

吴浪, 龙飞. 基于 GA-BP 的双频微带贴片天线设计与应用[J]. 智能计算机与应用, 2026, 16(3): 128-134. DOI: 10.20169/j.issn.2095-2163.25091102

基于 GA-BP 的双频微带贴片天线设计与应用

吴浪, 龙飞

(贵州民族大学 数据科学与信息工程学院, 贵阳 550025)

摘要: 针对当前双频微带天线设计周期长、难以同时满足多性能要求等难题, 设计了一种融合机器学习的双频微带贴片天线自动设计和优化方法。本文提出一种结合遗传算法 (Genetic Algorithm, GA) 与 BP 神经网络的模型—GA-BP。该模型通过遗传算法优化 BP 神经网络的权值和阈值, 以提升神经网络的预测性能。为验证本文所提出的模型的有效性, 设计了一款双频微带贴片天线用于构造数据集, 并基于同一组数据集对 GA-BP 与 BP 进行训练与验证。实验结果表明, GA-BP 相较于传统的 BP 神经网络具有更强的稳定性和更准确的预测结果, 在正向预测和逆向预测中均表现更优。

关键词: 机器学习; 遗传算法; BP 神经网络; 正向预测; 逆向预测

中图分类号: TP183 **文献标志码:** A **文章编号:** 2095-2163(2026)03-0128-07

Design and application of dual-frequency microstrip patch antenna based on GA-BP

WU Lang, LONG Fei

(School of Data Science and Information Engineering, Guizhou Minzu University, Guiyang 550025, China)

Abstract: To address the current challenges of prolonged design cycles and difficulty in simultaneously meeting multiple performance requirements in dual-band microstrip antenna design, the paper proposes an automated dual-band microstrip patch antenna design and optimization approach incorporating machine learning. This work proposes architecture combining Genetic Algorithm (GA) and Back Propagation neural network (BP)—GA-BP. This framework optimizes the weights and thresholds of the BP neural network through the genetic algorithm to enhance the prediction performance of the neural network. To verify the effectiveness of the proposed model, a dual-band microstrip patch antenna is designed to construct a dataset, and both models are trained and validated based on the same dataset. The experimental results show that GA-BP has stronger stability and more accurate prediction results compared to the traditional BP neural network, and performs better in both forward and reverse predictions.

Key words: Machine Learning; Genetic Algorithm; Back Propagation Neural Network; forward prediction; inverse prediction

0 引言

长期以来, 天线一直是射频前端中最重要的部件之一, 广泛应用于雷达、通信等领域^[1]。为了满足实际应用需求, 所设计的天线既要具有体积小巧的优点, 又要具有良好的增益、S 参数、有效带宽等性能^[2-4]。且随着移动通信中跳频、扩频等通信技术的发展, 当前天线需要同时满足多个终端的要求。这要求天线需要覆盖不同的工作频率范围。因此多频段通信技术成为现代通信领域迫切需要研究的问

题。传统的天线设计要求研究人员拥有专业的天线知识以及大量的设计经验, 并且对天线的电磁特性进行数值处理通常涉及大量的计算。尤其是当天线的拓扑结构比较复杂时, 建模与仿真需要大量的时间, 且难以寻到最优解。多种因素限制了天线的研究进展, 因此, 亟需结合其他方法解决上述问题。

随着科技的不断发展, 人工智能逐渐应用在各个领域。机器学习作为其核心, 被广泛应用于数据挖掘、图像处理、医学检验等多个方面^[5-7]。主要思想是模拟人脑的信息处理机制, 通过大量已有的数

基金项目: 贵州省基础研究计划(自然科学基金)项目(QKHJC-ZK[2023]YB144); 贵州民族大学科学基金(GZMUZK[2021]YB05); 贵州民族大学博士科研启动基金(GZMUZK[2024]QD02)。

作者简介: 吴浪(1998—), 男, 硕士研究生, 主要研究方向: 复杂信息分析与计算。

通信作者: 龙飞(1978—), 女, 副教授, 硕士生导师, 主要研究方向: 计算机应用技术, 深度学习。Email: lofeing@126.com。

收稿日期: 2025-09-11

据自动学习和提取特征,从而实现对新数据的预测和分类。

在过去的几年里,一系列的工作已经证明了基于人工智能的方法在解决电磁问题方面的潜力。机器学习辅助天线优化设计已在天线领域获得广泛应用^[8-10],该技术减少了设计人员以往在天线设计中对经验和电磁模拟器的依赖,显著提升了天线优化设计的效率与迭代速度。在训练过程中,人工神经网络(ANN)通过调整内部参数来模拟几何变量与电磁响应之间的关系^[11-15]。多种机器学习方法已被广泛应用于微带天线的驱动替代建模过程中^[16],Wu等学者^[17]结合机器学习方法在天线几何形状与天线性能之间建立代理模型,大幅度提升了天线的设计优化效率。Ahmed^[18]结合机器学习方法提升天线方向图可重构性的优化效率,缩短开发周期并增强可重构性的稳定性。Dan等学者^[19]结合多个机器学习模型,实现天线的自动化智能合成。该模型可根据天线性能要求自动计算预测出天线的几何参数。通过3种天线仿真验证,验证了该模型的准确率超过了99%。

针对天线设计中存在的复杂多目标优化问题,本文提出了一种基于遗传算法(GA)和BP神经网络相结合的遗传反向传播网络(GA-BP)混合模型。利用遗传算法的全局搜索能力对神经网络的权值和阈值进行优化,显著提高了模型的性能,尤其是在复杂的多目标优化任务中表现突出。

1 天线分析与设计

1.1 双频微带天线理论分析

在天线设计中,双频微带贴片天线应同时具备以下几个特点:跨多个频段独立工作以适应不同的通信需求;高增益以保证信号传输质量。设计微带贴片天线首先需要选择合适的介质基板,假设基板的介电常数为 ϵ_r ,对于工作频率为 f 的矩形微带天线,介质基板厚度 H 可有如下公式计算:

$$H = \frac{c}{4f\sqrt{\epsilon_r}} \quad (1)$$

其中, c 是光速, $c=3\times 10^8$ m/s。辐射贴片的宽度 W_0 可由下式计算得到:

$$W_0 = \frac{c}{2f\sqrt{\epsilon_r + 1}} \quad (2)$$

考虑到介质基板相对介电常数 ϵ_r 与微带结构边缘场效应。辐射单元的长度 L_0 应为:

$$L_0 = \frac{c}{2f\sqrt{\epsilon_e}} - 2\Delta L \quad (3)$$

其中, ϵ_e 表示有效介电常数, ΔL 表示等效辐射缝隙长度。可分别用下式计算得到:

$$\epsilon_e = \frac{\epsilon_r + 1}{2} + \frac{\epsilon_r - 1}{2} \left(1 + 12 \frac{h}{W}\right)^{-\frac{1}{2}} \quad (4)$$

$$\Delta L = 0.412h \frac{(\epsilon_e + 0.3) \left(\frac{W}{h} + 0.246\right)}{(\epsilon_e - 0.258) \left(\frac{W}{h} + 0.8\right)} \quad (5)$$

对于同轴线馈电的微带贴片天线,在确定贴片长度 L_0 和宽度 W_0 后,还需要确定同轴馈电点的位置,具体位置的数学公式为:

$$L = \frac{L}{2} \left(1 - \frac{1}{\sqrt{\delta_{re}}}\right) \quad (6)$$

其中, δ_{re} 的计算公式如下:

$$\delta_{re} = \frac{\epsilon_r + 1}{2} + \frac{\epsilon_r - 1}{2} \left(1 + 12 \frac{h}{L}\right)^{-\frac{1}{2}} \quad (7)$$

1.2 双频微带天线设计

双频微带天线目前可通过使用多层金属片、开槽或引入矩形缺口的正方形金属片等手段来实现^[19-23]。但这些都会增加微带贴片的规模。本文选择一种相对简单并且不会改变天线规模的方法,即通过馈电点来获取辐射贴片长度对应的一个谐振频率,宽度对应的另外一个谐振频率,从而实现双频的目的。具体结构如图1所示。由图1中可知, x 轴上的 A 点会激发 TM_{10} 模式,由于 A 点位于辐射贴片 y 方向的中心线上,因此不会激发其他 TM_{0n} 模式。同理 B 点也是如此,只会激发 TM_{01} 模式。然而,若将馈电点位于 C 点,那么就会同时激发 TM_{10} 模式和 TM_{01} 模式,从而实现双频的目的。因此本文先根据式(1)~(6)确定矩形贴片的长度、宽度以及馈电点位置,再选择合适的基板。基于上述设计思路,本文构建了一种双频微带贴片天线,结构如图2所示。如上所述,矩形贴片的长度、宽度、馈电点的位置基板的厚度对微带天线的性能至关重要。因此本文设计的模型主要是对参数 $[H, W_0, L_0, L_1, L_2]$ 进行优化。参数的取值以及变化范围见表1。

确定天线结构后,利用电磁仿真软件(HFSS)对天线进行建模仿真。通过改变这5个参数,在1.5~3.0 GHz的频率范围进行收集数据,共收集了1760组数据。其中90%作为训练集用于训练神经网络,10%作为测试集。






图1 单馈电双频矩形微带天线

Fig. 1 Single-fed dual-frequency rectangular microstrip antenna



(a) 天线俯视图



(b) 天线侧视图

图2 微带贴片天线结构图

Fig. 2 Structure diagram of microstrip patch antenna

表1 贴片天线5个几何参数的变化范围

Table 1 Range of variation for the 5 geometric parameters of the patch antenna

参数	H	W_0	L_0	L_1	L_2
最小值	1.2	40	24	5	8
最大值	1.8	47	28	8	12

2 算法模型

2.1 神经网络模型

BP神经网络是一种前馈神经网络,每层计算的结果正向传播,误差反向传播。通过梯度下降反向调整神经元之间的连接权值和阈值,直到满足设定的目标误差或达到迭代次数,训练结束。由Kolmogorov定理可知,3层的神经网络理论上可以拟合任意函数。因此目前大多数均采用3层结构。一个典型的3层BP神经网络结构如图3所示,由输入层、隐藏层和输出层组成,每层均包含多个神经元。




图3 神经网络结构图

Fig. 3 Neural network structure diagram

神经网络模型的每一层均通过神经元的权值、偏置和激活函数进行转换。该神经网络模型的隐含层输出 H 可通过下述公式计算:

$$H_i = f\left(\sum_{j=1}^n x_j \omega_{ij} - a_j\right), i = 1, 2, \dots, n, j = 1, 2, \dots, l \quad (8)$$

其中, f 表示隐藏层激活函数; ω_{ij} 表示输入与隐藏层的连接权值; a_j 表示隐藏层偏置。神经网络模型的预测输出可由下式计算:

$$y_k = \sum_{j=1}^l H_j \omega_{jk} - b_k, k = 1, 2, \dots, m \quad (9)$$

其中, ω_{jk} 表示隐藏层与输出的连接权值, b_k 表示输出层阈值。模型的预测误差定义为:

$$e_k = Y_k - y_k \quad (10)$$

其中, Y_k 表示目标输出。在迭代过程中,神经网络的连接权值和阈值更新过程为:

$$\omega_{ij} = \omega_{ij} + \beta H_j (1 - H_j) x_i \sum_{k=1}^m \omega_{jk} e_k \quad (11)$$

$$\omega_{jk} = \omega_{jk} + \beta H_j e_k \quad (12)$$

$$a_j = a_j + \beta H_j (1 - H_j) \sum_{k=1}^m \omega_{jk} e_k \quad (13)$$

$$b_k = b_k + e_k \quad (14)$$

其中, β 表示学习率。神经网络模型的收敛性评价引入了神经网络真实输出与目标输出之间的均方误差(MSE)函数。数学定义公式为:

$$\text{MSE} = \frac{1}{m} \sum_{k=1}^m (Y_k - y_k)^2 \quad (15)$$

通过训练神经网络模型,可以建立电磁特性与参数之间的映射关系,从而实现天线的自动化设计。在正向预测中,模型的输入为5个参数,用列向量表示为 $x = [H, W_0, L_0, L_1, L_2]^T$, 输出则是2处谐振频率,用列向量表示为 $y = [y_1, y_2]^T$ 。隐藏层神经元的个数严重影响了模型的预测能力,个数太多会导致

模型过拟合,过少则会导致数据特征提取不充分,最终预测结果不符合真实结果^[24],无法用于实际应用。神经元的个数可以根据以下经验公式确定:

$$h = a + \sqrt{m + n} \quad (16)$$

其中, h 表示神经元的个数; m 表示输入向量的个数; n 表示输出向量的个数; a 表示 1~10 的整数^[25]。经过实验验证,当隐藏层神经元个数为 12 时,模型达到最优性能。本文隐藏层选择 Sigmoid 激活函数,输出层使用了线性激活函数,学习率为 0.05,迭代次数为 200。

2.2 遗传算法优化神经网络

BP 神经网络的初始权值和阈值都是随机设置的,更新过程依赖梯度下降法实现,容易陷入局部最优的问题。并且这个过程需要大量的计算,因为每次迭代都需要重新计算所有连接权值和阈值。此外,梯度步长的设置直接影响了模型的性能,在更新过程中不能保证达到最优结果。遗传算法是一种启发式算法,具有强大的全局搜索能力,可以对神经网络存在的问题进行弥补^[26-28]。本文利用遗传算法来优化 BP 神经网络的权值和阈值,用于解决上述问题。

本文遗传算法的参数设定如下:初始种群 $N = 50$,交叉概率 $P_1 = 0.2$,变异概率 $P_2 = 0.05$ 。遗传算法优化 BP 神经的过程如图 4 所示。主要包括以下 4 个步骤:

步骤 1 确定神经网络的权值和阈值的个数,并随机初始化权值和阈值进行编码得到初始种群。

步骤 2 对权值和阈值进行解码,并传递给神经网络,由训练集进行训练网络,查看最终的适应度值。

步骤 3 根据“适者生存”原理,选择适应度值好的进行复制,选择方法主要采用轮盘赌法,适应度值越高越容易被选中。再进行交叉和变异操作,以产生新的个体,同时对新个体进行训练测试,查看是否比原来的染色体效果好,保留最好的个体。

步骤 4 判断是否满足终止条件,不满足则返回到步骤 2,满足则迭代结束,最终保留下来的染色体即为最优值,解码返还给神经网络。

在该过程中,适应度值代表着染色体的优劣,定义公式如下:

$$\text{Fitness} = \frac{1}{m} \sum_{i=1}^m |P_{ri} - O_{pi}| \quad (17)$$

其中, P_r 表示预测值; O_p 表示真实值; m 表示

输出层神经元的个数。式(17)求得的是输出的平均误差,将其作为多目标优化的评价指标,可直观反映遗传算法对 BP 神经网络的优化效果,适应度值越小说明优化效果越好。

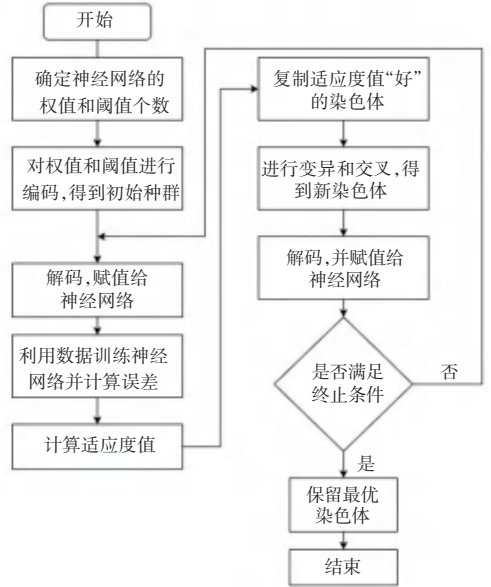


图 4 GA 优化 BP 网络流程图

Fig. 4 Flowchart of GA-optimized BP network

3 实验


3.1 正向预测

将上述仿真天线收集到的数据集进行实验,其中随机选择 90% 作为训练集,剩余 10% 作为测试集。并基于同一组数据集对 BP 和 GA-BP 进行训练,分别计算测试集的绝对误差进行比较,2 种模型之间的输出误差比较如图 5 所示。可以看出,GA-BP 模型中 2 个谐振频率的误差比 BP 模型明显更小、更稳定,大多数误差集中在 0.03 左右。这表明 GA-BP 模型具有更高的精度和鲁棒性。此外,选择均方误差作为损失函数,用来评判模型的收敛性。比较训练集和测试集的均方误差(MSE),如图 6 所示。训练集和测试集在 MSE 上的差异极小,这表明该模型具有很强的泛化能力。

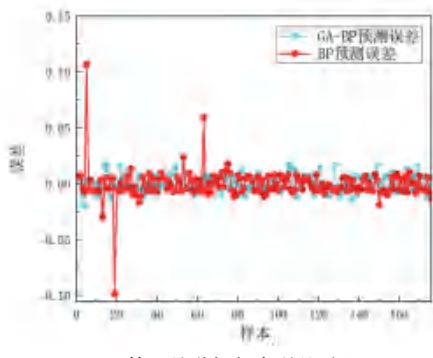
本文利用训练完成的 BP 和 GA-BP 模型,对同一组结构参数下的天线性能进行预测,该组结构参数的选取采用“边缘值+中间值+随机值”的组合方式,既涵盖了参数取值范围的边界与典型的中间水平,又引入了随机分布的样本点,可全方面覆盖天线结构参数的可能取值空间,从而更充分地验证了模型对不同参数选取的适配能力,且能有效验证模型的鲁棒性。此外,通过 HFSS 仿真对预测结果进行

验证。对比结果见表 2。由表 2 可以看出,GA-BP 模型的预测结果更接近仿真结果,误差更小,说明

GA-BP 模型对天线电磁特性的预测精度更高,也符合图 5 的结果。



(a) 第 1 处谐振频率预测误差对比



(b) 第 2 处谐振频率误差对比

图 5 BP 模型和 GA-BP 模型预测误差对比图

Fig. 5 Comparison chart of prediction errors between BP model and GA-BP model

表 2 实验预测结果表

Table 2 Experimental prediction results table

中心频率	H	W_0	L_0	L_1	L_2	仿真	BP_预测	GA-BP 预测
第 1 中心频率	1.20	41.0	26.00	5.00	10.00	1.72	1.81	1.73
	1.25	46.5	26.50	5.50	10.25	1.53	1.80	1.53
	1.30	47.0	27.00	6.00	11.00	1.52	1.76	1.51
	1.35	42.6	27.25	6.25	11.50	1.67	1.71	1.66
	1.40	45.0	27.50	6.75	8.50	1.58	1.65	1.58
	1.45	44.5	26.50	7.00	8.75	1.59	1.60	1.59
	1.50	43.0	25.50	7.50	9.50	1.65	1.69	1.65
	1.70	42.8	24.25	6.50	9.25	1.65	1.66	1.65
第 2 中心频率	1.80	41.5	24.00	5.75	8.25	1.69	1.78	1.70
	1.20	41.0	26.00	5.00	10.00	2.59	2.29	2.60
	1.25	46.5	26.50	5.50	10.25	2.65	2.56	2.63
	1.30	47.0	27.00	6.00	11.00	2.52	2.61	2.51
	1.35	42.6	27.25	6.25	11.50	2.50	2.59	2.50
	1.40	45.0	27.50	6.75	8.50	2.47	2.30	2.46
	1.45	44.5	26.50	7.00	8.75	2.55	2.54	2.54
	1.50	43.0	25.50	7.50	9.50	2.64	2.61	2.63
1.70	42.8	24.25	6.50	9.25	2.73	2.86	2.71	
1.80	41.5	24.00	5.75	8.25	2.74	2.67	2.73	

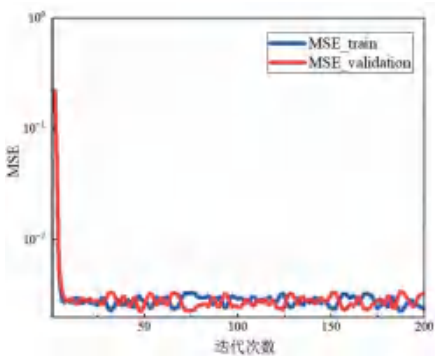


图 6 训练集和测试集的均方误差变化

Fig. 6 Changes in Mean Square Error of training set and test set

3.2 逆向设计

在逆向设计中,基于所提出的 GA-BP 模型设计了一款多频段天线,以验证其实际应用价值。同

样,在设计过程中,将天线的性能参数输入到训练好的模型中,即可直接获得天线的几何参数。本文设计的天线目标性能为:在 1.5~3.0 GHz 频率范围内 $|S_{11}| < -10$ dB, $f_1 = 1.77$ GHz, $f_2 = 2.44$ GHz, 2 个中心频率。选择一组满足上述性能的目标参数为: $\mathbf{x}_{\text{目标}} = [1.60, 40.0, 27.9, 6.6, 10.5]^T$, $\mathbf{x}_{\text{BP}} = [1.55, 40.50, 27.25, 6.53, 9.77]$, $\mathbf{x}_{\text{GA-BP}} = [1.59, 40.00, 27.80, 6.56, 9.75]^T$, 将这 3 组参数 ($\mathbf{x}_{\text{目标}}, \mathbf{x}_{\text{BP}}, \mathbf{x}_{\text{GA-BP}}$) 分别在 HFSS 中进行仿真,其天线特性对比如图 7 所示。从图 7 可以看出,GA-BP 预测的仿真曲线更接近真实结果,并且在第 2 处谐振频率, BP 预测的曲线有明显差异。

仿真完成后,天线在 2.45 GHz 的三维辐射图(目标, BP 以及 GA-BP)如图 8 所示。从图 8 中可

以看到,模拟的目标天线最大增益为 4.39 dBi,而 BP 和 GA-BP 模型预测的天线最大增益分别为 4.27 dBi 和 4.31 dBi。可以看出,所提出的 GA-BP 模型的预测结果更接近真实结果。






图 7 目标天线与预测天线的 S11 对比图


Fig. 7 Comparison chart of S11 between the target antenna and the predicted antenna



(a) 目标天线的三维辐射图



(b) BP 模型预测天线的三维辐射图



(c) GA-BP 模型预测天线的三维辐射图

图 8 目标天线、BP 模型和 GA-BP 模型所预测天线仿真性能图

Fig. 8 Simulation performance diagrams of the target antenna, the BP model, and the GA-BP model for the antenna prediction

4 结束语

传统的天线和微波元件设计受到开发人员经验和电磁仿真软件的限制,而机器学习辅助设计有效地解决了这一问题。本文以神经网络为基础构建单元,开展了天线设计工作。通过 3 层人工神经网络建立天线几何/材料参数与定制天线性能之间的映射关系。所提出的机器学习模型采用遗传算法进行多次迭代优化,所生成的训练数据集被有效地用于多频段天线的逆向设计方法中。通过实验对比,在正向设计与逆向设计中,GA-BP 模型的预测结果均更接近目标值,说明了该模型的优势。

参考文献

- [1] 周希朗. 微波技术与天线[M]. 南京: 东南大学出版社, 2015.
- [2] ALI T, AW M S, BIRADAR R C. A compact bandwidth enhanced antenna loaded with SRR for WLAN/WiMAX/Satellite applications[J]. *Advanced Electromagnetics*, 2018(4):1-8.
- [3] ABDULKAWI W M, MALIK W A, REHMANN S U, et al. Design of a compact dual-band MIMO antenna system with high-diversity gain performance in both frequency bands [J]. *Micromachines*, 2021, 12(4):383.
- [4] AWAN W A, NAQVI S I, NAQVI A H, et al. Design and characterization of wideband printed antenna based on DGS for 28 GHz 5G applications[J]. *Journal of Electromagnetic Engineering & Science*, 2021, 21(3):177-183.
- [5] 张腾飞, 郑雨, 郝龙, 等. 基于机器学习的交通网络级联失效态辨识与预测[J]. *智能计算机与应用*, 2024, 14(2):124-127.
- [6] 乔寅嵩, 张大龙, 韩刚涛, 等. 基于深度神经网络的室内定位算法[J]. *传感器与微系统*, 2024, 43(6):125-128.
- [7] 张洋, 章鲁瑶, 樊金宇, 等. 大数据背景下的深度学习在检验医学中的应用研究[J]. *电子元器件与信息技术*, 2021, 5(4):201-202.
- [8] 李怡然. 基于机器学习的天线优化设计和材料电磁参数预测[D]. 兰州: 兰州大学, 2021.
- [9] 徐晴, 王青洲, 李元岳. 基于 GA-BP 模型的微带贴片天线设计和优化[J]. *电子测量技术*, 2023, 46(21):55-62.
- [10] 肖聪. 基于多目标并行粒子群算法的超表面设计与优化[D]. 南京: 东南大学, 2022.
- [11] GAD A G. Correction to: Particle Swarm Optimization Algorithm and its applications: A systematic review [J]. *Archives of Computational Methods in Engineering*, 2023, 30:3471.
- [12] AN Sensong, FOWLER C, ZHENG Bowen, et al. A deep learning approach for objective-driven all-dielectric metasurface design[J]. *ACS Photonics*, 2019, 6(12):3196-3207.
- [13] HOU Junjie, LIN Hai, XU Weilin, et al. Customized inverse design of metamaterial absorber based on target-driven deep learning method[J]. *IEEE Access*, 2020, 8:211849-211859.
- [14] ROBERTS N B, HEDAYATI M K. A deep learning approach to the forward prediction and inverse design of plasmonic metasurface structural color [J]. *Applied Physics Letters*, 2021, 119(6):0611011-0611015.

- [15] FENG F, GONGAL - REDDY V M R, ZHANG C, et al. Parametric modeling of microwave components using adjoint neural networks and pole-residue Transfer functions with EM sensitivity analysis [J]. IEEE Transactions on Microwave Theory & Techniques, 2017, 65(6):1955 - 1975.
- [16] SHAH A H, GHOSH K, PATEL P N. Modeling and optimization of CPW-fed E-textile antenna using machine learning algorithms [J]. Progress in Electromagnetics Research C, 2023, 130:31 - 42.
- [17] WU Qi, CHEN Weiqi, YU Chen, et al. Machine-learning-assisted optimization for antenna geometry design [J]. IEEE Transactions on Antennas and Propagation, 2024, 72(3):2083 - 2095.
- [18] AHMED M M. Machine learning based design of pattern reconfigurable antenna [J]. IEEE Access, 2023, 11: 33121 - 33133.
- [19] DAN S, CHENG L, KEYI C, et al. Anintelligent antenna synthesis method based on machine learning [J]. IEEE Transactions on Antennas and Propagation, 2022, 70(7):4965 - 4976.
- [20] HAQUE S M, ALAM H. Miniaturized dual-band slot antenna design for GPS, amateur radio and WLAN applications[EB/OL]. (2020-01-06). <https://doi.org/10.1002/mmce.22125>.
- [21] DWIVEDI A K, SHARMA A, SINGH A K, et al. Design of dual band four port circularly polarized MIMO DRA for WLAN/WiMAX applications[J]. Journal of Electromagnetic Waves and Applications, 2020, 34(15):1990-2009.
- [22] ACIKAYA F C, YILDIRIM B S. A dual-bandmicrostrip patch antenna for 2.45/5-GHz WLAN applications[J]. AEU: Archiv fur Elektronik und Ubertragungstechnik: Electronic and Communication, 2021, 141:141-153.
- [23] KULKARNI J, SIM C Y D, PODDAR A, et al. A compact circularly polarized rotated L-shaped antenna with J-shaped defected ground structure for WLAN and V2X applications[J]. Progress in Electromagnetics Research Letters, 2022, 102(1): 135-143.
- [24] LAMBER J, SENER O, SAVARESE S. Deep learning under privileged information using heteroscedastic dropout [C]// Proceedings of 2018 IEEE/CVF Conference on Computer Vision and Pattern Recognition. Piscataway, NJ; IEEE, 2018: 8886 - 8895.
- [25] 余安安, 吴雪菲, 李栋, 等. 基于神经网络的毫米波测云雷达云状识别研究[J]. 国外电子测量技术, 2021, 40(4):82-86.
- [26] XUE J, LIN C and CHEN Y. Genetic algorithm in the field of BP neural network optimization [C]//Proceedings of 2023 IEEE International Conference on Sensors, Electronics and Computer Engineering (ICSECE). Piscataway, NJ; IEEE, 2023:451-457.
- [27] 任谢楠. 基于遗传算法的BP神经网络的优化研究及 MATLAB 仿真[D]. 天津:天津师范大学, 2014.
- [28] CAI Y, ZHOU Z, LI Z. Optimization study of BP neural network based on Genetic Algorithm [C]//Proceedings of 2023 IEEE International Conference on Electrical, Automation and Computer Engineering (ICEACE). Piscataway, NJ; IEEE, 2023: 1555 - 1560.