

# 基于深度学习的低副瓣稀疏阵列天线设计\*

肖远明, 贺连星<sup>†</sup>

(中国科学院微小卫星创新研究院, 上海 201304; 中国科学院大学, 北京 100049;

上海微小卫星工程中心, 上海 201304)

(2025 年 3 月 6 日收稿; 2025 年 4 月 29 日收修改稿)

Xiao Y M, He L X. Design of sparse antenna array with low sidelobe based on deep learning[J]. Journal of University of Chinese Academy of Sciences, 2026, 43(5): 650-656. DOI: 10. 7523/j.ucas. 2025. 030.

**摘要** 为满足星载相控阵天线对低成本以及低旁瓣电平的要求, 提出一种基于深度学习的天线稀疏阵列优化方法。针对大规模稀疏阵列优化问题, 传统遗传算法在优化过程中面临计算复杂度高、适应度评估耗时等问题。通过引入深度学习模型预测旁瓣电平, 替代耗时的仿真计算, 显著降低了时间复杂度。实验结果表明, 与传统遗传算法相比, 本文方法在优化效果上有一定提升, 在面向高频次工程应用场景下具有计算效率优势, 能够有效解决大规模稀疏阵列优化问题。

**关键词** 稀疏阵列; 深度学习; 遗传算法; 旁瓣优化

中图分类号: TN820.1 文献标志码: A DOI: 10. 7523/j.ucas. 2025. 030

## Design of sparse antenna array with low sidelobe based on deep learning

XIAO Yuanming, HE Liangxing

(Innovation Academy for Microsatellite, Chinese Academy of Sciences, Shanghai 201304, China;

University of Chinese Academy of Sciences, Beijing 100049, China;

Shanghai Engineering Centre for Microsatellites, Shanghai 201304, China)

**Abstract** To meet the requirements of low-cost and low-sidelobe level for space-borne phased array antennas, an optimization method for sparse arrays based on deep learning is proposed. For the optimization problem of large-scale sparse arrays, traditional genetic algorithms face issues such as high computational complexity and time-consuming fitness evaluation during the optimization process. In this paper, a deep-learning model is introduced to predict the sidelobe level, replacing the time-consuming simulation calculations, and significantly reducing the computational complexity. Experimental results show that, compared with traditional genetic algorithms, the method proposed in this paper shows some improvement in optimization effect, exhibits superior computational efficiency particularly suited for high-frequency engineering applications and can effectively solve the optimization problem of large-scale sparse arrays.

**Keywords** sparse array; deep learning; genetic algorithm; sidelobe optimization

\* 中国科学院重点部署科研专项(KGFZD-145-23-14)资助

<sup>†</sup> 通信作者, E-mail: helx@microsat. com

随着现代通信技术的快速发展,手机直连卫星(direct-to-satellite, DTS)等卫星通信技术已成为弥补地面网络覆盖不足的关键技术,它可支持语音通信、消息传递及基本网页浏览等功能<sup>[1-3]</sup>。然而,与传统卫星通信系统相比,DTS地面终端具有体积小、功率受限及天线尺寸有限等显著特征,导致其在增益与发射功率方面存在固有局限性。为克服这些限制,卫星载荷需采用大孔径相控阵天线以提升无源增益,从而实现高效的直连蜂窝通信<sup>[4]</sup>。传统大孔径相控阵天线通常依赖密集排列的阵元,这显著增加了系统的复杂性、制造成本以及卫星平台的重量与功耗。稀疏阵列技术通过优化阵元排布,在减少阵元数量的同时保持较高的辐射性能,为上述问题提供了有效解决手段,使其能更好地应对卫星平台在复杂工作环境中的挑战<sup>[5-6]</sup>。通过结合稀疏阵列技术和大孔径相控阵天线的优势,可以在保证通信性能的同时,显著优化卫星载荷的整体设计,为DTS卫星服务提供更高效、更经济的解决方案。

传统遗传算法(genetic algorithm, GA)作为一种经典的优化方法,广泛应用于天线阵列优化领域<sup>[7-9]</sup>。然而,在大规模稀疏阵列优化中,它面临显著挑战:稀疏阵列的阵元数量通常较大,传统GA需要通过仿真计算每个个体的适应度(如旁瓣电平),导致计算量呈指数级增长。

近年来,深度学习(deep learning, DL)的快速发展为天线设计提供了新的节能优化途径<sup>[10-12]</sup>。通过训练深度神经网络,DL能够以秒级速度精确预测阵列的布局与辐射性能,从而有效替代传统GA中复杂的适应度计算过程,显著降低优化过程中的计算成本和时间开销。该优化方法特别适用于高频工程应用场景,在此类工况下能够展现出显著效率优势。

针对上述挑战,本文提出一种基于DL的旁瓣电平预测方法。该方法通过构建深度神经网络模型,对GA中的适应度计算这一关键步骤进行优化,以替代传统耗时的仿真计算,从而实现稀疏阵列旁瓣电平的快速优化。具体而言,本研究首先建立基于DL的旁瓣电平预测模型,随后将该模型嵌入GA框架中,用于快速评估个体适应度值,进而有效筛选出具有最低旁瓣电平的稀疏阵列布局。实验结果表明,经过充分训练的DL网络能够实现天线阵列旁瓣电平的秒级预测,通过显著降低计算复杂度,使适应度评估时间减少了1个数

量级。最后,通过对比实验验证了所提算法的有效性和优越性。

## 1 改进的GA步骤及其原理

在传统GA框架下,适应度评估通常依赖于高计算成本的仿真或数值计算(如商用电磁仿真软件或有限元分析),单次评估耗时较长,对仿真服务器的内存要求较高。对于稀疏阵列优化问题,每个候选解(阵列布局)的旁瓣电平计算需要生成辐射方向图并计算最大旁瓣电平(max sidelobe level, MSLL),单次的适应度评估耗时过长,计算复杂度随阵元数量呈指数增长。高计算成本严重限制了传统GA在大规模阵列优化中的应用,导致优化效率低下,难以在有限时间内获得高质量解。为提升算法效率,本文通过训练一个神经网络模型来预测阵列的旁瓣电平,从而替代耗时的仿真计算。同时,还提出基于子阵级稀疏化和对称性约束的策略进一步降低优化问题的复杂度。

### 1.1 GA相关设计

在神经网络模型训练过程中,将适应度值归一化至 $[0, 1]$ 区间,可以有效地避免数据尺度差异对训练稳定性的影响。因此,本方法对适应度值的统一评判标准为最大旁瓣增益与主瓣增益的比值,计算公式如下

$$\text{Fitness} = \frac{\text{Gain}_{\text{MSL}}}{\text{Gain}_{\text{main}}}, \quad (1)$$

其中, $\text{Gain}_{\text{MSL}}$ 表示阵列的最大旁瓣增益; $\text{Gain}_{\text{main}}$ 表示阵列的主瓣增益。该比值范围限定在 $[0, 1]$ 之间,不仅确保了模型训练的稳定性与收敛性,还为DL模型的高效训练提供了规范化数据基础。

为保障阵列的圆极化辐射特性并降低射频馈电网络复杂度,本研究提出双重约束机制:

1)子阵级稀疏化:采用 $2 \times 2$ 子阵为基本单元进行稀疏化,有效地减少射频设计复杂度。

2)对称性约束:强制阵列布局满足4象限对称性,可以有效保证阵列辐射性能的一致性。为此,初始种群仅需仿真 $1/4$ 的阵元数,其余部分通过对称性生成。由于本研究采用 $2 \times 2$ 子阵作为基本单元进行稀疏化,阵列规模 $M \times M$ 必须为偶数。然而如图1所示,根据 $M$ 的具体形式( $M = 2m$ 或 $M = 2(m+1)$ , $m$ 为偶数正整数),对称性约束的数学表达式及设计变量的压缩方式均有所不同。图1(a)和1(b)中分别表示一个不同形式的 $M \times M$




图 1 稀疏阵列排布示意图

Fig. 1 Diagram of sparse array arrangement

的稀疏阵排布,其中,每个方框都表示为一个天线单元,保留的阵元用蓝色单元表示,稀疏掉的单元用白色方框表示。以下是具体的数学描述及分析:

1)如图 1(a)所示,当  $M = 2m$  ( $m$  为偶数正整数)时,阵列可划分为  $m \times m$  个  $2 \times 2$  子阵。此时,左上半阵列可进一步划分为一个  $m/2 \times m/2$  的子阵用于稀疏优化。因此,初始种群的个体解可表示为

$$x = [x_1, x_2, \dots, x_{N_{\text{opt}}}], \quad (2)$$

其中,优化变量数量为

$$N_{\text{opt}} = \left(\frac{m}{2}\right)^2 = \frac{m^2}{4}, \quad (3)$$

其余子阵可通过 4 象限对称性生成。由于个体解为二进制数组(0 表示稀疏,1 表示保留),则整阵保留的阵元总数为

$$N_R = 16 \times \sum_{i=1}^{N_{\text{opt}}} x_i. \quad (4)$$

2)如图 1(b)所示,当  $M = 2(m+1)$  ( $m$  为偶数正整数)时,阵列可划分为  $(m+1) \times (m+1)$  个  $2 \times 2$  子阵。由于阵列中轴线的子阵因维度奇偶性差异需单独处理,优化过程中需将左上半阵列划分为  $(m/2+1) \times (m/2+1)$ 。因此,初始种群的个体解数量为

$$N_{\text{opt}} = \left(\frac{m}{2} + 1\right)^2. \quad (5)$$

设  $x_1$  为阵列中心点的子阵状态,  $x_2 \sim x_m$  为中轴线上的子阵状态,则整阵保留的阵元总数为

$$N_R = 4 \times x_1 + 8 \times \sum_{i=2}^{m+1} x_i + 16 \times \sum_{i=m+1}^{N_{\text{opt}}} x_i. \quad (6)$$

在适应度评估时,将优化子阵扩展为完整的  $2 \times 2$

结构,以确保计算的一致性。

为验证上述方法的有效性,本研究对 2 组典型数据进行了对比分析,如表 1 所示。实验结果表明,所提出的子阵级稀疏化和对称性约束机制显著降低了优化问题的复杂度。需要特别说明的是,本文基于实际的工程设计需求,将采用  $50 \times 50$  阵列规模开展稀疏优化研究。其次,为了满足稀疏阵的主瓣增益降幅控制在系统可接受的 2 dB 范围内,选择 56.16% 的稀疏率进行稀疏,即保留 1 404 个阵元。

## 1.2 GA 具体流程

改进的 GA 流程如图 2 所示。具体流程如下:

1)DL 预测模型训练。使用仿真数据训练 DL 模型,使其能够准确预测给定阵列布局的最大旁瓣增益与主瓣增益的比值。训练完成后,将模型导出并用于后续适应度评估。

2)种群初始化。根据子阵级稀疏化和对称性约束机制的策略,随机生成  $NP$  组含  $N_{\text{opt}}$  个体的  $[x_1, x_2, \dots, x_{N_{\text{opt}}}]$  作为当前的初始解群。

3)适应度评估。采用训练完备的 DL 模型预测阵列布局的 MSLL 与主瓣增益的比值。在每次适应度计算前,将每个个体解扩展为完整的  $2 \times 2$  结构,以确保计算一致性。并在评估完成后重新缩小为含  $N_{\text{opt}}$  个体的个体解。

4)选择操作。基于适应度值,采用轮盘赌选择法从当前种群中筛选优秀个体进入下一代,适

表 1 设计变量压缩分析

Table 1 Design variable compression analysis

| 阵列规模  | $M$ | $m$ | $2 \times 2$ 子阵总数 | $N_{\text{opt}}$ | 压缩率/% |
|-------|-----|-----|-------------------|------------------|-------|
| 40×40 | 40  | 20  | 400               | 100              | 6.25  |
| 50×50 | 50  | 24  | 625               | 169              | 6.76  |

应度值越高的个体被选中的概率越大。

5)交叉操作。以预设交叉概率 $P_c$ ,对选中的个体执行单点交叉操作,生成新的子代个体,以增强种群的多样性。

6)变异操作。以预设变异概率 $P_m$ 对子代个体进行变异,随机翻转部分阵元的状态。

7)更新种群。用新生成的子代个体替换当前种群,形成新一代种群。

8)判断终止条件。若达到最大迭代次数或适应度值收敛至稳定状态,则终止迭代;否则,返回步骤3)继续优化。

9)输出最优布局。输出适应度比值最小的稀疏阵列布局,完成优化流程。

在改进的GA中,时间复杂度优化的核心在于适应度计算效率的提升。传统GA的适应度计算复杂度为 $O_{sim}=G \cdot NP \cdot O(S)$ ,其中 $O(S)$ 表示仿真计算的时间复杂度;而采用预训练的神经网络模型替代计算仿真后,改进算法的适应度计算复杂度降至 $O_N=G \cdot NP \cdot O(M)$ 。由于神经网络推理时间 $O(M)$ 显著低于仿真计算 $O(S)$ ,即 $O(M) \ll O(S)$ ,因此改进算法的时间复杂度得到有效降低。

为验证方法的有效性,本文基于以下参数设置对阵列进行了优化,具体仿真参数如表2所示。

表 2 仿真参数

| Table 2 Simulation parameters |        |
|-------------------------------|--------|
| 仿真参数                          | 数值     |
| 频率/GHz                        | 3.55   |
| 波长/m                          | 0.0845 |
| 阵元间距 d/m                      | 0.044  |
| 满阵的天线单元数 $N$                  | 2500   |
| 保留的天线单元数 $N_R$                | 1404   |
| 优化子阵数 $N_{opt}$               | 169    |
| 种群规模 $NP$                     | 200    |
| 迭代进化次数 $G$                    | 100    |
| 交叉概率 $P_c$                    | 0.8    |
| 变异概率 $P_m$                    | 0.05   |

2 基于DL的预测模型设计

本研究采用全连接神经网络(fully connected neural network, FCN)构建阵列旁瓣电平预测模型。FCN作为一种多层感知器结构,通过输入层、隐藏层和输出层之间的全连接方式,能够有效建立输入特征与输出目标之间的非线性映射关系。具体而言,网络结构包含2层隐藏层(每层1 024个节点),并采用修正线性单元(rectified linear unit, ReLU)作为激活函数,用于预测阵列布局的旁瓣电平。所提方法主要包含2个关键步骤:1)构建训练数据集;2)通过训练完备的FCN建立阵列布局与旁瓣电平之间的映射关系。

2.1 构建训练数据集

DL模型的训练依赖于大规模数据集的支持。本研究通过以下流程构建训练数据集:

1)数据生成。采用随机采样方法生成阵元布局数据集。训练数据基于子阵级优化后的规模(169个阵元),以充分捕捉阵元间电磁耦合效应,提升模型预测精度。每个样本表征为一个169维二进制向量,其中元素值1表示阵元保留,0表示阵元移除,且稀疏率与最终设计要求保持一致。基于快速傅里叶变换计算各布局的阵列因子,并通过峰值检测算法提取主瓣与旁瓣特征,进而计算最大旁瓣增益与主瓣增益的比值。该方法构建了具有充分多样性的数据集,确保了样本数据的广泛覆盖性和代表性,为模型训练提供了可靠的数据基础。

2)数据划分。采用随机分层抽样方法,实验共生成10 000组样本,将数据集按8:1:1的比例划分为训练集(80%)、验证集(10%)和测试集




图 2 本文改进的GA框架

Fig. 2 The improved genetic algorithm framework in this paper

(10%)。其中,训练集用于模型参数的学习,验证集用于参数优化与模型选择,测试集则用于评估模型的泛化性能。该划分方式有效避免了模型过拟合问题,同时确保了各子集中数据分布的均衡性,从而提升了模型训练的鲁棒性及评估结果的可靠性。

## 2.2 DL 网络设计和训练

在数据预处理完成后,构建并训练一个 FCN 网络。如图 3 所示,该网络采用 3 层架构:输入层、隐藏层和输出层。其中,输入层由 169 个节点构成,每个节点表征阵元的二元状态(激活或未激活),用于接收阵列布局数据。隐藏层包含 2 个全连接层,每层设置 1 024 个节点,并采用 ReLU 激活函数以增强模型非线性表达能力并加速收敛过程。输出层由单一节点组成,用于预测阵列的增益比值。该网络结构通过全连接方式实现了从阵列布局到旁瓣电平的高效非线性映射。

其次,采用 Adam 优化器(初始学习率 0.001)以兼顾稀疏优化问题的适应性和训练稳定性,设置批次大小为 32 以平衡效率与梯度可靠性,并添加 L2 正则化(系数  $1 \times 10^{-4}$ )用于抑制过拟合。

为验证训练完备的 FCN 网络的泛化性能,本研究采用独立于训练集的测试集进行评估。如图 4 所示,通过对比测试集中随机选取的阵列布局的仿真比值与网络预测结果,观察到两者具有高度一致性。实验结果表明,所训练的 FCN 网络能够准确预测给定天线阵列布局的最大旁瓣增益与主瓣增益的比值,验证了模型的可靠性和预测精度。

为量化评估 FCN 网络的预测精度,采用均方误差(mean square error, MSE)作为评价指标,计算公式如下

$$\text{MSE} = \frac{1}{N_L} \times \sum \left\| \text{Fitness}_{\text{sim}} - \text{Fitness}_{\text{pre}} \right\|^2. \quad (7)$$




图3 FCN网络架构

Fig. 3 FCN network architecture




图4 测试集中随机 100 个阵列布局的模拟和预测结果

Fig. 4 Simulation and prediction results for 100 random array layouts in the test set

其中:  $\text{Fitness}_{\text{sim}}$  表示每个样本的模拟适应度值,  $\text{Fitness}_{\text{pre}}$  表示网络预测的适应度值,  $N_L$  表示训练样本总数。经 6 000 次训练迭代后, MSE 收敛至  $2 \times 10^{-5}$  量级, 表明所训练的 FCN 网络具有较高的预测精度。

需要说明的是, 本文训练的 FCN 网络模型是针对特定工程应用场景进行优化的, 其适用范围限定于  $50 \times 50$  阵元规模及 56.16% 稀疏率的阵列布局。其次, 尽管模型训练阶段的耗时相较于传统 GA 优势不明显, 但在高频次工程应用场景下(如阵列参数动态调整、实时波束重构等), 该模型能够取代耗时较高的适应度值计算, 展现出显著的计算效率优势。当然, 本文提出的 DL 框架理论上可扩展至其他优化算法(如粒子群算法、压缩感知等)。

## 3 GA 仿真验证

为验证所提方法的有效性, 通过仿真实验对比分析改进 GA 与传统 GA 在稀疏阵列布局优化中的性能差异。实验以获取最低适应度比值的最优稀疏阵列布局为目标, 将训练完备的 FCN 网络嵌入 GA 的适应度评估模块中。优化结果分别如图 5(a) 和 5(b) 所示, 验证了所提方法的优越性。

为评估稀疏阵列性能, 对  $50 \times 50$  满阵及稀疏阵列的辐射性能进行了对比仿真分析。图 6 展示了三者的三维方向图, 图 6(a) 所示的满阵辐射方向图显示其旁瓣电平抑制约为 -14 dBc, 而图 6(b) 和 6(c) 中的 2 种稀疏阵列结构则表现出更优的旁瓣抑制性能, 均达到约 -20 dBc。结果表明稀疏阵列的旁瓣电平显著降低, 验证了优化布局的有效性。

基于图 7 的二维平面方向图分析, 满阵的峰值旁瓣电平为 -13.47 dBc, 而本文方法优化所得




图5 优化后的稀疏阵排布示意图

Fig. 5 Schematic diagram of the optimized sparse array arrangement

阵列的峰值旁瓣电平为 $-22.18$  dBc,较传统GA优化结果( $-20.94$  dBc)进一步降低了 $1.24$  dBc,且峰值均出现在 $xoz$ 面方向图上。仿真结果表明,本文方法在旁瓣抑制性能上优于传统GA,同时显著优于满阵布局,验证了所提方法的有效性。

此外,如图8所示的收敛曲线表明,改进的GA算法在38代内实现了快速收敛,而传统算法需迭代75代方可收敛。实验结果显示,本文方法最终获得的适应度值为 $0.421$ ,优于传统算法的 $0.448$ 。这一性能提升主要得益于本文方法引入的基于DL的高效适应度评估机制,该机制显著减少了单次适应度评估的计算时间,从而在相同时间内支持更多迭代次数,增强了算法的全局搜索能力,并有效降低了陷入局部最优的风险。实验结果验证了所提方法在优化效率上的提升。

实验数据表明,改进GA优化后的阵列性能较传统方法具有明显改善。图7中改进算法优化阵列的辐射方向图的旁瓣电平较传统GA降低 $1.24$  dBc;图8的收敛曲线进一步证实,该算法最终获得的适应度值比传统GA低 $0.027$ 。这些结果从辐射特性和收敛性能2个维度验证了所提算法在阵列优化性能上的改进效果。




图6 阵列三维方向图

Fig. 6 Array three-dimensional pattern

仿真结果如表3所示。当稀疏率为 $56.16\%$ 时(从满阵 $2500$ 阵元降至 $1404$ 阵元),优化后的稀疏阵列增益较满阵下降约 $1.9$  dBc,而MSLL降低 $8.71$  dBc,验证了稀疏优化方法的有效性。此外,在计算效率方面,本文方法仅耗时 $16.27$  s,相较于传统GA的 $267.36$  s,计算速度提升 $16$ 倍,显著提高了优化效率。实验结果表明,本文方法在保证性能的同时,大幅降低了计算复杂度,尤其适用于大规模阵列的快速优化设计。




图7 阵列平面方向图  
Fig. 7 Array plane pattern




图8 收敛曲线  
Fig. 8 Convergence curve

表3 满阵与2种方法的比较

| Table 3 | Full array and comparison of two methods |        |          |        |
|---------|------------------------------------------|--------|----------|--------|
|         | 阵元数目                                     | 增益/dBc | MSLL/dBc | 仿真耗时/s |
| 满阵      | 2500                                     | 39.92  | -13.47   | —      |
| 传统GA    | 1404                                     | 37.96  | -20.94   | 267.36 |
| 本文      | 1404                                     | 38.03  | -22.18   | 16.27  |

4 结论

本研究提出一种基于DL的低副瓣稀疏阵列优化方法。该方法通过将训练完备的FCN网络预测模型嵌入GA框架中,显著提升了稀疏阵列优化的计算效率。实验结果表明,与传统GA相

比,所提方法在计算时间上具有显著优势,有效解决了传统方法在优化过程中存在的计算复杂度高、适应度评估耗时长等问题。仿真实验验证了该方法的有效性,为大规模阵列优化设计提供了一种可行的快速解决方案。

参考文献

[ 1 ] 孙耀华, 彭木根. 面向手机直连的低轨卫星通信: 关键技术、发展现状与未来展望[J]. 电信科学, 2023, 39(2): 25-36. DOI: 10.11959/j. issn. 1000-0801. 2023031.

[ 2 ] 王达, 童建飞, 穆飞宇. 手机直连卫星通信: 发展现状、应用场景和标准演进[J]. 无线电通信技术, 2023, 49(5): 795-802. DOI: 10.3969/j. issn. 1003-3114. 2023. 05. 003.

[ 3 ] 孙晓南, 周世东, 侯利明, 等. 存量5G手机直连低轨卫星通信技术研究[J]. 信息通信技术, 2023, 17(5): 22-31. DOI: 10.3969/j. issn. 1674-1285. 2023. 05. 005.

[ 4 ] Xiao Y M, He L X, Wei X L. Dual-band dual-circularly polarized shared-aperture phased array for S-/C-band satellite communications[J]. Electronics, 2025, 14(2): 387. DOI: 10.3390/electronics14020387.

[ 5 ] 张骆怡, 张明, 董亮, 等. 大规模平面阵列稀疏优化技术综述[J]. 空间电子技术, 2022, 19(6): 21-29.

[ 6 ] Viganó M C, Llorens del Río D, Bongard F, et al. Sparse array antenna for ku-band mobile terminals using 1 bit phase controls[J]. IEEE Transactions on Antennas and Propagation, 2014, 62 (4) : 1723-1730. DOI: 10.1109/TAP. 2014. 2301439.

[ 7 ] 边霞, 米良. 遗传算法理论及其应用研究进展[J]. 计算机应用研究, 2010, 27(7): 2425-2429, 2434. DOI: 10.3969/j. issn. 1001-3695. 2010. 07. 006.

[ 8 ] 陈旭, 丁作诚, 徐磊, 等. 基于遗传算法的平面稀疏阵列优化及性能分析[J]. 舰船电子对抗, 2022, 45(2): 52-56, 117. DOI: 10.16426/j. cnki. jcdzdk. 2022. 02. 011.

[ 9 ] Wen Y Q, Wang B Z, Ding X. A wide-angle scanning and low sidelobe level microstrip phased array based on genetic algorithm optimization[J]. IEEE Transactions on Antennas and Propagation, 2016, 64(2): 805-810. DOI: 10.1109/TAP. 2015. 2507173.

[ 10 ] Shi D, Lian C, Cui K Y, et al. An intelligent antenna synthesis method based on machine learning [J]. IEEE Transactions on Antennas and Propagation, 2022, 70(7): 4965-4976. DOI: 10.1109/TAP. 2022. 3182693.

[ 11 ] Gençoğlu D N, Arslan M T, Çolak Ş, et al. Ultra-Wideband (UWB) characteristic estimation of elliptic patch antenna based on machine learning techniques [J]. Frequenz, 2020, 74(9/10): 351-358. DOI: 10.1515/freq-2019-0210.

[ 12 ] You X C, Lin F H. Inverse design of reflective metasurface antennas using deep learning from small-scale statistically random pico-cells [J]. Microwave and Optical Technology Letters, 2024, 66 (2) : e34068. DOI: 10.1002/mop. 34068.