Step7 若已达到迭代次数, 算法结束, 得出最终结果, 否则迭代次数加 1, 继续执行 Step3 至 Step7。

3 仿真测试与分析

为了检验 DMDE 算法的优化性能, 将 DMDE 与 DE (rand)、DE (best) 和 DELF 算法进行仿真对比。测试实验选用 6 个测试函数, 如表 1 所示, 测试函数中 x 代表优化变量, D 是优化变量维度, 前 4 个函数为单峰, 后 2 个函数为多峰。单峰函数可以检验优化算法的收敛速度和寻优精度, 多峰函数可以测试优化算法的全局搜索能力。实验仿真条件如表 2 所示, 测试函数中的变量维度 D 均为 100。

为了保证实验结果的可靠性, 对每种优化算法的每一个测试函数均进行 $MC=50$ 次蒙特卡罗仿

表 1 测试函数信息

Tab. 1 Test function information

测试函数	表达式	变量范围	最小值
f_1	$\sum_{i=1}^D x_i^2$	$[-100, 100]$	0
f_2	$\sum_{i=1}^D x_i + \prod_{i=1}^D x_i $	$[-100, 100]$	0
f_3	$\sum_{i=1}^D \left(\sum_{j=1}^i x_j \right)^2$	$[-100, 100]$	0
f_4	$\max \{ x_i \}$	$[-100, 100]$	0
f_5	$\sum_{i=1}^D [x_i^2 - 10 \cos(2\pi x_i) + 10]$	$[-5.12, 5.12]$	0
f_6	$\frac{1}{4000} \sum_{i=1}^D x_i^2 - \prod_{i=1}^D \cos\left(\frac{x_i}{\sqrt{i}}\right) + 1$	$[-600, 600]$	0

表 2 DMDE 运行参数

Tab. 2 DMDE operating parameters

优化算法	MC	NP	Iter	CR	MR	F
DE(rand)	50	50	1 000	0.5	—	0.5
DE(best)					—	0.5
DELF					0.5	0.5
DMDE					—	自适应

真实验，得到优化适应值的平均值和标准差。将 4 种算法的仿真结果数据进行对比，结果如表 3 所示。可以看出，对于 f_1 、 f_3 、 f_5 、 f_6 来说，DMDE 算法均找到了最小值 0；对于 f_2 、 f_4 来说，DMDE 算法的最优值分别为 1.44E-182、1.95E-302，结果也非常优秀。总体来说，DMDE 算法的寻优能力较为突出。

4 种优化算法迭代结果对比如图 5 所示，横坐

标表示迭代次数，纵坐标表示函数的适应值。可以看出，DMDE 算法的搜索效率和寻优能力的优势更加明显。对于 f_1 、 f_3 、 f_5 、 f_6 来说，DMDE 算法利用较少的迭代次数就能找到最小值，迭代效率高，收敛速度快。

4 稀布线阵仿真测试

为检验基于 DMDE 的低旁瓣稀布线阵的优化布阵效果，进行 3 组天线实例仿真。仿真参数设置为： $MC=50$ ， $NP=50$ ， $Iter=50$ ， $CR=1$ ， $MR=0.5$ ，自适应调整 F 。各组实验在相同条件下与 DELF^[15]、NBDE^[16]、BGA^[17]、Boolean PSO^[18] 等经典参考算法进行比较。3 组实验的天线为不同稀疏率下的对称稀布线阵综合（阵列孔径 $2L$ 和阵元数量 N_e 的设定主要是与参考算法中天线实例参数

表 3 4 种优化策略仿真数据对比（ $D=100$ ）

Tab. 3 Comparison of simulation data of four optimization strategies（ $D=100$ ）

测试函数	DE(rand)		DE(best)		DELF		DMDE	
	平均值	标准差	平均值	标准差	平均值	标准差	平均值	标准差
f_1	6.22E+02	9.94E+01	2.63E-06	6.85E-06	1.15E-03	1.60E-03	0.00E+00	0.00E+00
f_2	2.63E+01	3.49E+00	1.38E+00	2.91E+00	2.16E-01	1.82E-01	1.44E-182	0.00E+00
f_3	4.34E+05	5.14E+04	1.09E+05	1.54E+04	1.77E+05	2.09E+04	0.00E+00	0.00E+00
f_4	9.52E+01	1.50E+00	4.06E+01	2.79E+00	3.92E+01	3.65E+00	1.95E-302	0.00E+00
f_5	9.55E+02	2.59E+01	2.80E+02	4.49E+01	5.67E+02	3.33E+01	0.00E+00	0.00E+00
f_6	6.72E+00	9.71E-01	3.20E-01	1.02E+00	1.40E-02	1.91E-02	0.00E+00	0.00E+00

注：加粗字体表示最优值

设置保持一致), 最小阵元间隔 $d_c = 98.5\lambda$, 俯仰角采样点数设为 1 801, 每组实验均进行 50 次蒙特卡洛仿真以检验算法的稳定性, 数值统计结果如表 4 所示。

1) 天线仿真实例 1

实例 1 是对稀疏率为 76% 的 200 阵元稀布阵列进行优化, 实际阵元数为 152, 阵列孔径为 98.5λ 。DMDE 算法的优化结果如图 6 所示。




图 5 4 种优化算法迭代结果对比
Fig. 5 Comparison of iteration results of four optimization algorithms

表 4 不同算法的仿真结果对比

实例	dB									
	DMDE		DELFL		NBDE		Boolean PSO		BGA	
	最优	平均	最优	平均	最优	平均	最优	平均	最优	平均
1	-24.20	-23.84	-24.09	-23.80	-21.15	-20.78	-20.86	-20.20	-19.08	-18.17
2	-25.49	-24.03	-24.87	-23.75	-23.03	-22.54	-21.27	-20.27	-18.83	-18.36
3	-23.01	-20.18	-20.59	-18.68	-19.51	-18.35	-17.44	-17.06	-17.08	-16.67




图 6 DMDE 算法天线实例 1 的仿真结果
Fig. 6 Simulation results of antenna example 1 using DMDE algorithm

由图 6 可以看出, 在 50 次蒙特卡洛仿真中, 其最优 PSLL 为 -24.20 dB, 比表 4 所列参考算法中效果最好的 DELF 最优值 -24.09 dB 降低了 0.11 dB; 平均 PSLL 为 -23.84 dB, 也优于表 4 所列其他 4 种参考算法。可以得出, 在实例 1 中, DMDE 比其他 4 种参考算法寻优能力更强。

2) 天线仿真实例 2

实例 2 是对稀疏率为 66% 的 200 阵元稀布阵列进行优化, 实际阵元数为 132, 阵列孔径为 90.5λ 。DMDE 算法的优化结果如图 7 所示, 在 50 次蒙特卡洛仿真中, 其最优值为 -25.49 dB, 比表 4 所列参考算法中效果最好的 DELF 最优值 -24.87 dB 降低了 0.62 dB; 其均值为 -24.03 dB, 相比 DELF 的均值降低了 0.28 dB。结合表 4 可知, DMDE 算法

的优化结果明显好于对比算法。证明 DMDE 算法对 132 阵元的稀布线阵优化的有效性。

3) 天线仿真实例 3

实例 3 是针对超稀疏的阵列进行优化设计, 阵列的稀疏率为 39%, 实际总阵元数为 78, 阵列孔径为 73λ 。DMDE 算法的优化结果如图 8 所示, 在 50 次独立实验中, DMDE 算法获得的最优值为 -23.01 dB, 平均值为 -20.18 dB。结合表 4 可以看出, 与 4 种参考算法相比, DMDE 算法的最优值明显提高, 其最优值比参考算法中效果最好的 DELF 降低了 2.42 dB, 比 NBDE 降低了 3.5 dB, 比 Boolean PSO 降低了 5.57 dB, 比 BGA 算法降低了 5.93 dB。DMDE 算法的平均值与参考算法相比也有明显提升, 在稀布线阵优化性能提升明显。




图 7 DMDE 算法天线实例 2 的仿真结果

Fig. 7 Simulation results of antenna example 2 using DMDE algorithm




图 8 DMDE 算法天线实例 3 的仿真结果

Fig. 8 Simulation results of antenna example 3 using DMDE algorithm

5 结论

针对稀布线阵天线优化问题, 本文提出了一

种基于柯西-高斯双变异策略的改进差分进化算法 DMDE, 双变异策略能够使 DMDE 在全局和局部搜索之间取得更好的平衡。DMDE 利用 Tent 混沌映射生成初始种群和动态调整缩放因子机制, 增

加了初始解的多样性,避免算法过早陷入局部最优。此外,算法在搜索初期具有较强的探索能力,在后期则更加注重精细调整,提高了算法的收敛效率和稳定性。通过标准函数测试了算法的性能,证明 DMDE 在收敛速度、求解精度以及稳定性方面均表现出色。3 种典型天线设计的仿真实验结果表明:与 4 种参考算法相比,DMDE 在搜索更小的 PSL 方面展现出了显著的优势。下一步工作将围绕探索 DMDE 在机器学习、信号处理等其他领域的应用展开,以及对其参数设置和策略选择进行更深入的理论分析,进一步提升算法的性能和普适性。

参考文献

- [1] SHENG W G, WANG X, WANG Z D, et al. A differential evolution algorithm with adaptive niching and K-means operation for data clustering[J]. *IEEE Transactions on Cybernetics*, 2022, 52(7): 6181-6195.
- [2] ZHOU S C, XING L N, ZHENG X, et al. A self-adaptive differential evolution algorithm for scheduling a single batch-processing machine with arbitrary job sizes and release times[J]. *IEEE Transactions on Cybernetics*, 2021, 51(3): 1430-1442.
- [3] ZHANG F G, JIA W M, YAO M L. Linear aperiodic array synthesis using differential evolution algorithm[J]. *IEEE Antennas and Wireless Propagation Letters*, 2013, 12: 797-800.
- [4] WANG R Q, JIAO Y C, ZHANG H, et al. Synthesis of unequally spaced linear arrays using modified differential evolution algorithm[J]. *IET Microwaves, Antennas & Propagation*, 2018, 12(12): 1908-1912.
- [5] LI H, ZHANG L, JIAO Y C. Solution for integer linear bilevel programming problems using orthogonal genetic algorithm[J]. *Journal of Systems Engineering and Electronics*, 2014, 25(3): 443-451.
- [6] YANG J, LI W T, SHI X W, et al. A hybrid ABC-DE algorithm and its application for time-modulated arrays pattern synthesis[J]. *IEEE Transactions on Antennas and Propagation*, 2013, 61(11): 5485-5495.
- [7] 梁爽, 孙庚, 刘衍珩. 改进布谷鸟算法用于阵列天线方向图优化[J]. *西安电子科技大学学报*, 2019, 46(1): 174-180.
LIANG S, SUN G, LIU Y H. Improved cuckoo search algorithm for optimizing the beam patterns of linear antenna arrays[J]. *Journal of Xidian University*, 2019, 46(1): 174-180.
- [8] WEI Z F, GAO W F, LI G H, et al. A penalty-based differential evolution for multimodal optimization[J]. *IEEE Transactions on Cybernetics*, 2022, 52(7): 6024-6033.
- [9] 王维博, 冯全源. 粒子群算法在阵列天线方向图综合中的应用[J]. *西安电子科技大学学报*, 2011, 38(3): 175-180.
WANG W B, FENG Q Y. Application of PSO Algorithm in pattern synthesis for antenna arrays[J]. *Journal of Xidian University*, 2011, 38(3): 175-180.
- [10] GONG W Y, CAI Z H. Differential evolution with ranking-based mutation operators[J]. *IEEE Transactions on Cybernetics*, 2013, 43(6): 2066-2081.
- [11] TANG L X, ZHAO Y, LIU J Y. An improved differential evolution algorithm for practical dynamic scheduling in steelmaking-continuous casting production[J]. *IEEE Transactions on Evolutionary Computation*, 2014, 18(2): 209-225.
- [12] WANG X J, YAO M L, ZHANG F G, et al. Synthesis of sparse concentric ring arrays based on fitness-associated differential evolution algorithm[J]. *International Journal of Antennas and Propagation*, 2019, 2019: 4583268.
- [13] WANG X J, YAO M L, DAI D C, et al. Synthesis of linear sparse arrays based on dynamic parameters differential evolution algorithm[J]. *IET Microwaves, Antennas & Propagation*, 2019, 13(9): 1491-1497.
- [14] 戴定成, 姚敏立, 金伟, 等. 稀布同心圆环阵列的优化设计[J]. *系统工程与电子技术*, 2018, 40(4): 739-745.
DAI D C, YAO M L, JIN W, et al. Optimum design of sparse concentric rings array[J]. *System Engineering and Electronics*, 2018, 40(4): 739-745.
- [15] DAI D C, YAO M L, MA H G, et al. An effective approach for the synthesis of uniformly excited large linear sparse array[J]. *IEEE Antennas and Wireless Propagation Letters*, 2018, 17(3): 377-380.
- [16] GOUDOS S. Antenna design using binary differential evolution: Application to discrete-valued design problems[J]. *IEEE Antennas and Propagation Magazine*, 2017, 59(1): 74-93.

- [17] HAUPT R L. Thinned arrays using genetic algorithms[J]. IEEE Transactions on Antennas and Propagation, 1994, 42(7): 993-999.
- [18] MARANDI A, AFSHINMANESH M, SHAHABADI M, et al. Boolean particle swarm optimization and its application to the design of a Dual-Band Dual-Polarized Planar Antenna[C]//2006 IEEE International Conference on Evolutionary Computation. Piscataway, NJ, USA: IEEE, 2006: 3212-3218.

(编辑：于福兴)

关于本刊正式启用 OSID 码的公告

《火箭军工程大学学报》自 2025 年第 1 期始正式加入 OSID (Open Science Identity) 开放科学计划。OSID 开放科学计划是国家新闻出版署出版融合发展 (武汉) 重点实验室发起的, 面向学术期刊行业的一项开放科学公益性计划, 旨在促进学术交流, 推动科研诚信。

至此, 学报每篇论文将拥有专属的 OSID 码, 作者可以在码内对研究背景、学术价值、研究内容等问题进行语音阐述, 也可采用上传视频、图片、PPT、PDF、Word 文档等形式, 对研究方向、研究目的、研究意义、研究内容、实验数据、实验过程、实验方法、调研样本、相关资讯等内容进行介绍, 还可以分享研究过程中的趣事, 以使论文成果更加立体化展现, 提升论文阅读量、下载量和引用率, 扩大论文和作者影响力。

《火箭军工程大学学报》编辑部

二〇二五年一月