

改进蚁群算法的 BRBP 神经网络功放逆向建模方法

南敬昌, 臧净*, 高明明

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 针对 BP(back propagation)神经网络直接逆向模型精度低、耗时长、易振荡等缺点,提出一种联合改进蚁群算法(IACO)与贝叶斯正则化算法(BR)的 BP 神经网络逆向建模方法。通过改进蚁群算法,根据搜索阶段设置挥发因子、路径优劣程度更新信息素,并在启发式因子中考虑出发点、终点与各节点的间距等,优化正向模型的权值,提高整体模型精度;之后使用 $L_{1/2}$ 范数的贝叶斯正则化算法逆向迭代正向模型的输入,达到提高网络稳定性的目的。将本文方法应用于可重构功率放大器中,实验结果表明:相比于直接逆向建模方法和自适应 η 逆向建模方法,本文方法的建模精度分别提高 99.77%、90.70%,平均运行时间分别减少 35.76%、2.05%;本文方法可降低功放设计的复杂度,提高其设计速度。

关键词 光计算;神经网络逆向建模;改进蚁群算法;贝叶斯正则化; $L_{1/2}$ 正则子;可重构功率放大器

中图分类号 TP391.9

文献标志码 A

doi: 10.3788/LOP57.012001

Reverse Modeling Method for BRBP Neural Network Power Amplifier Based on Improved Ant Colony Algorithm

Nan Jingchang, Zang Jing*, Gao Mingming

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

Abstract Considering the disadvantages of the direct inverse model for the back propagation (BP) neural network, such as low precision, excessive time consumption, and easy to concussion, this paper proposes an inverse modeling method for the BP neural network that combines an improved ant colony algorithm and a Bayesian regularization algorithm. This method improves the ant colony algorithm, which sets the volatilization factor based on the search stage, updates the pheromone based on the degree of pros and cons of the path, and considers the distance between the starting point and the nodes and the distance between the end point and the nodes in the heuristic factor, to optimize the weight of the forward model and improve the accuracy of the overall model. Then the Bayesian regularization algorithm with $L_{1/2}$ norm is used to reverse the input of the forward model, which improves the stability of the network. It is applied to a reconfigurable power amplifier. Experimental results show that the accuracy of the method, compared with that of the direct inverse modeling method and the adaptive η inverse modeling method, is improved by 99.77% and 90.70%, respectively, with the average running time for the modeling being shorten by 35.76% and 2.05%, respectively. Thus, the complexity of designing a power amplification module is reduced and its design speed is accelerated.

Key words optics in computing; neural network inverse modeling; improved ant colony algorithm; Bayesian regularization; $L_{1/2}$ regular child; reconfigurable power amplifier

OCIS codes 200.4260; 250.4480; 230.2285

1 引言

动态射频微波模块一般使用计算机辅助设计

(CAD)软件进行辅助设计,但设计步骤繁琐,难以实现,且优化仿真得到目标参数需要花费大量的时间。用具有逼近任意非线性映射关系、并行处理、自

收稿日期: 2019-06-22; 修回日期: 2019-07-13; 录用日期: 2019-07-22

基金项目: 国家自然科学基金青年科学基金(61701211)、国家自然科学基金(61372058,61971210)、辽宁省特聘教授项目(551806006)、辽宁省高校重点实验室项目(LJZS007)

* E-mail: 2681318835@qq.com

学习等特点的神经网络逆向建模方法^[1]代替仿真软件应用到射频微波电路设计中,能够精确快速地求解出与目标参数对应的结构参数,以简化模块设计步骤、缩短电路设计时间,因此研究神经网络逆向建模方法对射频微波模块的设计具有重要的现实意义。

在神经网络逆向建模中,直接逆向模型^[2-3]通过交换神经网络的输入和输出就可以立刻综合出对应于系统响应的元件结构参数,虽然建模速度加快,但是输入与输出之间会存在多值映射的问题,无法确定它的唯一性和收敛性。Linden 等^[4]首次提出基于梯度下降法的神经网络逆向模型迭代算法,即通过迭代更新,输入参量最小化均方误差以近似目标输入。Mareddy 等^[5]提出一种基于共轭梯度算法的神经网络逆向建模方法,该方法将建立的具有最小误差的候选逆模型作为理想逆模型,该逆模型与原模型互补则可得到精确的模型。Kabir 等^[6]提出一种通过分组数据建立子逆模型的方法,解决了数据中的多解问题。Wang 等^[7]引入几个级联卷积神经网络模块,为实时求解大规模电磁逆散射问题提供了一种新的方法。Lui 等^[8]将深度网络用于光子器件的逆向设计中,通过在串联架构中组合正演模拟和逆向设计,克服了非唯一性问题。Xu 等^[9]、黄炳家等^[10]及李洋等^[11]提出带 $L_{1/2}$ 正则化项的神经网络逆向迭代算法,该算法保证在训练过程中输入的向量序列是稳定及稀疏的。在蚁群算法中,Meng 等^[12]使用自适应伪随机选择规则和动态调整挥发因子更新路径中的信息素,该方法可以改善路径的收敛速度和路径寻优的效率。俞焯等^[13]通过更新局部和全局信息素,使得蚂蚁对最优路径的搜索更具导向性和全局性,在提高寻优效率的同时能够避免陷入局部最优。袁琴琴等^[14]提出加大最好路径信息素和最差路径信息素的区分程度,促使蚁群算法(ACO)收敛加快,同时设置门限值,保证信息素不会过快增加或者减小。

针对上述逆向建模方法精度不够理想、建模过程复杂等问题,本文提出一种联合改进蚁群算法(IACO)与贝叶斯正则化算法(BR)的BP神经网络逆向建模方法,即IACO-BRBP方法。首先改进蚁群算法,即在不同的阶段设置不同的挥发因子、根据路径优劣程度更新信息素并在启发式因子中考虑出发点、终点与各节点的间距等,使蚁群能够遍历全局并可以快速有效地搜索到全局最优解,进而优化BRBP神经网络正向模型的权值;采用优化后的权

值和规则化函数为 $L_{1/2}$ 范数的贝叶斯正则化方法迭代更新输入参量,以获得更佳的结构参数。这样不仅可以平滑网络输出,提高泛化能力和稳定性,而且能够稀疏网络,缩短建模的运行时间。将该方法应用到可重构功率放大器的设计中,可验证此逆向建模方法的可行性和准确性。

2 建模基础

2.1 蚁群算法

科研人员于20世纪90年代初提出了蚁群算法^[15-18],它可以模拟自然界中蚂蚁的觅食行为,是一种新型的仿生算法。在初始阶段,蚂蚁 $k(k=1,2,\dots,n)$ 随机选择一条路径出发,在时刻 t 按照路径中的信息素浓度以概率 P_{ij}^k 决定下一个转移的方向,即

$$P_{ij}^k(t) = \begin{cases} \frac{[\tau_{ij}(t)]^\gamma \cdot [\eta_{ij}(t)]^\beta}{\sum_{s \in l_k} [\tau_{is}(t)]^\gamma [\eta_{is}(t)]^\beta}, & j \in l_k \\ 0, & j \notin l_k \end{cases}, \quad (1)$$

式中: $P_{ij}^k(t)$ 为蚂蚁 k 在 t 时刻从节点 i 向节点 j 移动的概率; $\tau_{ij}(t)$ 为 t 时刻路径 ij 上的信息素浓度; $\eta_{ij}(t)=1/d_{ij}$ 为从节点 i 到节点 j 的启发式因子,其中 d_{ij} 为节点 i 到节点 j 的距离; γ 为信息素重要程度因子; β 为启发式因子重要程度; $l_k(k=1,2,\dots,n)$ 为蚂蚁 k 待访问路径的集合。

当所有蚂蚁循环一次后,需要对信息素浓度进行更新,即

$$\tau_{ij}(t+1) = (1-\rho)\tau_{ij}(t) + \sum_{k=1}^n \Delta\tau_{ij}^k, \quad (2)$$

式中: $\rho(0<\rho<1)$ 为信息素挥发因子; $\Delta\tau_{ij}^k$ 为蚂蚁 k 从 $t+1$ 时刻到 t 时刻在路径 ij 上产生的信息素。 $\Delta\tau_{ij}^k$ 更新方式为

$$\Delta\tau_{ij}^k = \begin{cases} Q/L_k, & j \in l_k \\ 0, & j \notin l_k \end{cases}, \quad (3)$$

式中: L_k 为蚂蚁 k 通过的总路径长度; Q 为常量,为蚂蚁 k 实现一次循环所释放的信息素总量。

2.2 BRBP

贝叶斯正则化算法^[10-11,19],即用贝叶斯方法估计正则化参数,实际上是在网络误差函数的基础上加入一个惩罚项 E' ,其误差函数 F 为

$$F = \alpha E' + (1-\alpha)E, \quad (4)$$

式中: E 为BP神经网络模型输出 y 与实际输出 t 之间的均方误差; $\alpha \in [0,1]$ 为比例系数,当 α 大于 0.5 时,能够缩小网络规模,平滑网络输出,提高网络的泛化性能,使网络出现过拟合现象的可能性减

少。贝叶斯正则化算法在网络训练过程中能自适应地调节 α 的大小,得到最优的 α 值。

3 IACO-BRBP 神经网络逆向模型迭代算法

3.1 IACO

1) 改进挥发因子

挥发因子 ρ 是影响路径上信息素浓度的因素之一,为防止蚁群算法在搜索过程中陷入局部较优路径,对挥发因子 ρ 进行改进,即

$$\rho = \begin{cases} 0.4, & N < N_{\max}/3 \\ 0.2, & N_{\max}/3 < N < 2N_{\max}/3, \\ 0.1, & 2N_{\max}/3 < N < N_{\max} \end{cases} \quad (5)$$

式中: N_{\max} 为蚁群算法最大的迭代次数。

2) 改进信息素更新方法

经典 ACO 算法的信息素更新方式在蚂蚁搜索初期无法指导下一条路径的选取,会延长收敛时间。因而本文对信息素更新方法进行改进,当所有蚂蚁循环一次后,就加强当前最优路径附近的较优路径信息素,减弱远离当前较优路径的较差路径信息素,即

$$\Delta\tau_{ij}^k = \begin{cases} -|L_b - L_p|/L_p, & |L_b - L_p| > \delta \\ |L_b - L_p|/L_p, & |L_b - L_p| < \delta \\ 0, & |L_b - L_p| = \delta \end{cases} \quad (6)$$

式中: L_b 为本次循环的最优路径长度; L_p 为当前最优路径长度; δ 为一个常数。同时设定信息素上、下限值,以保证信息素不会急剧增加或者减小,当超过限定值时,自动设置为限定值。

3) 改进启发式因子

启发式因子 $\eta_{ij}(t) = 1/d_{ij}$ 表示节点 i 与节点 j 之间的距离关系,其作用是协助蚂蚁在下一步以更大的概率选择较短路径,然而这种更新方式忽略了节点与出发原点之间的关系,也忽略了节点与终点的间距,只能体现两节点之间的关系,存在一定缺陷。为提高搜索效率与精确程度,指明蚁群搜索全局最优解的方向,从全局着眼,将启发式因子更改为

$$\eta_{ij}(t) = 1/(d_{oj} \cdot d_{ij} \cdot d_{js}), \quad (7)$$

式中: d_{oj} 为原点到当前节点 j 之间的距离; d_{js} 为当前节点 j 与终点的间距。这一改进,既考虑了节点的间距,又考虑了出发点与各节点的间距。

改进后的蚁群算法在搜索初期能够遍历全局,不会因忽略某一个节点导致错过全局最优解。之后,通过改进的挥发因子、信息素更新方式和启发式

因子指引蚁群快速地搜索到全局最优解,这样就不会陷入局部较优解。

3.2 IACO-BRBP 神经网络逆向模型的迭代算法

3.2.1 IACO 优化 BRBP 神经网络权值

将蚂蚁待寻优路径的数据设定为训练神经网络后得到的 m 个待优化的权值,按顺序排列这些参数,记作 $p1, p2, \dots, pm$,初始化每一个参数为 N 个任意的非零值,形成集合 R_{pi} 。设蚂蚁的数量为 S ,每只蚂蚁从蚁巢出发,依据集合中每个元素的信息素状态,从集合 R_{pi} 中随机地选择一个元素,则 $\tau_{R_{pi},j}$ 为集合 R_{pi} 的第 j 个元素的信息素。

当蚂蚁独立地在所有集合中完成元素的搜寻后,即都抵达了目的地,此时根据 IACO 算法更新信息素和启发式因子,将每只蚂蚁所选择的元素集合作为下一次迭代的参数。反复以上过程,当达到给定的迭代次数,或蚂蚁收敛到同一路径时,训练完毕,即找到了神经网络的最优权值。

3.2.2 BRBP 神经网络逆向模型迭代算法

与神经网络正向建模不同,逆向建模最终求得的是结构参数,而非目标参数。在逆向建模过程中,保持由 IACO-BRBP 神经网络优化的权值不变,调整输入参数使误差函数达到最小,以获得与目标输入十分接近的模型输入,其更新过程为

$$x_{m+1} = x_m - \lambda \frac{\partial F}{\partial x_m}, m = 0, 1, 2, \dots, \quad (8)$$

式中: x_{m+1}, x_m 为输入参量; λ 为学习速率。

正则化方法包含 L_0, L_1, L_2 范数等正则化函数。最早应用于特征提取和变量选择的是 L_0 正则化方法,它能够产生最稀疏的解,但要得到最优的变量选择结果,需求解难度大的 NP 组合优化问题。 L_1 正则子仅需求解凸优化问题,易获得较稀疏的解,但总是无法产生最稀疏的解。 L_2 正则子是最常用的方法,可以产生光滑解,但稀疏性和网络剪枝能力都很差^[8,20-21]。 $L_{1/2}$ 正则子易求出稀疏解,当贝叶斯正则化的比例系数 $\alpha \in (0.5, 1)$ 时,将其应用到 IACO-BRBP 神经网络逆向建模中不仅能够平滑网络输出,而且可以有效减轻网络在逆向建模过程中的振荡。

本文选用隐含层数为 1 的 BRBP 神经网络结构,输入层神经元数为 M 、隐含层有 P 个神经元、输出层神经元数为 N ,如图 1 所示。隐含层、输出层分别采用 logsig 函数和线性 purelin 函数为激活函数。

从图 1 能够看出,隐含层神经元的输出为




图1 BRBP神经网络结构

Fig. 1 BRBP neural network structure

$$z_{pk} = f\left(\sum_{m=1}^M w_{pm} x_{mk} - \theta_{1p}\right), \quad (9)$$

式中： x_{mk} 为输入； z_{pk} 为隐含层输出； w_{pm} 和 θ_{1p} 分别为输入层与隐含层神经元之间的权值和阈值。隐含层的激活函数为 $f = \frac{1}{1+e^{-x}}$ ，则 z_{pk} 对 x_{mk} 的偏导为

$$\frac{\partial z_{pk}}{\partial x_{mk}} = w_{pm} \cdot z_{pk} (1 - z_{pk}). \quad (10)$$

IACO-BRBP 神经网络的输出为

$$y_{nk} = \sum_{p=1}^P v_{np} z_{pk} - \theta_{2n}, \quad (11)$$

式中： y_{nk} 为输出， v_{np} 和 θ_{2n} 分别为隐含层与输出层神经元之间的权值和阈值。

根据(4)式，本文逆向建模方法的误差函数 F 为

$$F = \frac{1-\alpha}{N} \sum_{k=1}^K \sum_{n=1}^N (y_{nk} - t_{nk})^2 + \frac{\alpha}{M} \sum_{k=1}^K \sum_{m=1}^M |x_{mk}|^{1/2}. \quad (12)$$

令

$$E_x = E' = \frac{1}{M} \sum_{k=1}^K \sum_{m=1}^M |x_{mk}|^{1/2}, \quad (13)$$

$$E_D = E = \frac{1}{N} \sum_{k=1}^K \sum_{n=1}^N (y_{nk} - t_{nk})^2, \quad (14)$$

那么(12)式中误差函数 F 对输入 x_m 求偏导，即

$$\frac{\partial F}{\partial x_m} = \sum_{k=1}^K \frac{\partial F_k}{\partial x_{mk}} = \sum_{k=1}^K \left[\alpha \frac{\partial E_{xk}}{\partial x_{mk}} + (1-\alpha) \frac{\partial E_{Dk}}{\partial x_{mk}} \right], \quad (15)$$

其中

$$\frac{\partial E_{xk}}{\partial x_{mk}} = \frac{1}{2M} \cdot \frac{\text{sgn}(x_{mk})}{|x_{mk}|^{1/2}}. \quad (16)$$

将(15)式中的 E_{Dk} 对隐含层输出 z_{pk} 求偏导，可得

$$\frac{\partial E_{Dk}}{\partial z_{pk}} = \sum_{n=1}^N \frac{\partial E_{Dk}}{\partial \left(\sum_{p=1}^P v_{np} z_{pk} - \theta_{2n} \right)} \times \frac{\partial \left(\sum_{p=1}^P v_{np} z_{pk} - \theta_{2n} \right)}{\partial z_{pk}}, \quad (17)$$

而(17)式等号右边第一项等于

$$\frac{\partial E_{Dk}}{\partial \left(\sum_{p=1}^P v_{np} z_{pk} - \theta_{2n} \right)} = \frac{\partial E_{Dk}}{\partial y_{nk}} = \frac{2}{N} (y_{nk} - t_{nk}), \quad (18)$$

(17)式中等号右边第二项为

$$\frac{\partial \left(\sum_{p=1}^P v_{np} z_{pk} - \theta_{2n} \right)}{\partial z_{pk}} = v_{np}, \quad (19)$$

从而可得

$$\frac{\partial E_{Dk}}{\partial z_{pk}} = \frac{2}{N} \sum_{n=1}^N (y_{nk} - t_{nk}) \cdot v_{np}. \quad (20)$$

(15)式中 E_{Dk} 对输入 x_{mk} 求偏导可得

$$\frac{\partial E_{Dk}}{\partial x_{mk}} = \sum_{p=1}^P \frac{\partial E_{Dk}}{\partial z_{pk}} \cdot \frac{\partial z_{pk}}{\partial x_{mk}}, \quad (21)$$

将(10)式和(20)式代入(21)式可得

$$\frac{\partial E_{Dk}}{\partial x_{mk}} = \frac{2}{N} \sum_{p=1}^P \sum_{n=1}^N [(y_{nk} - t_{nk}) \cdot v_{np} \cdot w_{pm} \cdot z_{pk} (1 - z_{pk})]. \quad (22)$$

因此有

$$\frac{\partial F}{\partial x_m} = \sum_{k=1}^K \left\{ \frac{\alpha}{2M} \cdot \frac{\text{sgn}(x_{mk})}{|x_{mk}|^{1/2}} + \frac{2(1-\alpha)}{N} \times \sum_{p=1}^P \sum_{n=1}^N [(y_{nk} - t_{nk}) \cdot v_{np} \cdot w_{pm} \cdot z_{pk} (1 - z_{pk})] \right\}. \quad (23)$$

把(23)式代入(8)式中更新完成输入参数逆向建模的过程。

4 逆向建模方法

4.1 神经网络逆向建模步骤

本文首先改进蚁群算法以优化正向模型的权值，并使用贝叶斯正则化算法迭代更新输入参量以获得最优结构参数，这可以有效提高逆向模型精度，缩短整体建模的运行时间，加强网络的稳定性和泛化能力。其中正则化选用 $L_{1/2}$ 正则子，具体实现步骤为

- 1) 提取数据；
- 2) 运用改进的蚁群算法训练 BRBP 正向模型，获取阈值和优化后的权值并保存；
- 3) 在建立好的 BRBP 正向模型中输入参量，并采用优化后的权值和阈值，运行得到输出参量；
- 4) 计算输出参量与目标参量之间的误差函数 F ；
- 5) 利用第 3.2 节推导出的逆向迭代算法更新输入参量 $x_{m+1} = x_m - \eta \frac{\partial F}{\partial x_m}$ ；
- 6) 若未达到设定的迭代次数或不满足误差函

数 F 的精度要求,则转到步骤 3),否则算法结束。

4.2 可重构功率放大器的 IACO-BRBP 神经网络逆向建模过程

将本文逆向建模方法应用到可重构功率放大器的仿真中,以验证该方法的可行性。图 2 为 ADS 软件所搭建的可重构功率放大器的整体电路图。

可重构功率放大器通过在匹配电路中加入可重构器件来对电容进行控制,从而切换不同的匹配网络,使功放可以工作在多个不同的频段^[22]。图 2 中的功放在设计时选择 1.75 GHz、2.1 GHz 和 2.6 GHz 这 3 个中心频点,可以覆盖 3G 和 4G 的典

型频段。可重构功率放大器的设计中,一般情况下设计者使用 ADS 软件调节电容,以满足匹配电路的回波损耗 $S_{11} < -10$ dB、整体电路的输出功率 $P \leq 10$ W、功率附加效率 $P_{AE} \geq 30\%$ 等参数指标,其过程耗时且繁琐。但是使用神经网络逆向建模方法就可以在已知参数指标时立即得出所需要的电容,给设计者以参考,即不再需要设计者进行重复的调节工作,既节省了时间又简化了功放的设计进程。本文以 2.1 GHz 中心频点为例,图 3 和图 4 分别是功放中的电容 C 与 S_{11} 之间的关系,电容 C 和 P 与 P_{AE} 之间的三维关系。




图 2 可重构功率放大器的整体电路图

Fig. 2 Overall circuit diagram of reconfigurable power amplifier




图 3 回波损耗 S_{11} 与电容 C 之间的关系

Fig. 3 Relationship between return loss S_{11} and capacitance C

从图 3 和图 4 可以看出, S_{11} 与 C , P_{AE} 、 C 和 P 之间存在一对多的问题。利用本文 IACO-BRBP 神经网络逆向建模方法来解决非线性映射、在重复参数调节上浪费时间等问题,其建模流程如图 5 所示。

5 实验验证及仿真结果

本文以频率可重构功率放大器为例,将 IACO-BRBP 逆向建模方法与自适应 η 逆向建模方法^[1]、直接逆向建模方法和 ADS 软件所需的元件值进行比较,来验证本文方法的可行性。这里神经网络的




图 4 功率附加效率 P_{AE} 与输出功率 P 和电容 C 之间的关系

Fig. 4 Relationship among power added efficiency P_{AE} , output power P , and capacitance C

结构为:输入层神经元数 $M = 75$,隐含层神经元数 $P = 10$,输出层神经元数 $N = 1$ 。

实验一:从整体电路中提取数据

从该放大器中提取出电容 C 、功率附加效率 P_{AE} 和输出功率 P 等参数的数据各 1100 组,从中分别选取训练数据 550 组,测试数据 100 组。本文逆向建模方法按照图 5 的建模流程训练模型,其中 α 取 0.95;按照文献[1]的步骤训练自适应 η 逆向模型;以输入目标参量、输出结构参量的方式训练直接

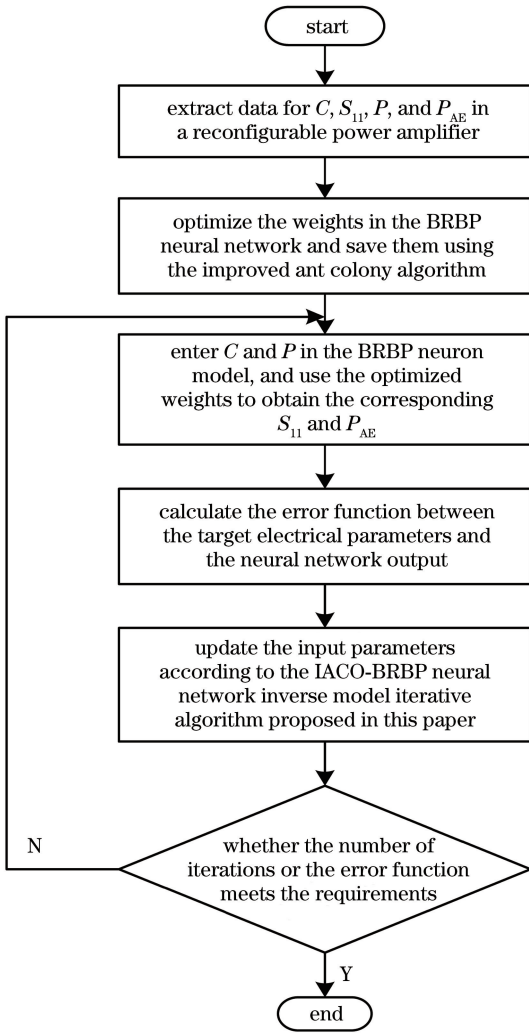


图5 可重构功放的 IACO-BRBP 神经网络逆向建模流程
Fig. 5 Process of IACO-BRBP neural network reverse modeling for reconfigurable power amplifier

逆向模型。训练后,利用 100 组数据对这三种模型进行测试,结果如图 6 和图 7 所示。图 6 为这三种方法输入 P_{AE} 后综合得出的电容 C 值和仿真所需的 C 值的拟合对比情况,图 7 为这三种方法输入 P_{AE} 后综合得出的 P 值和仿真结果中的 P 值的拟合效果对比。

通过测试可以知道,直接逆向模型不但没有解决 P_{AE} 、 C 和 P 之间的多值映射问题,而且与实际上 ADS 软件仿真所需 C 值和仿真结果 P 值都不拟合,因此,在设计频率可重构功放时,不能采用直接逆向模型。而本文逆向模型和自适应 η 逆向模型都很好地解决了参数之间一对多的问题,并且两者的拟合效果都要优于直接逆向模型。从图 6 和图 7 可以看出,本文逆向模型的拟合精度高于自适应 η 逆向模型,表明本文方法更适合设计频率可重构功率

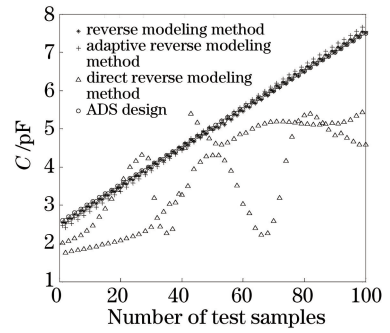


图6 电容值 C 拟合对比图

Fig. 6 Fitting contrast diagram of capacitance values C

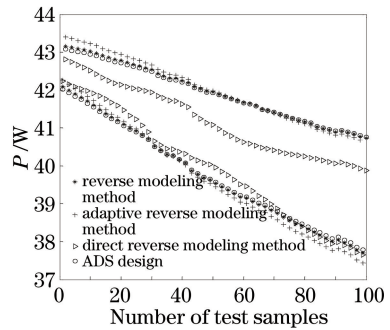


图7 输出功率 P 拟合对比图

Fig. 7 Fitting contrast diagram of output power P 放大器。

实验二:从放大器的输出匹配端提取数据

从输出匹配电路中提取出电容 C 和回波损耗 S_{11} 的数据各 500 组,从中分别选取训练数据 250 组,测试数据 50 组。图 8 为这三种逆向建模方法输入 S_{11} 后分别综合得出的电容 C 值和实际所需 C 值的拟合对比情况。

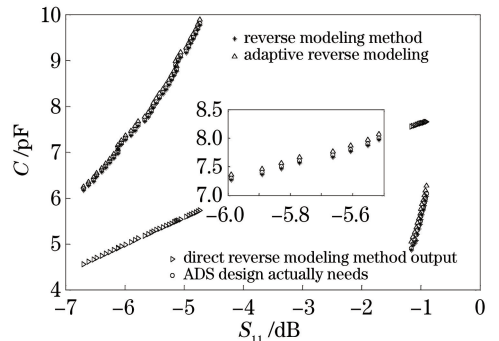


图8 三种逆向模型输出 C 值与 ADS 实际所需 C 值的对比
Fig. 8 Comparison of output values C of three reverse models and actual values C required by ADS

从图 8 可见,直接逆向模型精度低,其输出 C 值与 ADS 实际所需 C 值基本上都不拟合。从放大的局部图形可以看到,自适应 η 逆向模型的拟合效果优于直接逆向模型,而本文逆向模型的拟合程度

明显高于其他两种逆向模型。

为了更加直观地表明本文 IACO-BRBP 神经网络

逆向建模方法的准确性,将这三种逆向建模方法的建模运行时间和均方误差进行比较,如表 1 所示。

表 1 三种建模方法的性能比较

Table 1 Comparison of performances of three modeling methods

Reverse modeling method	Input S_{11} combined C		Input P_{AE} combined C		Input P_{AE} combined P	
	Mean	Run	Mean	Run	Mean	Run
	square error	time /s	square error	time /s	square error	time /s
IACO-BRBP	0.0014	4.025293	9.5779×10^{-4}	4.072177	0.0021	4.138958
Adaptive η	0.0155	4.239108	0.0078	4.048377	0.0319	4.235733
Direct modeling	8.7620	9.585498	2.3682	3.144256	0.3346	6.366971

由表 1 可知,在进行整体电路实验时,本文逆向建模方法输入 P_{AE} 综合得出 C 值所需时间要略长于直接逆向建模方法和自适应 η 逆向建模方法 29.51% 和 0.58%,但是本文 IACO-BRBP 神经网络逆向建模方法的平均运行时间短于后两种方法 35.76%、2.05%。而且本文逆向建模方法的均方误差小于其他两种方法,即精度平均高于另两种方法 99.77%、90.70%。因此,IACO-BRBP 方法的建模运行时间相对来说比较短,而且模型精度高,表明 IACO-BRBP 逆向建模方法可用于简化可重构多波段功率放大器的设计进程,缩短了设计周期。

这里,实验部分所说的直接逆向建模方法所使用的是 trainbr 函数(贝叶斯正则化算法)训练 BP 神经网络,为验证本文方法,又使用经 traingdx 函数(梯度下降法)训练的 BP 神经网络进行直接逆向建模,得到输入 S_{11} 综合出的 C、输入 P_{AE} 综合出的 C、输入 P_{AE} 综合出的 P 的误差和时间分别为 8.4346、1.208923 s, 2.2461、1.003142 s, 0.3627、1.663291 s。梯度下降法的运行时间比其他三种都短,但是误差相较于本文方法和自适应 η 逆向建模方法都大。

6 结 论

提出一种 IACO-BRBP 神经网络逆向建模方法。该方法首先改进蚁群算法,即在不同的搜索阶段设置不同的挥发因子值,根据路径是否较优更新信息素,并在启发式因子中加入出发点与节点的间距、终点与节点的间距等,使蚁群在遍历全局的同时能够快速有效地找到全局最优解;而后利用 IACO 算法优化 BRBP 神经网络正向模型的权值。本文逆向建模方法中贝叶斯正则化方法采用的是 $L_{1/2}$ 正则子且其比例系数大于 0.5,这样不仅可以使网络稀疏化、节省时间,而且可以使网络的输出愈加平滑,能减轻网络的振荡,增强其稳定性,提高其泛化能力。将本文方法应用到频率可重构功率放大器中,并与

直接逆向建模方法、自适应 η 逆向建模方法的仿真结果进行比较,验证了本文方法的可行性和准确性。研究表明本文方法对于加快可重构功放设计进程、缩短其设计周期具有实用价值。

参 考 文 献

- [1] Nan J C, Sang B H, Gao M M. Novel neural network inverse modelling method and its application [J]. Computer Applications and Software, 2016, 33(1): 147-150, 194.
南敬昌, 桑百行, 高明明. 新颖的神经网络逆建模方法及其应用[J]. 计算机应用与软件, 2016, 33(1): 147-150, 194.
- [2] Rayas-Sanchez J E. EM-based optimization of microwave circuits using artificial neural networks: the state-of-the-art [J]. IEEE Transactions on Microwave Theory and Techniques, 2004, 52(1): 420-435.
- [3] Zhang Y, Yin X X, Qian Z G, et al. Inverse neural network model for integrated capacitors design [J]. Journal of Microwares, 2005, 21(S1): 15-19.
张宇, 殷晓星, 钱治国, 等. 集成电容设计的逆向神经网络建模[J]. 微波学报, 2005, 21(S1): 15-19.
- [4] Linden A, Kindermann J. Inversion of multilayer nets [C] // International Joint Conference on Neural Networks, Washington, DC, USA. New York: IEEE, 1989: 425-430.
- [5] Mareddy L, Almalkawi M, Devabhaktuni V, et al. Gradient based reverse ANN modeling approach for RF/microwave computer aided design [C] // 2012 7th European Microwave Integrated Circuit Conference, October 29-30, 2012, Amsterdam, Netherlands. New York: IEEE, 2012: 246-249.
- [6] Kabir H, Wang Y, Yu M, et al. Neural network inverse modeling and applications to microwave filter design [J]. IEEE Transactions on Microwave Theory and Techniques, 2008, 56(4): 867-879.

- [7] Wang L G, Wang M, Zhong W, et al. Complex-valued deep convolutional networks for nonlinear electromagnetic inverse scattering [C] // 2018 IEEE International Conference on Computational Electromagnetics (ICCEM), March 26-28, 2018, Chengdu, China. New York: IEEE, 2018: 18167501.
- [8] Liu D J, Tan Y X, Khoram E, et al. Training deep neural networks for the inverse design of nanophotonic structures[J]. ACS Photonics, 2018, 5(4): 1365-1369.
- [9] Xu Z B, Zhang H, Wang Y, et al. $L_{1/2}$ regularization [J]. Science China Information Sciences, 2010, 53(6): 1159-1169.
- [10] Huang B J, Wang J, Wen Y Q, et al. Convergence analysis of inverse iterative algorithms for neural networks with $L_{1/2}$ penalty [J]. Journal of China University of Petroleum (Edition of Natural Science), 2015, 39(2): 164-170.
黄炳家, 王健, 温艳青, 等. 带光滑 $L_{1/2}$ 正则化项的神经网络逆向迭代算法收敛性分析[J]. 中国石油大学学报(自然科学版), 2015, 39(2): 164-170.
- [11] Li Y, Shi B M. Research of prediction of coal and gas outburst based on BP artificial neural network utilizing Bayesian regularization [J]. Industry and Mine Automation, 2009, 35(2): 1-5.
李洋, 石必明. 基于贝叶斯正则化 BP 人工神经网络的煤与瓦斯突出预测的研究[J]. 工矿自动化, 2009, 35(2): 1-5.
- [12] Meng H, He X P, Song J G, et al. Path planning research based on the improved ant colony algorithm in ECDIS[C] // 2016 35th Chinese Control Conference (CCC), July 27-29, 2016, Chengdu, China. New York: IEEE, 2016: 5504-5508.
- [13] Yu Y, He N B, Gao Q, et al. Path planning of mobile robot based on improved ant colony algorithm [J]. Internet of Things Technologies, 2017, 7(3): 46-49, 52.
俞焯, 贺乃宝, 高倩, 等. 基于改进蚁群算法的移动机器人路径规划[J]. 物联网技术, 2017, 7(3): 46-49, 52.
- [14] Yuan Q Q, Lü L T. Network intrusion detection method based on combination of improved ant colony optimization and genetic algorithm [J]. Journal of Chongqing University of Posts and Telecommunications (Natural Science Edition), 2017, 29(1): 84-89.
袁琴琴, 吕林涛. 基于改进蚁群算法与遗传算法组合的网络入侵检测[J]. 重庆邮电大学学报(自然科学版), 2017, 29(1): 84-89.
- [15] Wang X D, Zhang Y Q, Xue H. Improved ant colony algorithm for VRP [J]. Journal of Jilin University (Information Science Edition), 2017, 35(2): 198-203.
王晓东, 张永强, 薛红. 基于改进蚁群算法对 VRP 线路优化[J]. 吉林大学学报(信息科学版), 2017, 35(2): 198-203.
- [16] Lü H F, Gu X S. A two level information fusion algorithm based on ant colony neural network [J]. Journal of Shanghai Jiaotong University, 2016, 50(8): 1323-1330.
吕红芳, 顾幸生. 基于蚁群神经网络的两级信息融合算法[J]. 上海交通大学学报, 2016, 50(8): 1323-1330.
- [17] Hui X W, Chang Z Y, Lin S, et al. Image edge extraction combined with Predator-Prey-AACO algorithm [J]. Laser & Optoelectronics Progress, 2015, 52(5): 051001.
惠晓威, 常正英, 林森, 等. 结合 Predator-Prey-AACO 的图像边缘检测算法[J]. 激光与光电子学进展, 2015, 52(5): 051001.
- [18] Duan H B, Ma G J, Wang D B, et al. Improved ant colony algorithm for solving continuous space optimization problems [J]. Journal of System Simulation, 2007, 19(5): 974-977.
段海滨, 马冠军, 王道波, 等. 一种求解连续空间优化问题的改进蚁群算法[J]. 系统仿真学报, 2007, 19(5): 974-977.
- [19] Wang C, Yang F, Li J. Blind recovery method of motion blurred image based on combining l_1/l_2 norm with high order and low order total variation [J]. Laser & Optoelectronics Progress, 2018, 55(4): 0414051.
王灿, 杨帆, 李靖. 基于 l_1/l_2 的高低阶全变差运动模糊图像盲复原方法[J]. 激光与光电子学进展, 2018, 55(4): 0414051.
- [20] Shang Q L. BP network algorithm with $L_{1/2}$ regularizer [D]. Dalian: Dalian University of Technology, 2014.
商启龙. 带二分之一正则化项的 BP 网络算法[D]. 大连: 大连理工大学, 2014.
- [21] Fan Q W. Convergence analysis of learning algorithms with smoothing regularization for feedforward neural networks [D]. Dalian: Dalian University of Technology, 2014.
范钦伟. 带光滑正则项前馈神经网络学习算法的收

- 敛性分析[D]. 大连: 大连理工大学, 2014. 61-64.
- [22] Xu Q, Liu T J, Ye Y, et al. Design on reconfigurable multi-band RF power amplifier [J]. Radio Communications Technology, 2014, 40(3): 61-64.
- 徐谦, 刘太君, 叶焱, 等. 可重构多波段射频功率放大器设计[J]. 无线电通信技术, 2014, 40(3): 61-64.