

基于改进反向传播神经网络代理模型的快速多目标天线设计

董健^{*①} 钦文雯^① 李莹娟^① 李茜茜^① 邓联文^②

^①(中南大学信息科学与工程学院 长沙 410083)

^②(中南大学物理与电子学院 长沙 410083)

摘要: 针对传统天线设计方法计算代价较大的缺陷,该文构建基于反向传播神经网络(BPNN)的新型天线代理模型。为解决BPNN训练易陷入局部最优的问题,采用粒子群优化(PSO)算法来改善神经网络初始结构参数,进而构建PSO-BPNN天线代理模型,并基于该模型提出多参数天线结构的快速多目标设计方法。设计实例表明,该方法在预测精度以及计算代价等方面优于现有的常用天线设计方法。所提方法对处理复杂高维参数空间天线设计问题具有实用价值。

关键词: 天线设计; 性能预测; 代理模型; 反向传播神经网络; 粒子群优化

中图分类号: TN820

文献标识码: A

文章编号: 1009-5896(2018)11-2712-08

DOI: 10.11999/JEIT180025

Fast Multi-objective Antenna Design Based on Improved Back Propagation Neural Network Surrogate Model

DONG Jian^① QIN Wenwen^① LI Yingjuan^① LI Qianqian^① DENG Lianwen^②

^①(School of Information Science and Engineering, Central South University, Changsha 410083, China)

^②(School of Physics and Electronics, Central South University, Changsha 410083, China)

Abstract: Focusing on the problem of reducing the large computation cost of traditional antenna design methods, a new surrogate model based on Back Propagation Neural Networks (BPNN) is constructed. In order to solve the problem of easily falling into local optimum in BPNN, a PSO-BPNN surrogate model is developed by improving initial structural parameters of neural networks and applied to fast multi-objective optimization design of multi-parameter antenna structures. The design results show that the proposed PSO-BPNN outperforms other existing antenna surrogate models in terms of prediction accuracy and prediction speed. The proposed method is of value in dealing with complex antenna designs with high-dimensional parameter space.

Key words: Antenna design; Performance prediction; Surrogate model; Back Propagation Neural Network (BPNN); Particle Swarm Optimization (PSO)

1 引言

作为导行电磁波与自由空间电磁波之间的能量转换装置,天线在移动通信、雷达、卫星通信等领域具有广泛的应用。在实际天线设计过程中,通常利用全波电磁仿真的方法分析天线电磁性能(如带宽、增益等)。这些方法虽然具有计算精度高的特点,但是进行一次仿真计算通常需要几分钟到数十

分钟不等。而且,为了实现天线结构参数的自动调整以及多个设计目标的同时优化,智能优化算法的运用更加重了天线设计的计算负担^[1-3]。

近年来,基于代理模型的天线设计方法逐渐成为研究热点^[4-10]。相比于传统的全波电磁仿真方法,该方法通过构造计算简单的数学模型来完成天线性能参数预测,从而极大地减小计算代价。目前常用的代理模型构建方法包括Kriging^[4-6]方法、高斯过程(Gaussian Process, GP)^[7,8]、径向基函数神经网络(Radial Basis Function Neural Networks, RBFNN)^[9]等。文献^[4-6]中采用Kriging代理模型进行天线性能预测,该方法本质上为插值方法,泛化能力相对较弱;文献^[7]和文献^[8]采用GP代理模型,该模型本质上仍是由Kriging模型发展而来的^[10],也存在Kriging模型的部分缺陷;文献^[9]中提出基

收稿日期: 2018-01-08; 改回日期: 2018-07-17; 网络出版: 2018-07-30

*通信作者: 董健 dongjian@csu.edu.cn

基金项目: 国家重点研发计划(2017YFA0204600), 湖南省自然科学基金(2018JJ2533)

Foundation Items: The National Key Research and Development Program of China (2017YFA0204600), The Natural Science Foundation of Hunan Province (2018JJ2533)

于RBFNN的代理模型，但是RBFNN要达到高精度要求，所需隐层节点数较多，网络结构过于复杂。考虑到反向传播神经网络(Back Propagation Neural Networks, BPNN)也具有较宽的泛化能力，且在预测精度相同的条件下，网络结构要比RBFNN简单^[11]，是构建天线设计代理模型的理想选择。

基于此，本文构建了基于BPNN的天线代理模型。进一步地，针对BPNN训练易陷入局部最优的问题，采用粒子群优化(PSO)算法改善网络初始结构参数，构建PSO-BPNN天线代理模型，并基于该模型提出多参数天线结构的快速多目标设计方法。3频段平面单极子天线的设计实例结果验证了所提方法的有效性。

2 优化问题描述

多参数天线结构的多目标优化问题可以描述为

$$\begin{cases} \min F(\mathbf{x}) = (f_1(\mathbf{x}), f_2(\mathbf{x}), \dots, f_m(\mathbf{x}))^T \\ \text{s.t. } \mathbf{x} \in \mathbf{X} \end{cases} \quad (1)$$

其中， $\mathbf{X}$ 为各参数取值范围确定的参数空间， $\mathbf{x} \in (x_1, x_2, \dots, x_n) \in \mathbf{X} \subset \mathbf{R}^n$ 为 n 维的参数向量也称为一个可行解，对应于天线设计中 n 个待优化的结构参数； $f_k(\mathbf{x}), k=1, 2, \dots, m$ 是第 k 个设计目标， m 是优化目标的数目， $F(\mathbf{x}) \in \mathbf{R}^m$ 为 m 维的目标矢量。典型的天线设计目标包括阻抗带宽、增益、天线尺寸等。对于多目标天线设计问题，各目标之间往往是不可比较甚至相互冲突的，同时使多个目标均达到最优是不可能的，只能在各目标之间进行权衡折中，使所有目标尽可能达到最优。因此存在一个折中解的集合，称为Pareto最优解集(Pareto-optimal set)。在此基础上给出以下几个定义。

定义 1 (Pareto占优) 设 $\mathbf{x}_A, \mathbf{x}_B \in \mathbf{X}$ 是式(1)所示天线多目标优化问题的两个可行解，则称与 $\mathbf{x}_B$ 相比， $\mathbf{x}_A$ 是Pareto占优的，当且仅当

$$\begin{aligned} & \forall i = 1, 2, \dots, m, f_i(\mathbf{x}_A) \leq f_i(\mathbf{x}_B), \\ & \wedge \exists j = 1, 2, \dots, m, f_j(\mathbf{x}_A) < f_j(\mathbf{x}_B) \end{aligned} \quad (2)$$

记做 $\mathbf{x}_B \prec \mathbf{x}_A$ ，也称为 $\mathbf{x}_A$ 支配 $\mathbf{x}_B$ ^[12]。

定义 2 (Pareto最优解) 一个解 $\mathbf{x}^* \in \mathbf{X}$ 被称为Pareto最优解，当且仅当满足式(3)条件：

$$\neg \exists \mathbf{x} \in \mathbf{X} : \mathbf{x}^* \prec \mathbf{x} \quad (3)$$

所有Pareto最优解的集合称为Pareto最优解集 P^* ， P^* 中所有Pareto最优解对应的目标矢量组成的曲面称为Pareto前沿面 PF^* ^[12]。多参数天线结构的多目标设计问题中，目标就是获得 PF^* ，即天线的不同特性之间求取折中的多个设计。

3 方法描述

3.1 基于BPNN的天线代理模型

BPNN是由Rumelhart等人^[13]于1986年提出的一种多层前馈神经网络模型，能够实现精度很高的非线性逼近，而且具有很强的泛化能力。根据柯尔莫哥洛夫定理^[14]，在实际应用中大都采用单隐层BPNN，单隐层BPNN的拓扑结构如图1所示。

其中 $\mathbf{A}=[a_1, a_2, \dots, a_p]$ 为输入层神经元， $\mathbf{B}=[b_1, b_2, \dots, b_s]$ 为隐含层神经元， $\mathbf{C}=[c_1, c_2, \dots, c_q]$ 为输出层神经元； w_{ij}^1 表示输入层第 i 个神经元与隐含层第 j 个神经元之间的连接权值， w_{jk}^2 表示隐含层第 j 个神经元到输出层第 k 个神经元之间的连接权值； θ_j^1, θ_k^2 分别为隐含层和输出层各神经元的阈值， f^1 是隐含层的激发函数， f^2 是输出层的激发函数， $w_{ij}^1, w_{jk}^2, \theta_j^1, \theta_k^2 \in (0, 1)$ 。隐含层神经元 b_j 从输入层的每一个神经元处得到输出值，加权求和并加上阈值 θ_j^1 ，再通过激发函数 f^1 ，得到该神经元的输出值：

$$b_j = f^1 \left(\sum_{i=1}^p w_{ij}^1 a_i + \theta_j^1 \right), i = 1, 2, \dots, p; j = 1, 2, \dots, s \quad (4)$$

输出层神经元 c_k 接收隐含层每个神经元输出值，加权求和并加上阈值 θ_k^2 ，再通过激发函数 f^2 ，得到输出层该神经元的输出值：

$$c_k = f^2 \left(\sum_{j=1}^s w_{jk}^2 b_j + \theta_k^2 \right), j = 1, 2, \dots, s; k = 1, 2, \dots, q \quad (5)$$




图 1 单隐层BPNN拓扑图

样本集数据进入输入层,正向经隐含层各神经元处理后传向输出层,在输出层计算所得输出值的均方误差MSE。若MSE没有达到预定目标误差,则进入反向传播过程。输出误差沿着数据正向传播的通路逐层反向传回,反向传播过程中经过的各神经元的阈值 θ_j^1 , θ_k^2 以及神经元间的连接权值 w_{ij}^1 , w_{jk}^2 都将按照梯度下降的原理进行修正。反复运行信息的正向传播和误差逆向传播两过程,直到MSE达到预定目标误差。

构建基于BPNN的天线代理模型时,首先采用拉丁超立方采样(Latin Hypercube Sampling, LHS)算法^[15]在天线设计参数空间中获取样本集 $\mathbf{S} = [s_1, s_2, \dots, s_L]^T$, $s_i \in \mathbf{R}^n$,接着利用高保真度的电磁仿真软件得到 $\mathbf{S}$ 的响应集 $\mathbf{Y} = [y_1, y_2, \dots, y_L]^T$, $y_i \in \mathbf{R}$,其中 L 为所需样本点数目。LHS通过对参数区间分层和非重叠随机采样,可以使样本点相对均匀地填满整个参数空间。根据样本集 $\mathbf{S}$ 和响应集 $\mathbf{Y}$ 所构成的训练集,按BP算法训练网络连接权值和阈值得到基于BPNN的天线代理模型 $\mathbf{R}_s(\mathbf{x})$ 。基于BPNN的天线代理模型的训练过程仅需在天线优化前进行一次,天线迭代优化过程中适应度(与天线性能参数相关联,如回波损耗等)的评估只需要少量矩阵运算,避免了耗时巨大的电磁仿真,因此可显著提高天线设计效率。

3.2 基于PSO-BPNN的天线代理模型

Rmulhart等人^[13]研究表明,基于梯度下降的BP算法性能往往依赖于初始连接权值及阈值等网络参数的选择。通常采用的随机初始化网络参数会导致网络不稳定,网络训练易陷入局部最优等缺陷,从而影响其预测精度。为改善这些不足,本文提出一种改进的BPNN代理模型。其思想在于:首先利用PSO算法对神经网络结构参数(包括各神经元间的连接权值和神经元阈值)初始值进行训练,然后利用BP算法对神经网络结构参数进行小范围精细化搜索,最终得到PSO-BPNN代理模型 $\mathbf{R}_s(\mathbf{x})$ 。

神经网络初始结构参数优化问题可以描述为

$$\left. \begin{aligned} \text{find } \mathbf{z}_{\text{op}} &= \arg \min_{\mathbf{z}} f(\mathbf{z}) \\ \text{s.t. } \mathbf{z} &\in (0, 1)^d \end{aligned} \right\} \quad (6)$$

其中, $\mathbf{z} = (z_1, z_2, \dots, z_d)$ 表示BP神经网络连接权值和阈值映射的编码实数串;粒子的维度 d 由式(7)确定。

$$d = p \times s + s \times q + s + q \quad (7)$$

$\mathbf{z}_{\text{op}}$ 为待确定的最优解,表示BPNN神经元之间的一组最优连接权值和阈值; $f(\mathbf{z})$ 为标量适应度函数,对应于神经网络均方误差MSE。

采用PSO算法^[16]求解问题(6)时,粒子由4部分组成:隐含层与输入层连接权值 w_{ij}^1 、隐含层阈值 θ_j^1 、输出层与隐含层连接权值 w_{jk}^2 、输出层阈值 θ_k^2 ,其中, $i = 1, 2, \dots, p$, $j = 1, 2, \dots, s$, $k = 1, 2, \dots, q$ 。将网络连接权值与阈值按一定顺序级联起来形成实数数组,作为一个粒子(如图2所示)。当达到最大迭代次数或预定目标误差,搜索终止并给出最优参数向量 $\mathbf{z}_{\text{op}}$,作为BP神经网络的初始连接权值和阈值。

3.3 基于改进BPNN代理模型的天线快速设计

基于全波电磁仿真的传统天线设计方法由于需要反复参数扫描过程,因而耗时较长,限制了其在复杂多参数天线结构设计问题中的应用。本节将多目标粒子群算法(MultiObjective Particle Swarm Optimization, MOPSO)^[17]与PSO-BPNN代理模型相结合,构建多参数天线结构设计的快速多目标优化框架。优化框架中的每个粒子由天线设计中 n 个待优化的结构参数组成,这组参数定义了一个特定的天线结构。采用上节构建的PSO-BPNN模型以替代计算代价高昂的全波电磁仿真完成粒子适应度值的评估。粒子适应度值对应于特定天线结构的性能参数,如反射系数、增益、天线尺寸等。

因此,基于PSO-BPNN代理模型的天线快速多目标设计框架可概括如下:

- (1)预定义参数空间 $\mathbf{X}$;
- (2)利用LHS采样参数空间得到样本集 $\mathbf{S}$ 并获取响应集 $\mathbf{Y}$;
- (3)利用PSO算法优化得到BPNN的初始网络结构参数 $\mathbf{z}_{\text{op}}$;
- (4)基于 $\mathbf{S}$, $\mathbf{Y}$ 及 $\mathbf{z}_{\text{op}}$ 构建PSO-BPNN代理模型 $\mathbf{R}_s(\mathbf{x})$;
- (5)采用MOPSO算法优化种群,并采用 $\mathbf{R}_s(\mathbf{x})$ 评估粒子适应度值;




图2 PSO算法中粒子与BPNN结构参数对应关系

(6)若未达到终止条件,则转到步骤(5),否则结束优化。





图 3 基于PSO-BPNN的天线快速多目标设计方法流程图

基于PSO-BPNN的天线快速设计方法流程图如图3所示。



4 实验结果及分析

本节通过平面多频带天线设计实例来分析PSO-BPNN代理模型的预测性能,在此基础上给出小型化平面3频段天线多目标设计结果。仿真软件平台为MATLAB R2016a结合HFSS 13.0,硬件环境为Intel Core i5 3427U处理器、4 GB RAM内存。

4.1 代理模型构建

平面多频带天线初始结构如图4所示^[18]。该天线由厚度1.6 mm、介电常数4.4的FR-4环氧树脂介质基板、具有圆形槽的矩形微带贴片和缺陷地组成,可产生不同的谐振频带以覆盖想要的应用。选

取设计参数向量为 $\mathbf{x} = [d \ l \ l_1 \ l_2 \ l_3 \ l_4 \ w \ w_1 w_2 \ w_3]^T$ (单位为mm)。设计参数的初始范围如表1所示。

表 1 设计参数初始范围

参数	d	l	l_1	l_2	l_3
范围(mm)	[7,10]	[26,34]	[11,14]	[8,10]	[6,8]
参数	l_4	w	w_1	w_2	w_3
范围(mm)	[10,14]	[17,23]	[2,4]	[2,4]	[0.5,1.5]

首先,利用LHS算法生成给定初始范围内均匀分布的样本集 $\mathbf{S}$,样本点组数为150,通过HFSS-MATLAB-API以函数调用的方式将 $\mathbf{S}$ 传递给HFSS进行电磁仿真,得到反射系数 S_{11} 响应集 $\mathbf{Y}$ 。依据文献^[19]神经网络数据处理经验及实际试验效果,设置 $\mathbf{S}$ 和 $\mathbf{Y}$ 中的前145组数据用于训练网络,最后5组数据用于测试。BPNN模型输入层节点数目 p 与待优化天线设计变量数目一致(本例中取 $p=10$),输出层节点数目 q 与 S_{11} 频点数目一致(本例中取 $q=15$)。至于隐含层节点数目 s 的确定,虽然有一些经验公式可作为参考,但是并无成熟的理论作为指导。为保证网络的稳定性,这里通过实验测试来确定隐含层节点数。节点测试区间取[10, 20]。从训练数据中抽取30组,对区间内每个节点取值进行3次测试,从实验结果中发现,隐含层节点数 $s=18$ 时具有较低且稳定的误差。确定网络初始权值和阈值时,依据文献^[20,21]中PSO算法参数设置的经验,选择粒子数目为40,粒子的维度 d 由式(7)确定为483,以随机的方式在(0,1)之间生成初始粒子群,学习因子 $c_1=c_2=2.05$,最大速度 $V_{\max}=1$,惯




图 4 平面多频带天线结构

性权重 w 在0.9~0.4间线性递减,最大迭代次数设置为2000,当达到最大迭代次数或全局极值小于1时结束优化,输出最优解 z_{op} 并赋值给BPNN各神经元间的连接权值及阈值,完成BPNN的初始化。接着,利用训练集完成对BPNN模型的训练。图5给出了Kriging, RBFNN, BPNN, PSO-BPNN代理模型对5组测试数据的预测结果,其中RBFNN网络结构设置及参数设置与BPNN相同。图6给出了BPNN与PSO-BPNN代理模型的训练误差曲线。表2给出了各代理模型相对于HFSS仿真结果的均方误差。表3给出了各代理模型以及HFSS仿真的计算耗时比较。

从以上结果可以看出: PSO-BPNN代理模型在预测精度方面明显优于Kriging, RBFNN及

BPNN代理模型,其收敛速度也优于BPNN代理模型,有效缓解了BPNN训练易陷入局部最优的问题。同时,相较于HFSS仿真而言,极大地缩短了计算耗时。因此,对于给定的天线模型,利用PSO-BPNN代理模型完全可以替代电磁仿真软件进行天线性能预测,结合智能优化算法即可实现天线的快速优化设计。

4.2 小型多频带天线快速多目标设计

利用4.1节构建的PSO-BPNN代理模型和MOPSO算法,实现图4所示天线结构的快速多目标设计。设计目标为: (1)实现3频段特性(目标 F_1),覆盖WLAN2.4/5.2/5.8 GHz, WiMAX2.5/3.5/5.5 GHz和X频段SATcom应用(7.9~8.4 GHz); (2)天线尺寸尽可能小(目标 F_2),以满足移动设备中天线




图5 各代理模型对测试数据的预测结果

表2 各代理模型预测结果的均方误差

代理模型	第1组	第2组	第3组	第4组	第5组	平均误差
Kriging ^[4]	12.01	9.98	9.69	35.77	7.93	15.08
RBFNN ^[9]	11.42	13.63	18.19	7.94	2.95	10.83
BPNN	6.21	11.71	9.10	4.39	4.07	7.10
PSO-BPNN	0.43	0.65	0.39	0.67	0.55	0.54

表3 各代理模型以及HFSS仿真的计算耗时(s)

预测方法	HFSS	Kriging ^[4]	RBFNN ^[9]	BPNN	PSO-BPNN
总耗时	141.7572	0.0568	0.0134	0.0193	0.0186
平均耗时	28.3514	0.0114	0.0027	0.0039	0.0037




图6 BPNN与PSO-BPNN训练误差曲线

最小化的需要。目标函数 F_1 可以描述为

$$F_1 = \frac{1}{n} \sum_{i=1}^n Q(f_i) \quad (8)$$

$$Q(f_i) = \begin{cases} |S_{11}(f_i)|, & |S_{11}(f_i)| > -10 \\ -10, & |S_{11}(f_i)| \leq -10 \end{cases} \quad (9)$$

其中, f_i 是给定频率范围内的第 i 个采样频率点; $S_{11}(f_i)$ 是采样频率点 f_i 的反射系数; n 是频率采样点的个数。目标函数 F_2 可以描述为

$$F_2 = w \times l \quad (10)$$

基于文献[17,21]中MOPSO的参数选择原则以及多次试验的经验, 设置MOPSO的粒子群规模为

100, 粒子维度为10, 外部存储矩阵规模为6, 学习因子 c_1 和 c_2 取值均为2.05, 最大速度 $V_{\max}$ 取值为1, 惯性权重 w 在0.9~0.4间线性递减, 最大迭代次数为300。图7给出了平面3频带天线的Pareto最优解集, 详细的设计参数见表4。图8给出了各设计对应的回波损耗曲线。从图中可以看出, 在2.3~3.7 GHz, 5.1~6.4 GHz, 7.9~8.6 GHz 3个频段内, 天线的回波损耗均小于-10 dB, 满足WLAN, WiMAX和X波段3频段同时通信的要求。这些设计为实际的天线工程提供了灵活的选择。

为了验证PSO-BPNN代理模型的有效性, 我们对表5中Pareto最优解集的目标函数 F_1 分别采用不同方法计算, 得到的结果如表5所示。误差率1和




图7 平面3频带天线的Pareto最优解集




图8 Pareto最优解集的回波损耗

表4 平面3频带天线的Pareto最优设计

设计	$x^{(1)}$	$x^{(2)}$	$x^{(3)}$	$x^{(4)}$	$x^{(5)}$	$x^{(6)}$
F_1 (dB)	-17.57	-16.18	-15.19	-14.19	-13.27	-12.35
F_2 (mm ²)	629.28	608.94	590.00	580.14	555.84	533.90
d	8.7	8.8	8.4	8.6	8.3	9.4
l	30.4	30.6	29.5	29.3	28.8	28.1
l_1	11.8	12.9	12.8	12.4	10.9	11.2
l_2	9.0	8.8	9.0	9.2	8.8	9.7
l_3	6.4	6.8	6.8	6.8	7.0	6.6
l_4	11.5	11.5	11.1	12.3	10.9	11.0
w	20.7	19.9	20.0	19.8	19.3	19.0
w_1	3.1	3.3	3.2	3.4	3.0	2.9
w_2	3.0	3.1	3.8	3.4	3.2	3.4
w_3	1.0	1.0	0.9	0.8	1.1	1.2

表5 代理模型与HFSS所获得的Pareto最优解集的目标值 F_1 比较

代理模型	$x^{(1)}$	$x^{(2)}$	$x^{(3)}$	$x^{(4)}$	$x^{(5)}$	$x^{(6)}$
HFSS	-17.46	-15.75	-15.01	-14.69	-13.50	-12.53
BPNN	-19.19	-17.90	-16.97	-16.04	-15.13	-14.36
PSO-BPNN	-17.57	-16.18	-15.19	-14.19	-13.27	-12.35
误差率1(%)	9.91	13.65	13.06	9.19	12.07	14.60
误差率2(%)	0.63	2.73	1.20	3.40	1.70	1.44

误差率2分别表示BPNN, PSO-BPNN代理模型的预测结果与HFSS仿真结果的对比。结果表明, PSO-BPNN代理模型的预测结果(平均误差率1.85%)要明显优于BPNN代理模型(平均误差率12.08%)。

表6给出了不同的天线设计方法针对目标 F_1 的总耗时比较。方法1为基于HFSS电磁仿真软件的PSO天线设计方法, 每次电磁仿真耗时约35 s, 实现目标 F_1 需23.44 h; 方法2是基于动态更新Kriging代理模型的PSO天线设计方法^[6], 总用时约为方法1的9.15%; 方法3是本文提出的基于PSO-BPNN代理模型的天线设计方法, 该方法仅需在优化前进行一次代理模型训练, 天线迭代优化过程中无需调用电磁仿真软件, 耗时仅为方法1的6.67%, 可见, 基于PSO-BPNN代理模型的天线设计方法在具有较好预测精度的同时, 大幅减少了时间代价, 从而提高了天线设计效率。

表 6 不同的天线设计方法用时比较

优化方法	电磁仿真次数	CPU时间(s)	
		总时间	百分比(%)
方法1	2400	84380	100
方法2 ^[6]	210	7720	9.15
方法3	150	5624	6.67

5 结束语

本文提出了一种基于改进BPNN代理模型的快速多目标天线设计方法。首先根据参数空间样本集和响应集构造BPNN天线代理模型; 然后, 针对基本BPNN训练易陷入局部最优的缺陷, 采用PSO算法改善网络初始结构参数, 构建PSO-BPNN天线代理模型; 基于该模型提出了多参数天线结构的快速多目标优化设计方法。小型多频带天线设计实例的结果表明, 所提方法在预测精度、计算代价等方面优于现有天线设计方法。

参 考 文 献

- [1] MOHAMMED H J, ABDULLAH, A S, ALI R S, *et al.* Design of a uniplanar printed triple band-rejected ultra-wideband antenna using particle swarm optimisation and the firefly algorithm[J]. *IET Microwaves, Antennas & Propagation*, 2016, 10(1): 31–37. doi: [10.1049/iet-map.2014.0736](#).
- [2] CHOI K, JANG D, KANG S, *et al.* Hybrid algorithm combining genetic algorithm with evolution strategy for antenna design[J]. *IEEE Transactions on Magnetics*, 2016, 52(3): 7209004. doi: [10.1109/TMAG.2015.2486043](#).
- [3] GOUDOS S K, KALIALAKIS C, and MITTRA R. Evolutionary algorithms applied to antennas and propagation: A review of state of the art[J]. *International Journal of Antennas and Propagation*, 2016, 2016(4): 1–12. doi: [10.1155/2016/1010459](#).
- [4] KOZIEL S and OGURTSOY S. Multi-objective design of antennas using variable-fidelity simulations and surrogate models[J]. *IEEE Transactions on Antennas and Propagation*, 2013, 61(12): 5931–5939. doi: [10.1109/TAP.2013.2283599](#).
- [5] 陈晓辉, 裴进明, 郭欣欣, 等. 一种基于多维均匀采样与Kriging模型的天线快速优化方法[J]. *电子与信息学报*, 2014, 36(12): 3021–3026. doi: [10.3724/SP.J.1146.2013.01826](#).
CHEN Xiaohui, PEI Jinming, GUO Xinxin, *et al.* An efficient antenna optimization method based on kriging model and multidimensional uniform sampling[J]. *Journal of Electronics & Information Technology*, 2014, 36(12): 3021–3026. doi: [10.3724/SP.J.1146.2013.01826](#).
- [6] DONG Jian, LI Qianqian, and DENG Lianwen. Fast multi-objective optimization of multi-parameter antenna structures based on improved MOEA/D with surrogate-assisted model[J]. *AEUE-International Journal of Electronics and Communications*, 2017, 72: 192–199. doi: [10.1016/j.aeue.2016.12.007](#).
- [7] LIU Bo, ALIAKBARIAN H, MA Zhongkun, *et al.* An efficient method for antenna design optimization based on evolutionary computation and machine learning techniques[J]. *IEEE Transactions on Antennas and Propagation*, 2014, 62(1): 7–18. doi: [10.1109/TAP.2013.2283605](#).
- [8] JACOBS J P. Efficient resonant frequency modeling for dual-band microstrip antennas by Gaussian process regression[J]. *IEEE Antennas and Wireless Propagation Letters*, 2015, 14: 337–341. doi: [10.1109/LAWP.2014.2362937](#).
- [9] CHEN Linglu, LIAO Cheng, LIN Wenbin, *et al.* Hybrid-surrogate-model-based efficient global optimization for high-dimensional antenna design[J]. *Progress in Electromagnetics Research*, 2012, 124(8): 85–100. doi: [10.2528/PIER11121203](#).
- [10] MASSA A, OLIVERI G, SALUCCI M, *et al.* Learning-by-examples techniques as applied to electromagnetics[J]. *Journal of Electromagnetic Waves and Applications*, 2017, 32(4): 516–541. doi: [10.1080/09205071.2017.1402713](#).
- [11] 焦李成, 杨淑媛, 刘芳, 等. 神经网络七十年: 回顾与展望[J]. *计算机学报*, 2016, 39(8): 1697–1716. doi: [10.11897/SP.J.1016.2016.01697](#).
JIAO Licheng, YANG Shuyuan, LIU Fang, *et al.* Seventy years beyond neural networks: retrospect and prospect[J]. *Chinese Journal of Computers*, 2016, 39(8): 1697–1716. doi: [10.11897/SP.J.1016.2016.01697](#).

- 10.11897/SP.J.1016.2016.01697.
- [12] 公茂果, 焦李成, 杨咚咚, 等. 进化多目标优化算法研究[J]. 软件学报, 2009, 20(2): 271–289. doi: [10.3724/SP.J.1001.2009.03483](https://doi.org/10.3724/SP.J.1001.2009.03483).
- GONG Maoguo, JIAO Licheng, YANG Dongdong, *et al.* Research on evolutionary multi-objective optimization algorithms[J]. *Journal of Software*, 2009, 20(2): 271–289. doi: [10.3724/SP.J.1001.2009.03483](https://doi.org/10.3724/SP.J.1001.2009.03483).
- [13] RUMELHART D E, HINTON G E, and WILLIAMS R J. Learning representations by back-propagating errors[J]. *Nature*, 1986, 323(9): 533–536. doi: [10.1038/323533a0](https://doi.org/10.1038/323533a0).
- [14] KOLMOGOROV A N. On the representation of continuous functions of several variables by superposition of continuous functions of one variable and addition[J]. *Doklady Akademii Nauk SSSR*, 1957, 114(5): 953–956. doi: [10.1007/978-94-011-3030-1_56](https://doi.org/10.1007/978-94-011-3030-1_56).
- [15] STEIN M. Large sample properties of simulations using Latin hypercube sampling[J]. *Technometrics*, 1987, 29(2): 143–151. doi: [10.1080/00401706.1987.10488205](https://doi.org/10.1080/00401706.1987.10488205).
- [16] KENNEDY J and EBERHART R C. Particle swarm optimization[C]. Proceedings of IEEE International Conference on Neural Networks, Perth, Australia, 1995, 4: 1942–1948. doi: [10.1109/icnn.1995.488968](https://doi.org/10.1109/icnn.1995.488968).
- [17] COELLO C A C, PULIDO G T, and LECHUGA M S. Handling multiple objectives with particle swarm optimization[J]. *IEEE Transactions on Evolutionary Computation*, 2004, 8(3): 256–279. doi: [10.1109/TEVC.2004.826067](https://doi.org/10.1109/TEVC.2004.826067).
- [18] DONG Jian, YU Xiaping, and HU Guoqiang. Design of a compact quad-band slot antenna for integrated mobile devices[J]. *International Journal of Antennas and Propagation*, 2016, 2016: 1–9. doi: [10.1155/2016/3717681](https://doi.org/10.1155/2016/3717681).
- [19] ANURDHA, PATNAIK A, and SINHA S N. Design of custom-made fractal multi-band antennas using ANN-PSO[J]. *IEEE Antennas & Propagation Magazine*, 2011, 53(4): 94–101. doi: [10.1109/MAP.2011.6097296](https://doi.org/10.1109/MAP.2011.6097296).
- [20] ROBINSON J and RAHMAT-SAMMI Y. Particle swarm optimization in electromagnetics[J]. *IEEE Transactions on Antennas and Propagation*, 2004, 52(2): 397–407. doi: [10.1109/TAP.2004.823969](https://doi.org/10.1109/TAP.2004.823969).
- [21] JIN Nanbo and RAHMAT-SAMMI Y. Advances in particle swarm optimization for antenna designs: Real-number, binary, single-objective and multiobjective implementations[J]. *IEEE Transactions on Antennas and Propagation*, 2007, 55(3): 556–567. doi: [10.1109/TAP.2007.891552](https://doi.org/10.1109/TAP.2007.891552).
- 董 健: 男, 1980年生, 副教授, 研究方向为天线理论与设计、微波遥感、阵列信号处理等。
- 钦文雯: 女, 1993年生, 硕士生, 研究方向为天线自动优化技术等。
- 李莹娟: 女, 1994年生, 硕士生, 研究方向为天线自动优化技术等。
- 李茜茜: 女, 1993年生, 硕士生, 研究方向为超宽带与多频带天线设计等。
- 邓联文: 男, 1969年生, 教授, 研究方向为微波技术、天线等。