

DOI: 10.13382/j.jemi.B2306708

改进蝴蝶算法的神经网络天线建模*

南敬昌 黄 菊 张慧妹
(辽宁工程技术大学 葫芦岛 125105)

摘 要:为提高天线建模效率,改变传统建模方法速度慢、效率低的问题,提出了一种用改进的蝴蝶算法(BOA)优化多层前馈神经网络(back propagation neural network, BPNN)的天线建模方法。首先,以多层前馈神经网络为基础网络,建立蝴蝶算法优化的 BP 神经网络,解决 BP 神经网络预测精度低的问题。其次,在蝴蝶算法中融入天牛须算法(BAS),用天牛须算法替代蝴蝶算法的局部寻优过程,减小蝴蝶算法的空间复杂度、解决蝴蝶算法易陷入局部最小值的问题,创建改进的 BOA-BP 神经网络对天线进行精准建模。设计实例表明,该网络的预测精度达到了 99.60%,相比于传统的 BPNN 和未改进蝴蝶算法优化的 BPNN,预测 S_{11} 的误差分别减少了 47%和 40.9%。此外,改进的 BOA 算法的运行时间相对于粒子群算法和遗传算法也分别减小了 80.86%和 82.79%,大大降低了网络运行的时间成本。综上,改进的 BOA 优化后的 BPNN 的建模精度和速度均得到了提高,验证了改进的蝴蝶算法作为一种新型神经网络优化策略的可行性和有效性。

关键词: 多层前馈神经网络;双陷波蜂窝结构分形超宽带天线;蝴蝶算法;天牛须算法;权值优化

中图分类号: TP391.9;TN820 **文献标识码:** A **国家标准学科分类代码:** 510.5199

Improved neural network antenna modeling for butterfly algorithms

Nan Jingchang Huang Ju Zhang Huimei
(Liaoning University of Engineering and Technology, Huludao 125105, China)

Abstract: To improve the efficiency of antenna modeling and change the problem of slow speed and low efficiency of traditional modeling methods, an antenna modeling method using improved butterfly algorithm (BOA) to optimize multilayer feedforward neural network (back propagation neural network (BPNN)) is proposed. Firstly, the BP neural network optimized by the butterfly algorithm is established with the multilayer feedforward neural network as the base network to solve the problem of low prediction accuracy of the BP neural network. Secondly, the beetle antennae search (BAS) algorithm is integrated into BOA, replacing the local optimization process of the butterfly algorithm with the beetle antennae search algorithm to reduce the spatial complexity of the BOA, solve the problem that the BOA is prone to fall into local minima, and create an improved BOA-BP neural network for accurate antenna modeling. The design example shows that the prediction accuracy of the network reaches 99.60%, and the prediction error is reduced by 47% and 40.9% compared with the traditional BPNN and the BPNN optimized by the unimproved butterfly algorithm, respectively. In addition, the running time of the improved BOA algorithm is reduced by 80.86% and 82.79% compared with the particle swarm algorithm and the genetic algorithm, which greatly reduces the running time cost of the network. In summary, the modeling accuracy and speed of the improved BOA-optimized BPNN are improved, which verifies the feasibility and effectiveness of the improved butterfly algorithm as a novel neural network optimization strategy.

Keywords: multilayer feedforward neural networks; dual notch cellular fractal ultra-wideband antenna; butterfly algorithm; beetle antennae search algorithm; weight optimization

0 引言

随着无线网络的迅猛发展、各种通信终端数量的不断增加,所使用通信设备的质量与性能正面临着挑战。作为无线通信系统的重要模块,超宽带天线 (ultra wideband antenna, UBW) 已经成为了当下的研究热点。在超宽带系统中,3.1~10.6 GHz 的超宽带范围已被分配给短距离的信号应用^[1],数据的高速传输需要大带宽,因此,天线作为无线电系统的发送和接收装置,能在宽带宽上很好地运作是它必须具备的条件^[2],更快更简洁的设计出满足需求的超宽带天线是追求的目标。但是令人唏嘘的是传统方法建模天线具有诸多弊端,不仅计算量非常大,而且需要的时间也非常长。在这种情况下,借助神经网络对天线进行建模是非常有必要的。

文献[3]提出用改进的粒子群算法 (quantum particle optimization algorithm, QPOS) 对同轴馈电矩形微带天线和同轴馈电双频微带天线建模,文献[4]提出用自适应的 RBF 神经网络对微带天线建模,文献[5]提出用遗传算法和粒子群算法对标签天线进行优化,文献[6]提出用基于 POS 的神经网络集成方法对矩形微带天线的谐振频率建模。文献[7]提出用果蝇算法改进的广义回归神经网络对超宽带天线进行建模,文献[8]提出了一种利用卷积神经网络对超宽带天线的 S_{11} 参数进行建模。文献[9]中将粒子群算法引入到 BP 神经网络模型中,解决了传统 BP 神经网络模型易陷入局部最优解的问题。根据以上文献中的内容不难发现,现有的研究主要集中在使用遗传算法、粒子群算法等方式对神经网络进行优化和改进^[10]。随着研究的深入,这些方法本身的缺陷也暴露了出来,如粒子群算法中初始种群的设置十分关键但却不易掌控,初始种群过大将会导致算法搜索速度变慢^[11],一旦出现这种问题,基于群体智能算法优化 BP 神经网络预测模型的性能^[12]将被制约;此外,使用遗传算法去优化 BP 神经网络时,如果预测数据是大样本数据,遗传算法会有不错的表现,但反之对于小样本且分布不均匀的数据^[13],遗传算法优化后的 BP 神经网络的预测表现就强差人意了,而且遗传算子的正确设置也需要花费一些精力,若遗传算子设定不当,算法的搜索性能将大打折扣,还可能使算法易陷入局部最优解^[12]。由此可见,对超宽带天线进行建模还有着很大发展进步的空间。

针对以上算法中存在的问题,本文提出了一种改进的蝴蝶算法优化 BP 神经网络的策略,该策略参数简单,计算量小,不易陷入局部最优解,具有优秀的全局寻优能力,可以有效规避以上算法中存在的问题。BP (back propagation) 神经网络是一种按照误差反向传播算法训练

的多层前馈神经网络,可以根据应用设计不同数量的隐藏层、根据需求找到最合适的隐藏层神经元数量,具有很强的灵活性和普适性。作为一种元启发式智能算法,蝴蝶优化算法 (butterfly optimization algorithm, BOA) 能够有效的优化神经网络的参数。本文提出的基于改进的蝴蝶算法优化 BP 神经网络智能模型,对超宽带天线进行精准建模,实现了快速高效的建模。通过改进的蝴蝶算法优化网络的权重和阈值,加快了网络的收敛速度,提高了模型的准确率。很大程度上提高了采用 BP 神经网络对超宽带天线进行建模的建模精度。

1 基本原理

1.1 网络结构

BP 神经网络由输入、隐藏和输出层组成,图 1 为 BP 神经网络的结构图。其中 $X_j (j = 1, 2, 3, \dots, N)$ 为神经元 j 的输入信号, W_{ij} 为连接权重, i 表示神经元, j 表示 i 后面一层的神经元。 b_k 是第 k 个神经元的偏置 ($k = 1, 2, \dots, n$)。 u_i 是输入信号经过上一层神经元与上层神经元对应权重相乘后的输出。 θ_i 是神经元 i 的阈值, v_i 为 u_i 经累加法则和阈值调整后的值, $f(\cdot)$ 代表神经元的激活函数。输入的信号在单层感知器中经历的一系列操作的数学模型如图 1 所示。




图 1 BP 神经网络结构

Fig. 1 BP neural network structure diagram

图 1 中相关变量关系如下:

$$u_i = \sum_{j=1}^N W_{ij} X_j \quad (1)$$

$$v_i = u_i + b_k \quad (2)$$

$$y_i = f(v_i) \quad (3)$$

$f(\cdot)$ 是 BP 神经元的激励函数,是非线性函数,常用的形式有 Sigmoid、Tanh 和 ReLU,数学表达式和对应图像如图 2~4 所示。




图 2 Sigmoid 函数
Fig. 2 The Sigmoid function




图 3 Tanh 函数
Fig. 3 The Tanh function




图 4 ReLU 函数
Fig. 4 The ReLU function

$$\sigma(x) = \frac{1}{1 + \exp(-x)} \tag{4}$$

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)} \tag{5}$$

$$\text{ReLU}(x) = \begin{cases} x, & x > 0 \\ 0, & x \leq 0 \end{cases} \tag{6}$$

通过 3 种函数的表达式可以看出, Sigmoid 函数和 Tanh 函数涉及指数运算,而 ReLU 激活函数运算更加简单,有效的加大了网络的运算速度。

1.2 BP 算法思想

BP 算法的思想是将神经网络的学习过程分成两个部分,前一部分是前向传播,后一部分是反向传播。首先, N 个特征信号 $X_1, X_2, \dots, X_N$ 依次通过神经网络各层的神经元,经过相应运算得到预测结果,这是前一部分。而后,将预测值与真实值进行比较,如果预测结果未能满足精度要求,则进行误差反向传播,未能满足精度要求的误差信号从输出层开始,将误差分摊给各层的神经元,以此动态调整各个神经元对应连接的权重值,这是后一部分。BP 神经网络正是通过这种方法不断进行前向传播和反向调节,使得网络的权重得到不断修正,当输出信号的准确率达到一定要求时,学习过程结束。

反向传播的过程可以用如下公式更好的进行描述:

$$E = \frac{1}{2} \sum (r - y_k)^2 \tag{7}$$

其中, r 为真实结果,以下简称真实值,输出层设定为第 k 层, y_k 为预测值, E 为损失函数,该公式为损失函数定义式。将式(1)~(3)代入式(7)后,根据链式求导法则则可推导出参数更新公式:

$$W = W - \eta \frac{\partial E}{\partial W} = W - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial f} \frac{\partial f}{\partial W} \tag{8}$$

$$b = b - \eta \frac{\partial E}{\partial b} = b - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial f} \frac{\partial f}{\partial b} \tag{9}$$

式中: f 为激活函数。

2 BOA 算法

蝴蝶优化算法(butterfly optimization algorithm, BOA)属于元启发式智能算法的一种,受到了蝴蝶觅食和交配行为的启发。蝴蝶在寻找食物和求偶时可以通过各种感官,如嗅觉、视觉、味觉和听觉等,在所有感觉中最重要的是嗅觉^[14]。蝴蝶用于嗅觉的感觉受体遍布各个器官,如触角,手掌,腿等。蝴蝶通过这些器官感知并分析空气中的气味,以确定食物来源和交配伙伴的潜在方向。当一只蝴蝶闻到其他蝴蝶释放的香气时,蝴蝶将向着香气最浓的地方飞去,这个阶段在算法中的体现就是全局搜索。与之相对应的,如果蝴蝶没有闻到任何香气,那么蝴蝶将

进行随即飞行,这个过程体现在算法中就是局部飞行的过程。在蝴蝶算法中使用概率 p 来控制普通全局搜索之间的转换。

为了排除其他因素对于蝴蝶飞行的影响,针对上述过程提出如下假设:

- 1) 所有蝴蝶都处于正常状态,可以正常释放香气,蝴蝶之间会因为香气相互吸引。
- 2) 所有蝴蝶都能自由的向着香味方向或者随机移动。
- 3) 蝴蝶所受到的刺激强度由目标函数决定或受目标函数影响。
- 4) 进行全局飞行还是局部搜索受到概率 P 控制。
- 5) 概率 P 受物理接近度和自然因素如大风、暴雨、闪电等。

每只蝴蝶都有独特的感觉和个体感知能力,蝴蝶个体产生香味的公式如下:

$$f = cI^a \quad (10)$$

其中, f 为其他蝴蝶感知到香味的强度,即香味感知强度, c 是感觉模态, I 是刺激强度, a 是依赖于模态的幂指数,它表示了对香味的吸收程度的变化,在 $[0, 1]$ 范围内取值。

算法在每次迭代时计算解空间中不同位置上所有蝴蝶的适应度值,然后通过式 (10) 分别在它们的位置产生香味。

在全局搜索阶段蝴蝶朝着最优蝴蝶 g^* 飞行,可用式 (11) 表示:

$$x_i^{t+1} = x_i^t + (r^2 \times g^* - x_i^t) \times f_i \quad (11)$$

其中, x_i^t 为第 t 次迭代中第 i 只蝴蝶的解向量, g^* 表示在当前迭代中所有解中的最优解, f_i 为第 i 只蝴蝶释放的香味量。 r 是 $[0, 1]$ 之间的随机数。

在局部搜索时蝴蝶的飞行根据式 (12) 完成:

$$x_i^{t+1} = x_i^t + (r^2 \times x_k^t - x_k^t) \times f_i \quad (12)$$

其中, x_i^t 和 x_k^t 分别表示第 i 只蝴蝶和第 k 只蝴蝶的解向量,若第 i 只蝴蝶和第 k 只蝴蝶属于同一种群,并且 r 是 $[0, 1]$ 之间的随机数,则式 (12) 表示局部随机游走。

蝴蝶算法的流程如图 5 所示。

根据图 5 可以知道在未达到停止标准之前,算法将一直进行迭代。迭代结束的标准可以有多个,如达到的最大迭代次数、使用的最大 CPU 时间、达到错误率的特定值或任何其他适当的标准。当迭代阶段结束时,算法输出具有最佳适应度的最优解。

蝴蝶算法的流程虽然很简单,但存在收敛精度低,容易陷入局部最优解的问题^[14]。针对蝴蝶算法的不足,提出了用天牛须算法改进蝴蝶算法的方法以提升原本算法的收敛精度。




图 5 蝴蝶算法流程

Fig. 5 Butterfly algorithm flowchart

3 改进的 BOA-BP 神经网络介绍

3.1 天牛须算法

天牛须搜索 (beetle antennae search, BAS) 是 2017 年提出的一种智能优化算法,其具有运行速度快、计算量小的优势,该算法是仿照天牛觅食时天牛不知道食物的具体位置,根据食物气味进行觅食的过程提出的。BAS 不需要知道函数的具体形式就可以实现高效寻优,只需要 1 个天牛就可以完成寻优,大大降低了算法的计算量^[15]。

天牛须的仿生原理如下:

天牛在觅食时,凭借对食物气味的强弱判断来觅食,通过触角感知到的食物气味的强弱来判断下一步的飞行方向,如果天牛左边的触角接收到的气味大,那下一步天牛就向左飞,反之天牛则向右飞^[15]。食物的气味就相当于一个函数,天牛的目标是全局气味最大的点。仿照以上原理,得到天牛须算法如下:

- 1) 为了能在任意维度情况下使用,将三维空间中的天牛扩展到任意维空间。
- 2) 将天牛抽象为一个质点,左右两须位于质点两侧。
- 3) 天牛的步长与左右两个天牛须之间有固定的比例关系。

4) 天牛每进行一次飞行后头的朝向是随机的。

算法流程:

1) 对于 k 维优化问题, 质心用 x 表示, 左须用 x_l 表示, 右须用 x_r 表示, 两须之间的距离用 d_0 表示, 其中质心、左、右须均为 k 维坐标。

2) 为了模拟天牛的搜索行为, 定义它的方向向量 (左须指向右须的向量) 为 b :

$$b = \frac{\text{rands}(k, 1)}{\| \text{rands}(k, 1) \|} \quad (13)$$

3) 天牛左右须的坐标在空间中表示为:

$$\begin{cases} x_n = x^t + d^t b \\ x_{ln} = x^t + d^t b \end{cases}, (t = 0, 1, \dots, n) \quad (14)$$

其中, x_{ln}, x_n 分别代表天牛左右须在第 t 次迭代时的空间位置, x^t 表示在第 t 次迭代时质点所在的空间位置, d^t 表示天牛左须与右须之间的距离。

4) 适应度函数

在天牛算法中, 适应度函数的自变量是天牛的左右须在空间中的位置, 表达式如下:

$$\begin{cases} \text{fright} = f(\cdot) \\ \text{fleft} = f(\cdot) \end{cases} \quad (15)$$

5) 步长设置

$$\text{step}^t = c_1 \text{step}^{t-1} + \text{step}^0 \quad (16)$$

$$d^t = \text{step}^t / c_2 \quad (17)$$

其中, step^t 为天牛在第 t 次迭代时的步长, step^0 为初始步长, c_1, c_2 两个参数需要根据实际情况设定。

6) 位置更新

$$x^t = x^{t-1} + \text{step}^t \times b \times \text{sign}(\text{fright} - \text{fleft}) \quad (18)$$

其中, $\text{sign}(\cdot)$ 为符号函数。天牛根据上式进行位置的更新, 如果 $\text{fright} > \text{fleft}$ 则天牛向右飞行一个步长, 否则 $\text{fright} < \text{fleft}$, 天牛向左飞行一个步长。若 $\text{fright} = \text{fleft}$, 则前进 1/2 个步长, 方向与上一次的前进方向相同。

7) 接受更新的判断依据

BAS 在进行位置更新时, 根据适应度函数的大小判断是否进行位置更新。

3.2 天牛须结合蝴蝶算法优化 BP 神经网络

根据上述的天牛须算法流程图可知, 该算法计算量小, 过程简单, 是一种高效的智能算法, 因为其不限定具体的适应度函数, 所以与其他算法结合的空间很大, 这里创建一个改进的 BOA-BP 神经网络, 其中 BAS 算法用于代替 BOA 进行局部飞行, 经过的计算, 如果全局飞行的方向食物气味更大则进行全局飞行, 否则进行局部飞行。天牛须算法具有寻优简洁快速的特点, 能提高蝴蝶算法的收敛速度和精度。经过测试, 验证了天牛须算法优化蝴蝶算法提高蝴蝶算法的收敛速度和精度、减小蝴蝶算

法陷入局部最优风险的能力。最后使用改进的 BOA 算法优化 BP 网络的权重和偏置, 从而提高网络预测的准确率。网络整体的流程如图 6 所示。

4 超宽带天线模型

改进的 BOA-BP 神经网络的建模目标为一现有的具有双陷波特性的蜂窝结构分形超宽带天线, 以下为天线设计过程^[16]。

4.1 蜂窝结构分形结构设计

该天线是具有陷波结构的超宽带天线, 超宽带特性通过 2 阶蜂窝结构来实现, 该结构将正六边形作为基本单元, 蜂窝结构的 0 阶分形结构是一个正六边形, 1 阶分形结构是在 0 阶分形结构的基础上正六边形以 $k=0.5$ 的比例缩小后沿六边形的 6 个边分别向外延伸, 得到一个边长与原来相同的正六边形。将 1 阶分形继续以比例 k 缩小, 然后重复 1 阶分形形成的过程, 即沿最外侧 6 个六边形的边分别向外延伸一个边长相同的六边形, 这就是 2 阶分形结构。该天线背面采用上侧开槽和两侧切角的结构以减少天线损耗、改善天线的阻抗匹配特性, 扩展天线带宽。分形迭代过程如图 7 所示。

4.2 陷波结构设计

为了方便引入陷波结构, 根据天线辐射贴片上中心区域和顶部电流密度较低的情况, 在辐射贴片中心挖去正六边形宽缝隙, 在辐射贴片上引入对称鱼钩形枝节产生一个陷波频段, 此外, 在馈线处嵌入宽为 0.4 mm 的倒 U 形窄缝隙, 产生另一段陷波特性, 得到天线的结构图如图 8 所示。

根据半波长谐振原理, 以上两种陷波结构加入后相当于在天线上加入半波长谐振器, 陷波结构的总长度为陷波中心频率对应波长的 1/2。天线工作在这一频率附近时, 大量的电流会聚集在陷波结构上, 造成阻抗失配, 产生陷波, 陷波中心频率与陷波结构长度的对应关系如下:

$$L = \frac{c}{f_{\text{notch}} \sqrt{2(\epsilon_r + 1)}}, \quad (19)$$

其中, f_{notch} 为陷波对应的中心频率, c 为光速, ϵ_r 为介质基板的相对介电常数。

4.3 设计结果

用电磁仿真软件 HFSS15.0 对天线的各个参数进行扫描, 得到天线的尺寸值如表 1 所示。

S_{11} 仿真结果如图 9 所示, 加入陷波结构以后的天线有 7~23 GHz 和 13~18 GHz 两个频段的陷波, 工作带宽为 5~20 GHz。




图 6 改进的 BOA 优化 BP 神经网络流程

Fig. 6 Improved BOA-optimized BP neural network flowchart




图 7 分形迭代过程

Fig. 7 Fractal iteration process

表 1 天线尺寸

Table 1 Antenna dimensions unit:mm (mm)					
参数	数值	参数	数值	参数	数值
L	25.00	W	18.00	W_r	2.00
L_r	3.00	L_{11}	10.00	L_{12}	3.50
L_b	2.20	L_H	6.50	W_u	1.60
L_u	5.20	W_f	2.89	L_f	6.40
W_t	4.20	L_t	4.50	W_s	2.89
L_s	4.50	L_g	6.20	S	0.40




图 8 天线结构图

Fig. 8 Antenna structure diagram




图 9 天线 S_{11} 曲线
Fig. 9 Antenna curve of S_{11}

5 实验仿真及结果分析

以双陷波特性的蜂窝结构分形超宽带天线的 S_{11} 为例,基于 MATLAB2022b 仿真平台将文中提出的改进的 BOA-BP 网络建模方法与其他建模方法进行比较,验证文中提出的建模方法的可行性^[17-21]。

首先,先在 HFSS 设计仿真超宽带天线中提取天线不同变量值及其对应的数据,用 HFSS 生成 128 016 个样

本,其中 6 个不同的天线参数作为输入, S_{11} 作为输出。将数据集的 80%作为训练集,其余 20%作为测试集。测试最大迭代次数为 500 次,采用含 3 个隐藏层的 BP 网络,其中 3 个隐含层的神经元个数分别为 5、4 和 7 个。分别统计用传统 BP 网络、蝴蝶算法优化的网络、改进后的蝴蝶算法优化的网络、粒子群算法优化的网络和遗传算法优化后的网络预测输出的准确率。

通过多次仿真测试发现,遗传算法和粒子群算法对网络的优化效果不但不稳定而且效果有待改进。改进后的蝴蝶算法不仅使优化后的网路更加稳定了而且有效的抑制了过拟合现象的发生。为了更加直观的感受改进的蝴蝶算法的优化效果,以下以同一组数据在采取不同优化方式的情况下网络的预测结果为例,对仿真结果进行分析:

BP 神经网络测试集预测结果、BOA 优化后网络和改进的 BOA 优化后测试集的预测结果:

图 10(a)、(b)、(c) 分别表示传统的 BP 神经网络、BOA-BP 神经网络、改进的 BOA-BP 神经网络对天线 S_{11} 参数的预测情况,从图中可以很清楚的观察到预测精度在不断提高,具体的预测精度可以从表 2 中的预测集误差大小中体现,其中改进的 BOA-BP 网络的平均误差只有 0.004 0(预测精度为 99.60%),相对未优化的 BP 神经网络和未改进的 BOA-BP 神经网络的误差 0.015 2 和 0.004 9 减少了很多。说明改进的 BOA-BP 算法可以有效地提高网络的预测精度。




图 10 未优化的 BP 神经网络测试集预测结果
Fig. 10 Unoptimized BP neural network test set prediction results

- 1) BOA 和改进的 BOA 寻优曲线:
图 11(a)、(b) 分别为 BOA 算法和用天牛须改进的 BOA 算法的寻优过程,从图中可以看出改进之后的 BOA 算法在第 70 轮以后优化速度和准确率有了很大的提升。说明加入了天牛须算法后 BOA 算法的寻优能力有了很大提高。
- 2) 未优化的 BP、BOA、改进的 BOA、遗传算法和粒

- 子群优化后的网络测试集预测结果:
图 12 为不同优化策略预测结果对比,可以看出不同算法优化后的 BP 神经网络的预测结果与真实值的拟合情况,其中改进 BOA 优化后的 BP 神经网络的预测曲线与真实值更加接近。为了更加清晰的体现拟合情况,对图像进行部分放大。
图 13 为图 12 的部分放大的结果,通过图 13 可以清




图 11 算法寻优过程比较

Fig. 11 Comparison of algorithm optimization processes




图 12 不同优化策略预测结果对比

Fig. 12 Comparison of the predicted results of different optimization strategies

楚的看出改进后的 BOA-BP 神经网络对应曲线与真实值对应曲线最接近。




图 13 不同优化策略预测结果放大对比

Fig. 13 Zoomed-in comparison of predicted results of different optimization strategies

不同优化方式对应的网络均方误差如表 2 所示。

通过以下仿真结果,可以看出传统 BP 网络、BOA-BP 网络和改进的 BOA-BP 网络的预测结果对真实结果的拟合情况整体向好。改进之后的 BOA 算法在第 60 轮

以后优化速度明显提升。最后通过图 10 和表 2 可以清楚的看到不同优化策略下预测值对真实值的拟合情况,其中改进的 BOA 算法的均方误差最小,拟合效果也最好。

表 2 不同优化策略误差结果

Table 2 Error results of different optimization strategies

优化方法	训练集误差	测试集误差
未优化	0.015 9	0.015 2
BOA 优化	0.004 9	0.004 9
改进的 BOA 优化	0.004 0	0.004 0
POS 优化	0.008 5	0.007 5
GA 优化	0.005 6	0.004 7

通过表 3 可得改进的 BOAS-BP 神经网络所需耗费的预测时间相比于 POS-BP 神经网络和 GA-BP 神经网络减小了 80.86%和 82.79%,说明改进的 BOA-BPNN 在运行时间有很大优势。

表 3 不同算法消耗时间

Table 3 Different algorithms consume time

优化方法	耗时/min
改进的 BOA	1.07
POS	5.59
GA	6.22

6 结 论

本文提出了一种用改进后的蝴蝶算法优化传统 BP 神经网络的策略。该策略将天牛须算法加入到蝴蝶算法的寻优过程中,提高了蝴蝶算法的寻优能力。将改进后的算法用于优化 BP 神经网络的权重和阈值,使网络的预测能力有了很大提升。

将该建模方法在现有的双陷波蜂窝结构分形超宽带天线上实操,通过仿真结果可以看出,与传统的蝴蝶算法相比,改进后的蝴蝶算法具有更高的收敛精度和更快的收敛速度。相比于现有文献中的用粒子群算法和遗传算法优化的网络,BOA 算法优化后的神经网络模型具有更高的预测精度,改进的 BOA 算法优化后的网络预测结果在未改进 BOA 算法优化后的网路预测结果的基础上获得了进一步的提升,与 POS-BP 神经网络和 GA-BP 神经网络相比,不仅网络的预测精度更高,还大大地缩短了网络的预测时间并且很好地抑制了网络的过拟合现象,为超宽带天线建模仿真提供了一种更好的选择,可以有效避免因使用遗传算法优化时数据样本大小不同导致结果不佳,或使用粒子群算法优化时初始种群大小不当而导

致的结果不佳等问题。能够更好的应用到射频微波器件中,验证了该文提出的方法的意义和可行性。

参考文献

- [1] PRASAD S, PUMICHAT R, ODDITI G. A novel planar ultra-wideband biconical antenna [C]. 2019 IEEE Asia-Pacific Microwave Conference (APMC), 2019: 542-544.
- [2] 南敬昌,刘银玲,高明明,等.具有双陷波特性的蜂窝结构分形超宽带天线 [J]. 电波科学学报, 2019, 34(2): 172-179.
NAN J CH, LIU Y L, GAO M M, et al. Fractal ultra-wideband antenna with honeycomb structure with double trap band [J]. Journal of Radio Science, 2019, 34(2): 172-179.
- [3] 宋虹莹. 基于粒子群优化算法的超宽带天线设计 [D]. 郑州: 郑州大学, 2016.
SONG H Y. Ultra-wideband antenna design based on particle swarm optimization algorithm [D]. Zhengzhou: Zhengzhou University, 2016.
- [4] 黄元君,楼平,吴志军,等. 新型自适应 RBF 神经网络应用于微带天线建模 [J]. 工程设计学报, 2014, 21(5): 426-431.
HUANG Y J, LOU P, WU ZH J, et al. A novel adaptive RBF neural network applied to microstrip antenna modeling [J]. Chinese Journal of Engineering Design, 2014, 21(5): 426-431.
- [5] 尚家川. 基于遗传算法、粒子群算法和人工神经网络的 RFID 标签天线优化方法的研究 [D]. 北京: 北京邮电大学, 2011.
SHANG J CH. Research on RFID tag antenna optimization method based on genetic algorithm, particle swarm algorithm and artificial neural network [D]. Beijing: Beijing University of Posts and Telecommunications, 2011.
- [6] 田雨波,董跃. 基于神经网络集成的微带天线谐振频率建模 [J]. 电波科学学报, 2009, 24(4): 610-616.
TIAN Y B, DONG Y. Resonant frequency modeling of microstrip antenna based on neural network integration [J]. Chinese Journal of Radio Science, 2009, 24(4): 610-616.
- [7] 南敬昌,曹馨元,高明明,等. 改进果蝇算法优化广义回归神经网络的双陷波超宽带天线建模 [J]. 激光与光电子学进展, 2021, 58(4): 413-421.
NAN J CH, CAO X Y, GAO M M, et al. Modeling of double-notch ultra-wideband antenna to optimize generalized regression neural network by improving Drosophila algorithm [J]. Progress in Laser and Optoelectronics, 2021, 58(4): 413-421.
- [8] 南敬昌,孙雯雯,杜有益,等. 一维卷积神经网络超宽带天线建模方法 [J]. 电子测量与仪器学报, 2023, 37(2): 204-210.
NAN J CH, SUN W W, DU Y Y, et al. Modeling method of 1D convolutional neural network ultra-wideband antenna [J]. Journal of Electronic Measurement and Instrumentation, 2023, 37(2): 204-210.
- [9] 董健,钦文雯,李莹娟,等. 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 [J]. 电子与信息学报, 2018, 40(11): 2712-2719.
DONG J, QIN W W, LI Y J, et al. Fast multi-target antenna design based on improved backpropagation neural network surrogate model [J]. Journal of Electronics & Information Technology, 2018, 40(11): 2712-2719.
- [10] 南敬昌,杜有益,王明寰,等. 深度学习架构神经网络对超宽带天线建模优化 [J]. 激光与光电子学进展, 2022, 59(13): 362-368.
NAN J CH, DU Y Y, WANG M H, et al. Modeling and optimization of ultra-wideband antenna by deep learning architecture neural network [J]. Advances in Laser and Optoelectronics, 2022, 59(13): 362-368.
- [11] 曾辉,王倩,夏学文,等. 基于自适应多种群的粒子群优化算法 [J]. 计算机工程与应用, 2018, 54(10): 59-65.
ZENG H, WANG Q, XIA X W, et al. Particle swarm optimization algorithm based on adaptive multiple swarms [J]. Computer Engineering and Applications, 2018, 54(10): 59-65.
- [12] 马创涛,邵景峰. 烟花算法改进 BP 神经网络预测模型及其应用 [J]. 控制工程, 2020, 27(8): 1324-1331.
MA CH T, SHAO J F. Fireworks algorithm improves BP neural network prediction model and its application [J]. Control Engineering, 2020, 27(8): 1324-1331.
- [13] 李国勇,闫芳,郭晓峰. 基于遗传算法的灰色神经网络优化算法 [J]. 控制工程, 2013, 20(5): 934-937.
LI G Y, YAN F, GUO X F. Grey neural network optimization algorithm based on genetic algorithm [J]. Control Engineering, 2013, 20(5): 934-937.
- [14] 高文欣,刘升,肖子雅,等. 柯西变异和自适应权重优化的蝴蝶算法 [J]. 计算机工程与应用, 2020, 56(15): 43-50.
GAO W X, LIU SH, XIAO Z Y, et al. Cauchy variation and adaptive weight optimization butterfly algorithm [J]. Computer Engineering and Applications, 2020, 56(15): 43-50.
- [15] 邵良杉,韩瑞达. 基于天牛须搜索的花朵授粉算法 [J]. 计算机工程与应用, 2018, 54(18): 188-194.

- SHAO L SH, HAN R D. Flower pollination algorithm based on longhorn beetle whisker search [J]. Computer Engineering and Applications, 2018, 54(18): 188-194.
- [16] ARORA S, ANAND P. Chaos-enhanced flower pollination algorithms for global optimization [J]. Journal of Intelligent & Fuzzy Systems: Applications in Engineering and Technology, 2017, 33(6): 3853-3869.
- [17] TUBISHAT M, ALSWAITTI M, MIRJALILI S, et al. Dynamic butterfly optimization algorithm for feature selection [J]. IEEE Access, 2020, 8: 194303-194314.
- [18] 张丹丹, 胡钢, 卢静, 等. 基于 GAD-BP 神经网络的短期负荷预测 [J]. 电子测量技术, 2019, 42(24): 143-147.
- ZHANG D D, HU G, LU J, et al. Short-term load prediction based on GAD-BP neural network [J]. Electronic Measurement Technology, 2019, 42(24): 143-147.
- [19] 宋伟, 张杨. 依赖神经网络的交通流量预测 [J]. 国外电子测量技术, 2019, 38(12): 27-31.
- SONG W, ZHANG Y. Traffic flow prediction relying on neural networks [J]. Foreign Electronic Measurement Technology, 2019, 38(12): 27-31.
- [20] 董勋, 郭亮, 高宏力, 等. 代价敏感卷积神经网络: 一种机械故障数据不平衡分类方法 [J]. 仪器仪表学报, 2019, 40(12): 205-213.
- DONG X, GUO L, GAO H L, et al. Substitute-sensitive convolutional neural network: A mechanical fault data imbalance classification method [J]. Chinese Journal of Scientific Instrument, 2019, 40(12): 205-213.
- [21] 申中一, 吕刚震, 王建祥. 基于变步长自适应线性神经网络的 PMSM 参数辨识 [J]. 电子测量技术, 2019, 42(23): 85-90.
- SHEN ZH Y, LYU G ZH, WANG J X. PMSM parameter identification based on variable-step adaptive linear neural network [J]. Electronic Measurement Technology, 2019, 42(23): 85-90.

作者简介



E-mail: nanjc886@sina.com

Nan Jingchang received the B. Sc. degree from Liaoning University of Engineering and Technology in 1993, the M. Sc. degree from Liaoning University of Engineering and Technology in 2003, and the Ph. D. degree from Beijing University of Posts and Telecommunications in 2007. He is now a professor in Liaoning University of Engineering and Technology. His research interests include RF circuit devices, multimedia information coding, and communication system simulation.



Huang Ju (Corresponding author) received the B. Sc. degree from Liaoning University of Engineering and Technology (LUET) in 2021. She is now a M. Sc. candidate at LUET. Her main research interests include intelligent wireless radio frequency, neural networks, etc.



Zhang Huimei received her B. Sc. degree from Fuyang Normal University in 2021. She is now a M. Sc. candidate at LUET. Her main research interests include miniaturized ultra-wideband antennas, multi-input and multi-output antennas, and so on.

南敬昌, 1993 年于辽宁工程技术大学获得学士学位, 2003 年于辽宁工程技术大学获得硕士学位, 2007 年于北京邮电大学获得博士学位。现为辽宁工程技术大学教授, 主要研究方向为射频电路器件、多媒体信息编码、通信系统仿真等。

黄菊(通信作者), 2021 年于辽宁工程技术大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为智能无线射频、神经网络等。

E-mail: 946387041@qq.com

张慧妹, 2021 年于阜阳师范大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为小型化超宽带天线、多输入多输出天线等。

E-mail: 1724498568@qq.com