

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

南敬昌, 曹馨元*, 高明明, 张沛泓

辽宁工程技术大学电子与信息工程学院, 辽宁 葫芦岛 125105

摘要 为实现对双陷波超宽带(UWB)天线的精准神经网络建模,提出了一种利用改进的果蝇算法(FOA)优化广义回归神经网络(GRNN)的建模方法。该方法通过扩大果蝇搜索范围,在味道判定公式中引入调整项来实现果蝇算法的改进,并用改进后的果蝇算法优化 GRNN 的光滑因子。这样可以避免果蝇算法陷入局部最优,提高模型预测精度。将该方法用于双陷波超宽带天线模型的建立中,并对天线的 S_{11} 参数和电压驻波比 V_{VSWR} 参数进行预测。结果表明,相比于 FOA-GRNN 建模方法和 GRNN 建模方法, S_{11} 参数的最大相对误差分别减小了 91.08% 和 99.14%; V_{VSWR} 参数的最大相对误差分别减小了 98.36% 和 99.18%,使超宽带天线建模精度得到提高,验证了该方法的可行性。

关键词 光计算; 广义回归神经网络; 双陷波超宽带天线; 果蝇算法; 局部最优; 光滑因子

中图分类号 TP391.9

文献标志码 A

doi: 10.3788/LOP202158.0420001

Improved Fruit Fly Algorithm to Optimize Generalized Regression Neural Network of Double Notch Ultra-Wideband Antenna Modeling

Nan Jingchang, Cao Xinyuan*, Gao Mingming, Zhang Peihong

School of Electronics and Information Engineering, Liaoning Technical University, Huludao, Liaoning 125105, China

Abstract In order to realize accurate neural network modeling for the dual notch ultra-wideband(UWB)antenna, a modeling method using the improved fruit fly algorithm (FOA) to optimize the generalized regression neural network (GRNN) is proposed. This method achieves the improvement of the fruit fly algorithm by expanding the search range of fruit flies, introducing adjustment items into the taste judgment formula, and using the improved fruit fly algorithm to optimize the smoothing factor of GRNN. In this way, the fruit fly algorithm can be prevented from falling into local optimum and the model prediction accuracy can be improved. This method is used in the establishment of the dual notch UWB antenna model, and the antenna S_{11} parameters and voltage standing wave ratio V_{VSWR} parameters are predicted. Experimental results show that, compared with the FOA-GRNN modeling method and the GRNN modeling method, the maximum relative error of the S_{11} parameter is reduced by 91.08% and 99.14%, respectively, and the maximum relative error of the V_{VSWR} parameter is reduced by 98.36% and 99.18%, respectively. The accuracy of UWB antenna modeling is improved, and the method feasibility is verified.

Key words optics in computing; generalized regression neural network; double notch ultra-wideband antenna; fruit fly algorithm; local optimal; smoothness factor

OCIS codes 200.4260; 230.4320; 230.2285

收稿日期: 2020-06-19; 修回日期: 2020-07-24; 录用日期: 2020-08-11

基金项目: 国家自然科学基金(61971210)、辽宁省特聘教授项目(551710007004)、辽宁省自然科学基金指导计划项目(20180550282)

*E-mail: 18240391566@163.com

1 引言

如今人们的生活早已和无线通信息息相关。其中,超宽带(UWB)天线因具有抗干扰性能强、传输速率高、保密性好、功率低等特性而受到广泛关注,已成为无线通信领域研究的热门课题^[1]。超宽带天线所覆盖的带宽极宽,其中包含了如无线局域网(WLAN, 5.15~5.85 GHz)和 IEEE 802.16 全球互通微波接入(WIMAX, 3.3~3.7 GHz)的窄带通信范围^[2]。为避免超宽带通信与窄带通信间产生的干扰而提出了陷波特性的超宽带天线。而传统用于天线设计仿真的射频微波 CAD 软件一直存在仿真过程繁琐、精度低、运行速度慢和占用计算机内存较大等问题,为解决这些问题,国内外相关领域研究者长期进行着广泛的研究,其中神经网络理论是重要的建模基础和发展方向,并取得了一定的研究成果^[3]。

神经网络因其强大的自学习自适应能力、并行处理的特点以及具有对多维复杂非线性关系进行建模的能力^[4],而受到研究学者们的青睐。在射频微波领域,神经网络建模已经得到了广泛的应用。Vilović 等^[5]使用粒子群优化(PSO)算法优化的人工神经网络,对神经网络的权重系数和学习因子寻优,应用于微带贴片天线设计中,可以不需要耗时和密集的计算就能对微带天线特性进行更准确的分析。Yan 等^[6]使用递归神经网络(RNN)提出了一种具有短期和长期记忆效应的功率放大器(PA)行为建模的新技术,可以准确地反映非线性电路的行为。Divakar 等^[7]使用知识基神经网络(KBNN)结合反向传播算法的建模方法,对圆环微带贴片天线谐振频率进行预测计算,通过比较预测结果与仿真测量结果,验证方法的可行性。文献[8]采用了广义回归神经网络(GRNN)对相干光正交频分复用(CO-OFDM)系统进行非线性系均衡,并通过仿真

验证其非线性均衡效果优于反向传播神经网络(BPNN)。GRNN 没有复杂的结构,参数设置也十分简单,还具有良好的非线性逼近能力,适用于处理非线性问题。但其光滑因子的取值直接影响着 GRNN 的预测结果,因此有研究者提出采用优化算法对 GRNN 进行优化,以提高预测精度。如文献[9]将遗传算法(GA)与 PSO 算法结合使用来优化 GRNN,文献[10-11]使用果蝇算法(FOA)优化 GRNN,通过对比测试结果,验证这些方法对预测精度有明显的改善。对于传统的果蝇优化算法容易陷入局部最优值,整体寻优速度慢,收敛精度不高等问题,一些研究学者提出了改进果蝇算法,如改进步长的果蝇优化算法^[12-13],通过在位置变化公式中引入可动态调节的步长值,使算法的全局探索能力得到了很大的提高。

针对上述建模方法结构复杂,预测精度不够理想等问题,本文提出了一种改进型果蝇算法优化 GRNN 的建模方法。通过将原始果蝇算法的二维搜索空间扩展为三维空间,并采用一个一行二列的随机矩阵来随机产生果蝇的初始位置;同时在味道判定公式中引入调整项来改进果蝇算法。这样可以扩大果蝇搜索范围,提高算法搜索能力,且避免因陷入局部极值而影响预测精度。进而利用改进后的果蝇算法对 GRNN 的光滑因子进行优化处理,这样所建模型可以提高对非线性问题的预测精度。将该方法用于对双陷波超宽带天线的建模中,验证了此建模方法的可行性。

2 建模基础

2.1 广义回归神经网络

GRNN 于 1991 年提出。它不需要复杂的迭代过程,具有高度并行的结构^[14]。GRNN 具有输入层、隐含层、求和层和输出层的四层结构。其结构如图 1 所示。




图 1 广义回归神经网络结构图

Fig. 1 Structure diagram of generalized regression neural network

输入的学习样本为 $\mathbf{X} = [x_1, x_2, \dots, x_n]^T$, 输出样本 $\mathbf{Y} = [y_1, y_2, \dots, y_k]^T$, n 和 k 均为一实数, 分别代表输入输出样本向量维度。隐含层第 i 个神经元输出为

$$p_i = \exp \left[-\frac{(\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i)}{2\sigma^2} \right], i = 1, 2, \dots, n, \quad (1)$$

式中: \mathbf{X}_i 为第 i 个神经元的训练样本; σ 为光滑因子, 决定了隐含层位置中基函数的形状^[15]。将求和层中分子层神经元 S_{Nj} 与分母层神经元 S_D 相除得到每个神经元的输出计算式为

$$y_j = \frac{S_{Nj}}{S_D} = \frac{\sum_{i=1}^n y_{ij} p_i}{\sum_{i=1}^n p_i}, j = 1, 2, \dots, k, \quad (2)$$

式中: y_{ij} 为隐含层的第 i 个神经元与求和层的第 j 个分子求和神经元之间的连接权值。

由(2)式可知, 使用 GRNN 进行天线预测建模时, 仅需要确定一个合适的光滑因子即可。当光滑因子 σ 的取值非常大时, $\frac{(\mathbf{X} - \mathbf{X}_i)^T (\mathbf{X} - \mathbf{X}_i)}{2\sigma^2}$ 趋于 0, 预测值近似等于所有样本因变量的均值; 反之, 当光滑因子趋于 0 时, 预测值则会更加接近训练样本, 但若遇到未包含在样本中的数据, 则所得到的预测结果有可能会非常差, 即出现过拟合现象。因此, 本文使用改进型 FOA 算法来寻找一个最佳的光滑因子。

2.2 果蝇优化算法

FOA 算法是一种基于果蝇的寻食行为寻找全局最优化的新方法^[16]。果蝇本身在感知方面优于其他物种, 由于果蝇拥有极为敏锐的嗅觉, 可以闻到远处的食物气味, 接近食物后再依靠优异的视觉能力确定食物位置及同伴位置, 并飞向该方向完成觅食过程。果蝇算法的具体步骤如下。

1) 确定初始果蝇的随机位置 (X_0, Y_0) 、种群大小 s_{sizepop} 和最大迭代次数 M_{Maxgen} 。

2) 记录第 l 个果蝇寻找食物的随机方向和距离为

$$X(l) = X_0 + r_{\text{rand}}, \quad (3)$$

$$Y(l) = Y_0 + r_{\text{rand}}, \quad (4)$$

式中: l 为种群数量, 即果蝇的个数, $l = 1, 2, \dots, s_{\text{sizepop}}$ 。

3) 计算出第 l 个果蝇个体到原点之间的距离 $D(l)$, 然后求其倒数作为该果蝇的味道浓度判定值 $S(l)$ 。

$$D(l) = \sqrt{X(l)^2 + Y(l)^2}, \quad (5)$$

$$S(l) = \frac{1}{D(l)}. \quad (6)$$

4) 将步骤 3 所得到的 $S(l)$ 替换为气味浓度判断函数(或称为适应度函数), 以便找到果蝇各个位置的味道浓度 $\text{Smell}(l)$ 。

$$\text{Smell}(l) = \text{Function}[S(l)]. \quad (7)$$

5) 寻找味道浓度的极值, 求最大值时取最高的味道浓度, 反之, 求最小值时则取最低味道浓度。并保留此时最佳味道浓度值 $S_{\text{bestSmell}}$ 及该值的位置坐标 $I_{\text{bestindex}}$ 。

$$[S_{\text{bestSmell}} I_{\text{bestindex}}] = \min[\text{Smell}(l)]. \quad (8)$$

6) 重复上述步骤 2~5 来开始寻优迭代, 判断味道浓度是否优于先前的味道浓度, 若优于则记录当次最优值及其位置坐标。

3 改进型 FOA 优化 GRNN 的算法

3.1 改进型果蝇优化算法

果蝇算法具备算法简单易懂、优化参数少、应用广等优势条件。但传统的 FOA 算法也存在着自身缺陷, 搜索空间为二维空间, 搜索范围有所局限, 搜索力度不强, 易陷入局部最优值, 导致过早收敛影响预测精度。对此, 本文对 FOA 算法做出了如下改进。

1) 将原始的果蝇算法搜索的空间范围扩展到三维空间。

2) 果蝇算法的初始位置对果蝇搜索能力存在直接影响^[17]。原始果蝇算法初始位置由 $[0, 1]$ 区间随机产生一个随机值, 本文改进算法合理扩大随机值范围且每一个维度都产生一行二列服从 $0 \sim 1$ 均匀分布的随机矩阵作为初始值, 提高了果蝇的初始搜索能力。

3) 在果蝇迭代寻优过程中, 每一代果蝇都飞向适应度值最高的果蝇个体, 判定其方位并向该位置聚集^[18]。当用果蝇算法优化 GRNN 光滑因子时, 若与原点间距离值过大, 则会导致光滑因子极小, 这可能会使果蝇寻优到个体极值, 而使整个算法陷入局部最优。为了避免这一情况, 本文改进型果蝇算法在味道浓度判定函数 $S(l)$ 中添加一个调整项 β , 以跳出局部最优值。具体改进为

$$\begin{cases} S(l) = \frac{1}{D(l)} + \beta \\ \beta = \max[D(l)] + \exp\left(\frac{g_{\text{gen}}}{M_{\text{Maxgen}}}\right) \times \frac{r_{\text{rand}}}{2} \end{cases}, \quad (9)$$

式中: g_{gen} 为当前迭代次数。

3.2 改进型 FOA 优化 GRNN 的算法

1) 随机初始化果蝇的位置 (X_0, Y_0, Z_0) , 本文将果蝇算法的搜索空间扩展到三维空间, 且初始位置

由一个一行二列的随机矩阵生成,以扩大果蝇初始搜索范围,提高搜索能力。

$$\begin{cases} X_0 = 50 \times \text{rand}(1,2) \\ Y_0 = 50 \times \text{rand}(1,2) \\ Z_0 = 50 \times \text{rand}(1,2) \end{cases} \quad (10)$$

2)在初始位置基础上加一个随机值 r_{rand} ,用来赋予果蝇初始飞行方向。

$$\begin{cases} X(l) = X_0 + r_{\text{rand}} \\ Y(l) = Y_0 + r_{\text{rand}} \\ Z(l) = Z_0 + r_{\text{rand}} \end{cases} \quad (11)$$

3)计算果蝇到原点之间的距离 $D(l)$,并将其倒数加上一个调整因子 β 作为味道浓度判定函数 $S(l)$,即为待优化的初始光滑因子。令初始调整因子 $\beta=0$ 。

$$\begin{cases} D(l) = \sqrt{X(l)^2 + Y(l)^2 + Z(l)^2} \\ S(l) = \frac{1}{D(l)} + \beta \end{cases} \quad (12)$$

4)创建 GRNN,代入 $S(l)$ 作为光滑因子,提取训练样本数据,并将其等分两组进行交叉训练,即一组用于训练网络,一组用于测试数据,并求其测试结果的均方根误差(RMSE)作为适应度函数,该适应度值为味道浓度值 $\text{Smell}(l)$;再调换这两组数据,分别训练和测试网络,同样求其味道浓度值,这样可以避免训练过度。求得最小的 $\text{Smell}(l)$ 值即为初始优化得到的最佳味道浓度值 $S_{\text{bestSmell}}$,此时的 $S(l)$ 为初始优化得到的 GRNN 光滑因子。

$$\begin{cases} \text{Function}[S(l)] = E_{\text{RMSE}} = \sqrt{\frac{\sum_{t=1}^M (\hat{y}_t - y_t)^2}{M}} \\ [S_{\text{bestSmell}} I_{\text{bestindex}}] = \min[\text{Smell}(l)] \end{cases} \quad (13)$$

5)迭代开始,令 $g_{\text{gen}} = 1, 2, \dots, M_{\text{Maxgen}}$ 。重复步骤 2~4 的过程。其中味道浓度判定函数 $S(l)$ 为

$$\begin{cases} S(l) = \frac{1}{D(l)} + \beta \\ \beta = \max[D(l)] + \exp\left(\frac{g_{\text{gen}}}{M_{\text{Maxgen}}}\right) \times \frac{r_{\text{rand}}}{2} \end{cases} \quad (14)$$

6)当迭代次数达到最大迭代次数 M_{Maxgen} 时,则停止迭代,此时得到的最佳味道浓度值 $S_{\text{bestSmell}}$,则是经过优化所收敛到的最小 RMSE 值;此时所对应的 $S(l)$,即为最终优化得到的最佳 GRNN 的光滑因子。

4 基于改进型 FOA-GRNN 的双陷波超宽带天线建模

4.1 天线结构及陷波特性的分析

图 2 为本文采用的小型化双陷波超宽带天线的结构图。该天线采用的介质基板厚度为 1 mm,长为 31 mm,宽为 18 mm;将该天线矩形辐射片的两侧切角顶部挖半圆凹槽,凹槽内设有 T 形枝节,半圆凹槽半径为 8.8~9.2 mm,切角水平长度为 5.8~6.2 mm,竖直长度为 8.5~9.0 mm,T 形枝节上部长度为 12.5~13.5 mm,竖直长度为 7.8~8.0 mm;微带馈线长为 13~14 mm,宽为 1.5 mm,且刻蚀有缝隙宽度为 0.19 mm 的 U 形窄缝隙;接地板顶部又设对称切角,其水平长为 3~5 mm,竖直长为 3~4 mm。




图 2 双陷波超宽带天线的结构图

Fig. 2 Structure diagram of dual notch UWB antenna

用高频结构仿真(HFSS)对本文所设计的双陷波特性超宽带天线进行射频特性的建模仿真。图 3 为该天线的 HFSS 仿真结果图。图 3(a)为双陷波超宽带天线的 S_{11} 特性曲线,可以看出,当 $S_{11} < -10$ dB 时,带宽范围为 2.8~12.3 GHz,并且在 3.23~3.7 GHz 和 8.01~8.66 GHz 两个频段产生良好的陷波特性的,有效地将 WiMAX 和国际电信联盟两种窄带信号带来的电磁干扰滤除掉。图 3(b)为双陷波超宽带天线的电压驻波比 V_{VSWR} 特性曲

线,可以看出,该天线在 2.8~12.3 GHz 的带宽范围内的电压驻波比 $V_{VSWR} < 2$ 。同时,在两个产生较好的陷波特性的频段,即 3.23~3.7 GHz 和 8.01~8.66 GHz 内,频段内的电压驻波比 $V_{VSWR} > 2$ 。且对应两个陷波频段分别覆盖了 WiMAX (3.3~3.6 GHz) 和国际电信联盟(8.01~8.5 GHz),滤除了两种窄带通信系统产生的电磁干扰。

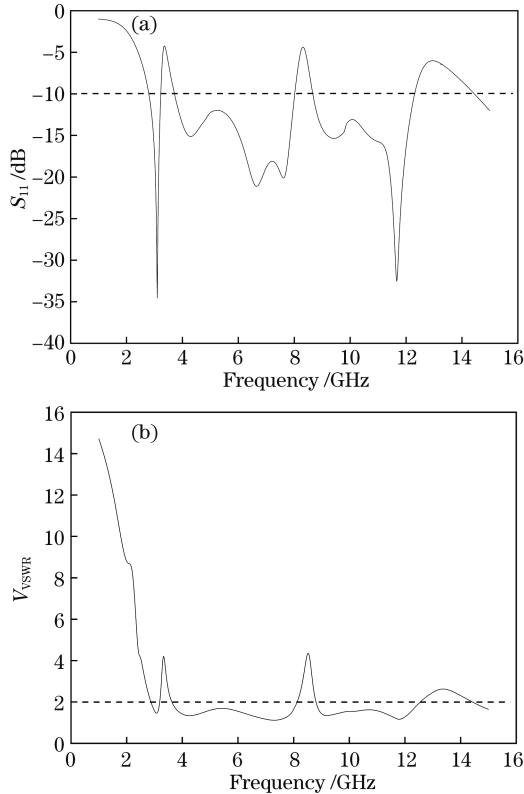


图 3 双陷波超宽带天线的 HFSS 仿真结果。(a) S_{11} 特性曲线;(b) V_{VSWR} 特性曲线
Fig. 3 HFSS simulation results of dual notch UWB antenna. (a) S_{11} characteristic curve; (b) V_{VSWR} characteristic curve

如果只使用 HFSS 仿真软件来设计宽带天线和研究天线特性,则会出现操作过程复杂、耗时长、占用计算机内存资源等问题。而使用神经网络模型对天线建模则可以大幅加快设计进程。神经网络模型可以很好地学习天线参数和响应之间的关系,所得到的具备天线特性的模型可以替代繁琐的电磁软件仿真,将天线参数输入模型中就可以快速预测其对应的响应特性,从而提升设计速度。

4.2 基于改进型 FOA-GRNN 的双陷波超宽带天线建模过程

根据算法流程,改进型 FOA-GRNN 双陷波超宽带天线建模的具体过程如下。

1) 提取天线的 S_{11} 和 V_{VSWR} 数据,并将每个参数的

数据样本都以同样的比例分为训练样本和预测样本。

2) 设置种群规模 $s_{sizepop} = 20$ 和最大迭代次数 $M_{Maxgen} = 100$,设置果蝇随机初始位置同时随机赋予果蝇搜寻目标的方向。

3) 计算果蝇到原点之间的距离 $D(l)$,并将其倒数作为对应的光滑因子值。

4) 将 GRNN 测试数据的 RMSE 作为适应度函数,代入光滑因子值,计算个体浓度值 $Smell(l)$ 。

$$E_{RMSE} = \sqrt{\frac{\sum_{t=1}^M (\hat{y}_t - y_t)^2}{M}}, \quad (15)$$

式中: M 为一个实数,表示预测样本总数量; \hat{y}_t 为第 t 组预测样本的 GRNN 预测输出值; y_t 为对应的实际目标输出值, $t = 1, 2, \dots, M$ 。

5) 找出果蝇群体中浓度值 $Smell(l)$ 最小的个体(即 RMSE 值最小),记录此时最优浓度值 $S_{bestSmell}$ 并保留该个体位置。

6) 判断当前的迭代次数是否达到最大,若是,则输出最佳光滑因子,若否,则循环执行步骤 3~5 直至达到最大迭代次数。

7) 将优化得到的最佳光滑因子输入 GRNN 并建立模型。其建模流程如图 4 所示。

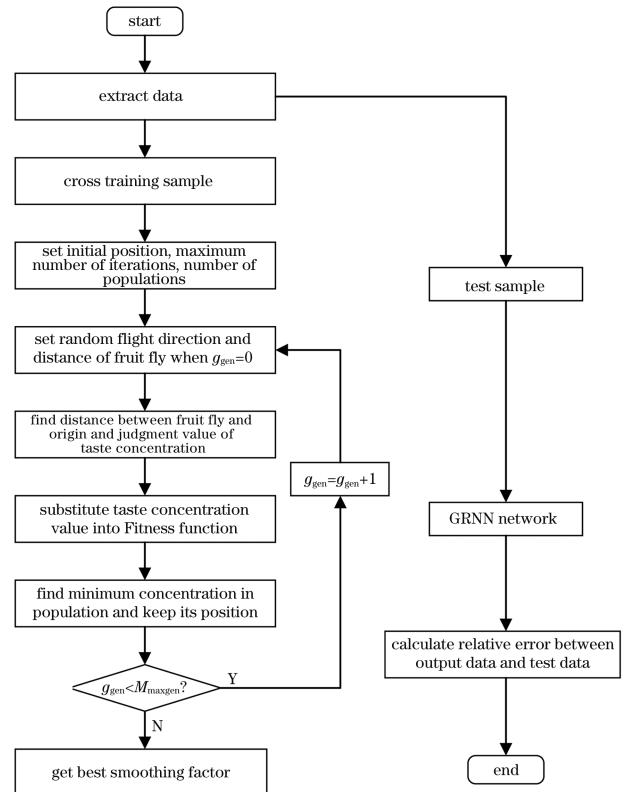


图 4 改进型 FOA-GRNN 的双陷波超宽带天线建模流程图
Fig. 4 Flow chart of improved FOA-GRNN double notch UWB antenna modeling

5 实验验证与仿真分析

以双陷波超宽带天线 S_{11} 和 V_{VSWR} 的关系为例, 将本文建模方法的预测结果与未改进的 FOA-GRNN 建模方法、GRNN 建模方法和 HFSS 仿真的所得结果进行比较分析, 验证本文建模方法的可行性。

用 HFSS 设计仿真超宽带天线, 提取天线 S_{11} 与频率 f 的数据及驻波比 V_{VSWR} 与 f 的数据, 设置扫频范围为 1~15 GHz, 以 0.01 GHz 为步长, 每个参数的数据均提取 1400 组, 从中分别选取 1200 组数据作为训练样本, 取 120 组作为预测数据。本文建模方法与 FOA-GRNN 建模方法和 GRNN 建模方法使用相同的训练样本和预测样本, 并按照上节所述的建模过程来训练模型, 在 MATLAB R2015a 上实现建模以及模型的训练和预测。

其中 FOA-GRNN 建模方法和本文建模方法均设定迭代次数为 100 次, 设置相同的种群数量。图 5 为 FOA 算法的优化过程, 图 6 为本文改进型

FOA 算法的优化过程。可以看出, FOA 算法优化 GRNN 光滑因子, 经过 100 次迭代计算, 在第 3 代开始收敛, 到第 37 代收敛结束, 对应最小的 RMSE 为 0.2141; 而本文改进型 FOA 算法的优化过程在第 2 代开始收敛到第 33 代结束, 得到对应最小 RMSE 为 0.210。本文改进型 FOA 优化算法的收敛情况更好, 收敛速度更快, 收敛得到更小的 RMSE。

对于提取的 120 组预测数据, 利用三种建模方法求出频率 f 对应的 S_{11} 值与 HFSS 仿真实际输出拟合情况如图 7 所示, 与频率 f 对应的驻波比 V_{VSWR} 值与 HFSS 仿真的实际输出拟合情况如图 8 所示。由图 7 和图 8 可以看出, 三种神经网络建模




图 5 FOA 算法的优化过程

Fig. 5 Optimization process of FOA algorithm




图 6 改进型 FOA 算法的优化过程

Fig. 6 Optimization process of improved FOA algorithm

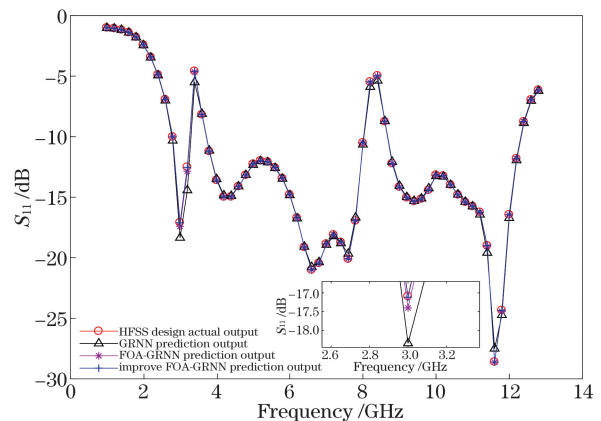


图 7 三种建模方法输出频率 f 对应的 S_{11} 值与 HFSS 仿真实际输出拟合情况

Fig. 7 Fitting situation of S_{11} corresponding to output frequency f of three modeling methods with actual output of HFSS simulation

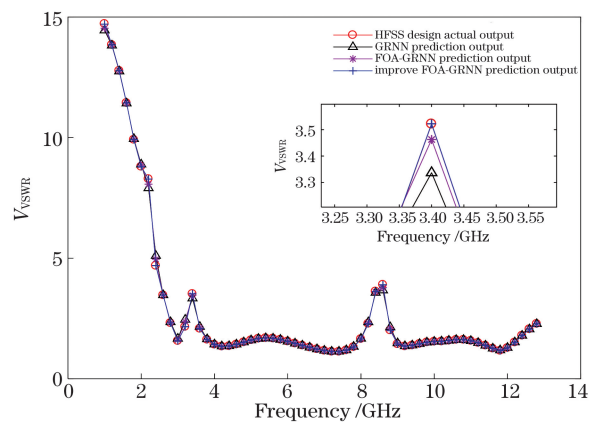


图 8 三种建模方法输出频率 f 对应的 V_{VSWR} 值与 HFSS 仿真实际输出拟合情况

Fig. 8 Fitting situation of V_{VSWR} corresponding to output frequency f of three modeling methods with actual output of HFSS simulation

方法都可以拟合超宽带天线的 S_{11} 参数和驻波比 V_{VSWR} 参数。由插图可以看出,在频率为 3 GHz 附近,即天线出现陷波特性的地方,GRNN 建模方法和 FOA-GRNN 建模方法都不能完全拟合 HFSS 的仿真输出曲线,存在着一定的误差。其中,GRNN 建模方法的预测输出曲线明显比 FOA-GRNN 建模方法的预测输出曲线更偏离实际输出曲线。而本文改进型 FOA-GRNN 建模方法的预测输出曲线可以很好地拟合天线的 S_{11} 参数曲线和 V_{VSWR} 参数曲线,预测仿真过程中的误差更小。这是由于改进型 FOA-GRNN 模型的光滑因子小于 FOA-GRNN 模型和 GRNN 模型的光滑因子,进而使得模型预测输出值更接近预测样本的实际输出值。

对比三种模型可以发现,本文改进型 FOA-GRNN 模型的预测误差最低,可以很好地实现非线性拟合;而 FOA-GRNN 模型的拟合略差于本文方

法,精度略低,但相比于 GRNN 模型,前两个模型的泛化能力更好。

表 1 和表 2 给出了三种建模方法对天线部分 S_{11} 参数和 V_{VSWR} 参数的预测结果以及预测相对误差。由表 1 和表 2 的部分预测结果可见,本文改进型 FOA-GRNN 模型对 S_{11} 参数的预测相对误差的绝对值最大为 0.0113%,对 V_{VSWR} 参数的预测相对误差的绝对值最大为 0.0018%,FOA-GRNN 模型对应的最大值为 0.1267%和 0.11%,而 GRNN 模型对应的最大值则为 1.3201%和 0.2208%。本文建模方法预测 S_{11} 参数的最大相对误差分别比 GRNN 建模方法和 FOA-GRNN 建模方法减少了 91.08%和 99.14%; V_{VSWR} 参数的最大相对误差分别减小了 98.36%和 99.18%。说明改进型 FOA-GRNN 有很好的优化效果,使用改进型 FOA-GRNN 方法对超宽带天线建模的精度较高。

表 1 三种建模方法对天线 S_{11} 参数的部分预测结果以及预测相对误差

Table 1 Partial prediction results of antenna S_{11} parameters by three modeling methods and relative prediction errors

Actual output /dB	GRNN		FOA-GRNN		Improved FOA-GRNN	
	Predictive value /dB	Relative error /%	Predictive value /dB	Relative error /%	Predictive value /dB	Relative error /%
-1.06193	-1.06761	0.5348	-1.06242	0.0461	-1.06198	0.0041
-1.10881	-1.11575	0.6253	-1.10947	0.0592	-1.10887	0.0052
-1.17474	-1.18387	0.7780	-1.17561	0.0740	-1.17481	0.0066
-1.26585	-1.27775	0.9400	-1.26699	0.0896	-1.26596	0.0079
-1.77476	-1.79819	1.3201	-1.77701	0.1267	-1.77497	0.0113
-4.88503	-4.93705	1.0605	-4.88995	0.1008	-4.88547	0.0089
-5.82055	-5.88455	1.0996	-5.82652	0.1025	-5.82108	0.0091
-6.93023	-7.07922	1.2840	-6.93834	0.1170	-6.93095	0.0103

表 2 三种建模方法对天线 V_{VSWR} 参数的部分预测结果以及预测相对误差

Table 2 Partial prediction results of antenna V_{VSWR} parameters by three modeling methods and relative prediction errors

Actual output /dB	GRNN		FOA-GRNN		Improved FOA-GRNN	
	Predictive value /dB	Relative error /%	Predictive value /dB	Relative error /%	Predictive value /dB	Relative error /%
1.601681	1.599510	-0.1355	1.600599	-0.0675	1.601663	-0.0011
1.637008	1.634142	-0.1751	1.635580	-0.0872	1.636985	-0.0014
1.664341	1.660957	-0.2003	1.662654	-0.1013	1.664313	-0.0016
1.682230	1.678550	-0.2187	1.680395	-0.1090	1.682200	-0.0017
1.689849	1.686117	-0.2208	1.687989	-0.1100	1.689818	-0.0018
1.674378	1.671216	-0.1888	1.672805	-0.0939	1.674353	-0.0015
1.652895	1.650250	-0.1600	1.651582	-0.0794	1.652874	-0.0013
1.624062	1.621990	-0.1270	1.623039	-0.0629	1.624045	-0.0010

6 结 论

本文提出一种改进型果蝇算法优化广义回归神经网络的建模方法。通过将原始果蝇算法的二维搜索空间扩展为三维空间,并采用一个一行二列的随机矩阵来随机产生果蝇的初始位置;同时在味道判定公式中引入调整项来实现果蝇算法的改进。这样可以扩大果蝇搜索范围,使果蝇算法很好地跳脱出局部极值,而后用改进型 FOA 优化 GRNN 光滑因子并建立模型。改进型 FOA 与传统 FOA 相比,可以更快完成收敛,收敛得到对应的 RMSE 更小,精度更高。将该建模方法用在双陷波超宽带天线建模中,并与 FOA-GRNN 和 GRNN 两种建模方法的仿真结果进行比较,验证了本文方法有较高的预测精度和非线性预测能力,可以很好地应用于射频微波器件的设计研究中。

参 考 文 献

- [1] Hou H C. Analysis and design of band-notched UWB antenna[D]. Jinan: Shandong University of Science and Technology, 2018: 13-14.
侯焕存. 陷波超宽带天线研究与设计[D]. 济南: 山东科技大学, 2018: 13-14.
- [2] Singh C, Kumawat G. A compact rectangular ultra-wideband microstrip patch antenna with double band notch feature at wi-max and WLAN [J]. *Wireless Personal Communications*, 2020, 114 (3): 2063-2077.
- [3] Wang H J, Jin T, Men K N. Application of FA-LMBP hybrid neural network algorithm in image compression[J]. *Laser & Optoelectronics Progress*, 2019, 56(19): 191005.
王海军, 金涛, 门克内木乐. FA-LMBP 混合神经网络算法在图像压缩中的应用[J]. *激光与光电子学进展*, 2019, 56(19): 191005.
- [4] Chen H W, Yu Z M, Zhang T, et al. Advances and challenges of optical neural networks [J]. *Chinese Journal of Lasers*, 2020, 47(5): 0500004.
陈宏伟, 于振明, 张天, 等. 光子神经网络发展与挑战[J]. *中国激光*, 2020, 47(5): 0500004.
- [5] Vilović I, Burum N, Brailo M. Microstrip antenna design using neural networks optimized by PSO[C]// *International Conference on Applied Electromagnetics and Communications (ICECom)*, Oct. 14-16, 2013, Dubrovnik, Croatia, 2013, 1-4.
- [6] Yan S, Zhang C, Zhang Q J. Recurrent neural network technique for behavioral modeling of power amplifier with memory effects [J]. *International Journal of RF and Microwave Computer-Aided Engineering*, 2015, 25(4): 289-298.
- [7] Divakar T, Panda D C. Resonant frequency calculation of circular ring microstrip patch antenna using knowledge based neural network [C] // *2014 International Conference on Electronics and Communication Systems (ICECS)*, February 13-14, 2014, Coimbatore, India. New York: IEEE Press, 2014: 1-3.
- [8] Wu J D, Lu J, Ren H L, et al. Nonlinear equalizer based on general regression neural network in coherent optical OFDM system [J]. *Acta Optica Sinica*, 2018, 38(9): 0906002.
吴金达, 卢瑾, 任宏亮, 等. 基于广义回归神经网络的 CO-OFDM 系统非线性均衡 [J]. *光学学报*, 2018, 38(9): 0906002.
- [9] Agarkar P, Hajare P, Bawane N. Optimization of generalized regression neural networks using PSO and GA for non-performer particles [C] // *2016 IEEE International Conference on Recent Trends in Electronics, Information & Communication Technology (RTEICT)*, May 20-21, 2016, Bangalore, India. New York: IEEE Press, 2016: 103-107.
- [10] Nie N N, Wang Y B, Wang M Z, et al. Safety prediction of mine tailing reservoir based on FOA-GRNN algorithm [J]. *Journal of Safety Science and Technology*, 2014, 10(8): 39-45.
聂娜娜, 王英博, 王铭泽, 等. FOA 优化 GRNN 网络的尾矿库安全预测 [J]. *中国安全生产科学技术*, 2014, 10(8): 39-45.
- [11] Wang S H, Qin S L. Temperature prediction of nano-iron powder decomposing furnace based on FOA-GRNN [J]. *China Measurement & Test*, 2017, 43(4): 100-104.
王盛慧, 秦石凌. 基于 FOA-GRNN 的纳米铁粉分解炉温度预测 [J]. *中国测试*, 2017, 43(4): 100-104.
- [12] Zhu F Z, Zou H, Ding G S. An improved fruit fly optimization with changing step [J]. *Microelectronics & Computer*, 2018, 35(6): 36-40.
朱富占, 邹海, 丁国绅. 改进的变步长果蝇优化算法 [J]. *微电子学与计算机*, 2018, 35(6): 36-40.
- [13] Guo X D, Wang L F, Zhang X L. Fruit fly optimization algorithm based on adaptive step size [J]. *Journal of North University of China (Natural Science Edition)*, 2016, 37(6): 570-575.
郭晓东, 王丽芳, 张学良. 基于自适应步长的果蝇优化算法 [J]. *中北大学学报(自然科学版)*, 2016, 37(6): 570-575.
- [14] Huang H B, Xie Z H. Generalized regression neural network optimized by genetic algorithm for solving

- out-of-sample extension problem in supervised manifold learning [J]. *Neural Processing Letters*, 2019, 50(3): 2567-2593.
- [15] Yu S M, Lu W, Liang K, et al. Study on prediction of germination rate of rice seeds using hyperspectral imaging combined with PCA and GRNN[J]. *Laser & Optoelectronics Progress*, 2015, 52(11): 113001.
于施淼, 卢伟, 梁琨, 等. 基于高光谱成像技术结合 PCA-GRNN 的糙米发芽率检测方法研究 [J]. *激光与光电子学进展*, 2015, 52(11): 113001.
- [16] Pan W T. A new fruit fly optimization algorithm: taking the financial distress model as an example[J]. *Knowledge-Based Systems*, 2012, 26:69-74.
- [17] Pi J, Ma S, Zhang Q Q, et al. Aero-engine exhaust gas temperature prediction model based on IFOA-GRNN[J]. *Journal of Aerospace Power*, 2019, 34(1): 8-17.
皮骏, 马圣, 张奇奇, 等. 基于改进果蝇算法优化的 GRNN 航空发动机排气温度预测模型 [J]. *航空动力学报*, 2019, 34(1): 8-17.
- [18] Wang L F, Deng L, Liu P. Improved fruit fly optimization based hysteresis Bouc-Wen model identification of piezoelectric precision positioning stages[J]. *Computer Engineering and Applications*, 2020, 56(2): 242-247.
王龙飞, 邓亮, 刘萍. 基于改进果蝇优化的压电精密定位平台迟滞 Bouc-Wen 模型辨识 [J]. *计算机工程与应用*, 2020, 56(2): 242-247.