

激光与光电子学进展

深度学习架构神经网络对超宽带天线建模优化

南敬昌, 杜有益*, 王明寰, 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 为了加快天线建模优化速度, 提出了一种基于深度学习网络架构的新型深度多层感知机(DMLP)网络用于优化超宽带天线, 该网络采用阶梯下降形深度全连接层网络, 应用Adam优化器自动更新学习率, 加快了模型的权值更新。应用drop-out技术对隐含层中的部分神经元进行随机剔除, 以防止网络层数过深所导致的过拟合现象的发生。使用DMLP网络对超宽带阶梯形微带单极子天线几何参数进行建模, 从天线的8个几何参数中提取特征, 对天线的S11值进行预测。实验结果表明, 该结构网络与传统多层感知器神经网络、径向基神经网络相比, 对S11的预测平均误差分别减小了118.32%和123.76%, 拥有更高的预测准确度, 拟合速度也有较大提升, 通过实验验证了此网络的可行性。

关键词 光学器件; 深度多层感知机; 超宽带阶梯形微带单极子天线; Adam优化器

中图分类号 TP391.9

文献标志码 A

DOI: 10.3788/LOP202259.1323001

Deep Learning Architecture and Neural Network Optimization of Ultra-Wideband Antenna Modeling

Nan Jingchang, Du Youyi*, Wang Minghuan, Gao Mingming

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

Abstract To speed up the optimization of antenna modeling, this paper proposes a novel deep multi-layer perceptron (DMLP) network based on deep learning network architecture for optimizing ultra-wideband antenna. The DMLP network uses a step-down, connected-layer deep network, and the Adam optimizer automatically updates the learning rate. Dropout technology is used to remove random neurons in the hidden layer, preventing overfitting due to the deep network layers. This paper uses the DMLP network to model the geometric parameters of the ultra-wideband stepped microstrip monopole antenna, extracts features from the eight geometric parameters of the antenna, and predicts the S11 value of the antenna. The experimental results show that compared with traditional multilayer perceptron and radial-basis-function neural networks, the average prediction error of S11 is reduced by 118.32% and 123.76%, respectively, and it has a higher prediction accuracy. In addition, the fitting speed is improved. The feasibility of this network is verified through experiments.

Key words optical devices; deep multi-layer perceptron; ultra-wideband stepped microstrip monopole antenna; Adam optimizer

1 引言

在今天, 大多数人已经处在无线通信技术包裹之下, 其中天线因在不同环境下可以调制成该环境所需求的性能, 已经被广泛应用于各种场景, 成为了无线通信领域中的热门。特别是在短距离通信中, 超宽带(UWB)无线系统因具有功耗低、天线结构简单、数据

传输速率高等优点, 被广泛应用在各领域^[1]。在天线的设计中, 传统的建模分析方法[如有限元法(FEM)^[2]、有限积分法(FIT)^[3]、矩量法(MoM)^[4]等数值分析法]对天线的各种性能进行精准计算, 而其传统仿真软件对复杂天线的多参数优化过程一直存在运行时间长、过程繁琐、需要占用大量内存运算空间等问题。因此, 针对天线的大规模参数优化很难运用在普

收稿日期: 2021-06-30; 修回日期: 2021-08-04; 录用日期: 2021-08-09

基金项目: 国家自然科学基金(61971210)

通信作者: *491887202@qq.com

遍场景中。

为了解决这一问题,中外研究人员将人工神经网络(ANN)应用在天线设计领域^[5]。神经网络建模技术具有解决高维、非线性问题的能力,已经广泛应用于各领域中^[6-8]。运用数据对所搭建的神经网络成功训练之后,就搭建成一个具有映射关系的神经网络模型,当输入新数据时,数据会快速通过神经网络模型进行映射计算,给出所预测的输出结果^[9]。文献[10]采用单层隐含层的浅层人工神经网络,通过高效的弹性反向传播(RPROP)算法进行训练,对分形贴片天线进行建模。文献[11]提出了一种基于数据挖掘技术的人工神经网络模型。与传统的人工神经网络相比,该模型可以用较小的训练数据集和准确的结果来实现训练,并用U型插槽补丁天线证实了其有效性和效率。文献[12]提出了改进的多层感知器模型(M2LP),它是标准多层感知器(MLP)的等效卷积神经网络(CNN)模型,其中代替了MLP的传统训练参数,使用了卷积神经网络模型的参数处理,例如batch-size处理、ReLU激活函数层和Adam优化算法,并用一个电容馈电天线模型验证了其神经网络结构。文献[13]使用三种不同类型的人工神经网络即前馈反向传播网络、级联前向反向传播网络和层递归网络进行了比较分析。通过对U型缝隙圆形微带天线进行仿真,对比神经网络的仿真结果和计算机软件建模仿真结果可知,它们拥有较强的一致性,由最小均方误差值对比可知,级联前向反向传播网络优于其他网络。




图1 多层感知机结构框图及其隐含神经元

Fig. 1 Structure block diagram of multi-layer perceptron and hidden neurons

多层感知机的BP算法首先前向传导,在第一层隐含层中引入了偏置节点 $b^{(n)}$,即第二层隐含层第 n 个节点结果输出为

$$y_2^{(n)} = f(u_2^{(n)}) = f\left(\sum_{l=1}^L \omega_2^{(n)(l)} v_l + b_2^{(n)}\right), \quad (1)$$

式中: v_l 为上层隐含层输出; L 为下层隐含层数量; f 函数是非线性激活函数,常见有sigmod和tanh,在最近的深度学习研究中经常使用ReLU作为激活函数。

通过上述文献可知,针对天线设计任务,可以使用人工神经网络进行辅助工作,但是上述文献都处于浅层神经网络,对真实数据的拟合程度不够高,处理多特征输入时拟合乏力。基于这个问题,本文提出了一种新型深度学习网络架构,即深度多层感知机(DMLP)神经网络,与传统MLP网络相比,不仅加深了隐含层深度,使得隐含层宽度逐渐下降,而且使用深度学习中较为流行的ReLU激活函数、Adam优化器、batch-size数据处理、drop-out技术来优化此DMLP神经网络,并且对从超宽带阶梯形微带单极子天线仿真中提取出的数据进行实验建模,通过S11均方根误差对模型精准度进行比较。实验结果表明,本文提出的DMLP神经网络模型相比传统MLP神经网络模型以及径向基神经网络(RBF)具有更高的精准度和收敛速度。

2 深度MLP神经网络建模

2.1 多层感知机

感知机是ANN人工神经网络的一个概念,由Frank Rosenblatt于1950年提出,MLP多层感知机是一种前向ANN网络,可以把一组输入数据映射到输出数据。MLP由多个节点层构成,每一层节点全连接到下一层节点,每一个节点都是拥有激活函数的人工神经元,使用反向传播(BP)算法监督学习进行数据训练,MLP成功地改正了单层感知机只能处理线性问题的缺点,可以对非线性问题进行处理^[14]。图1为多层感知机的结构图。

sigmod、tanh和ReLU分别表示为

$$\sigma(x) = \frac{1}{1 + \exp(-x)}, \quad (2)$$

$$\tanh(x) = \frac{\sinh(x)}{\cosh(x)} = \frac{\exp(x) - \exp(-x)}{\exp(x) + \exp(-x)}, \quad (3)$$

$$\text{ReLU}(x) = \begin{cases} x, & \text{if } x > 0 \\ 0, & \text{if } x \leq 0 \end{cases}. \quad (4)$$

可以看出,sigmod和tanh激活函数涉及了指数运

算,而ReLU激活函数运算更加简单,因此有效地加大了网络的运算速度。由于其非线性体现在折点0上,表达能力更强,对非负区间梯度为常数,不存在梯度消失等问题,所以模型收敛速度可以维持在一个稳定状态。

在前向传播完成之后对网络最后一层即输出层,定义损失函数为

$$E = \frac{1}{2} \sum (r - y_k)^2, \quad (5)$$

式中:输出层设定为第 k 层; r 表示真实值。将式(1)代入式(5)之后运用链式法则可以得到参数更新公式为

$$w = w - \eta \frac{\partial E}{\partial w} = w - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial \beta} \frac{\partial \beta}{\partial w}, \quad (6)$$

$$b = b - \eta \frac{\partial E}{\partial b} = b - \eta \frac{\partial E}{\partial y} \frac{\partial y}{\partial \beta} \frac{\partial \beta}{\partial b}, \quad (7)$$

式中: β 为激活函数。

2.2 Adam 优化器

2014年Kingma和Ba^[15]提出了Adam优化器。Adam优化器是一种对随机目标函数执行一阶梯度优化的算法,结合了AdaGrad和RMSProp两种优化算法的优点,对梯度的一阶矩估计和二阶矩估计进行合并思考并计算步长,利用梯度的一阶矩估计和二阶矩估计动态调节每个参数的学习率,使得每次的迭代学习都在一个明确的范围内,参数变化平稳,这也减少了梯度爆炸或者梯度消失出现的可能性。其流程如图2所示。

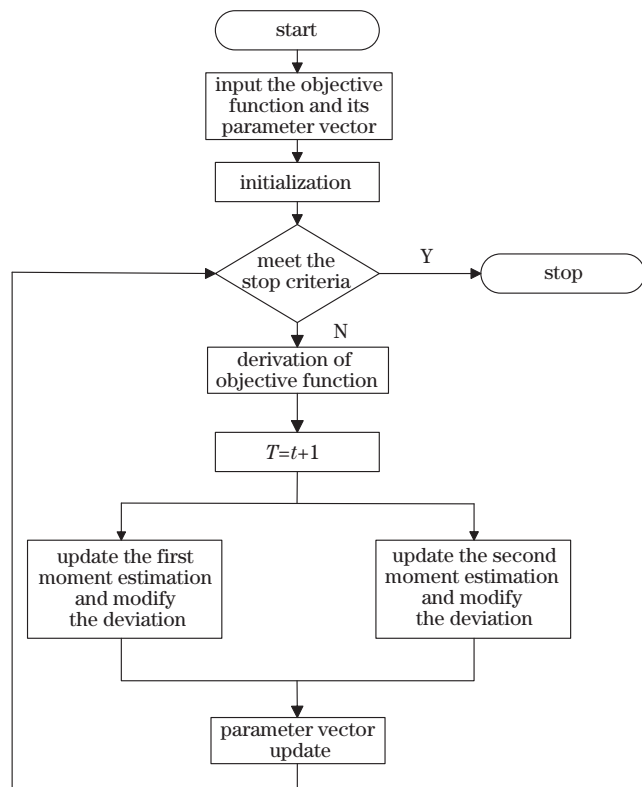


图2 Adam优化器算法框架流程

Fig. 2 Adam optimizer algorithm framework flow

Adam优化器参数更新原理表示为

$$m_w^{t+1} = \beta_1 m_w^t + (1 - \beta_1) \nabla L^t, \quad (8)$$

式中: m 为一阶矩估计; β 为超参数; t 为更新次数。

$$v_w^{t+1} = \beta_2 m_w^t + (1 - \beta_2) (\nabla L^t)^2, \quad (9)$$

式中: v 为二阶矩估计。

$$\hat{m}_w = \frac{m_w^{t+1}}{1 - \beta_1^{t+1}}, \quad (10)$$

然后进行估计校正,实现无偏估计,

$$\hat{v}_w = \frac{v_w^{t+1}}{1 - \beta_2^{t+1}}. \quad (11)$$

将式(10)和式(11)结合得到

$$w^{t+1} = w^t - \eta \frac{\hat{m}_w}{\sqrt{\hat{v}_w + \epsilon}}, \quad (12)$$

式中: w 为待更新参数

2.3 新型DMLP神经网络模型

新型DMLP神经网络不仅限于优化了浅层MLP的层数,从理论上分析,神经网络层数越深,拟合函数的能力会越强,但是实际上过深的层数带来的不仅是过拟合问题,还会增加训练难度,使得模型难以收敛。为了解决这些问题,本文提出的新型深层DMLP神经网络采用了7层全连接层,ReLU激活函数,Adam优化器,batch-size数据处理,drop-out技术对此网络进行优化,并且把神经网络的隐含层宽度层层递减。

ReLU激活函数和Adam优化器大大加快了新型深层DMLP神经网络的运算速度,在实验过程中发现,此深层网络输出结果泛化能力较差,导致训练集损失值远远低于验证集损失值,推断出现过拟合现象,故而使用drop-out技术对此网络进行优化,并对一些神经元进行“剔除”操作,有效避免过拟合现象。

本文对天线的8个几何参数进行仿真建模判断8个几何参数变化对S11值的影响。因为输入参数是8个,从卷积神经网络特征提取的角度分析,使用卷积核宽度为2的conv1d卷积核,所能达到的最大层数为7,说明从维度角度来看7层就能达到8个参数全组合影响输出结果的层数,把参数组合中对S11影响最大的表征作为重点,将隐含层神经网络宽度层层递减正是起到了此作用。为了避免极端压缩的瓶颈层出现在达到最终表征之前,表征的大小应该从输入到输出逐渐减小并将前一层中的强壮神经元进一步整合^[16],即1000个神经元的隐含层不应直接连接250个神经元的隐含层,而是连接800个神经元的隐含层。此操作不仅减少了神经网络运算量,还避免了可能出现的表征在某层极端压缩导致的失真,从而出现欠拟合的困局。DMLP网络的具体组成架构如图3所示。

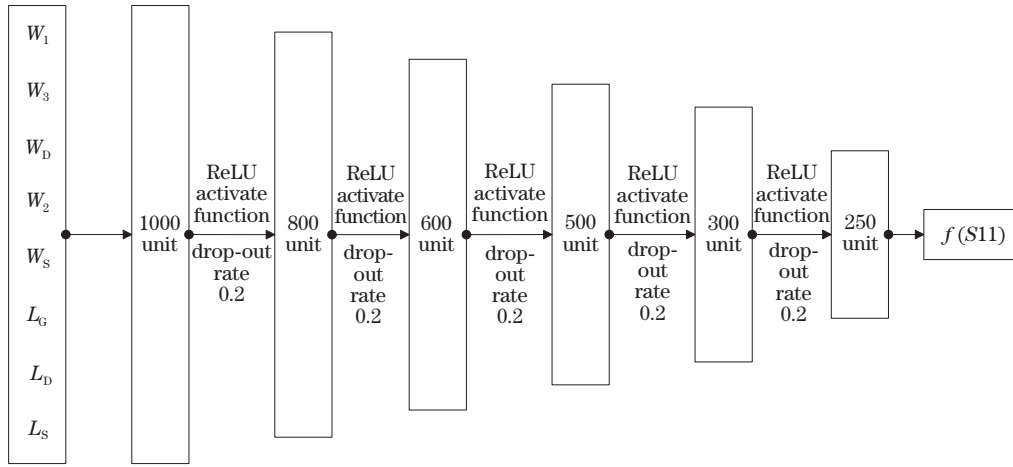


图3 DMLP神经网络架构

Fig. 3 DMLP neural network architecture

3 超宽带阶梯形微带单极子天线建模

3.1 天线结构及其特性分析

本文采用了一种超宽带阶梯形微带单极子天线^[17]作为实验对象,该天线尺寸为 13 mm×22 mm×0.8 mm,采用阶梯形微带线馈电,具有三角形缺槽的矩形辐射贴片和缺陷地面结构(DGS)。此天线在 2.9~22.1 GHz 频段内工作。天线结构如图 4 所示,其具体几何参数如表 1 所示。

用 HFSS 软件对本文所使用的超宽带阶梯形微带




图4 超宽带阶梯形微带单极子天线结构图。(a)天线正面;
(b)天线背面

Fig. 4 Structure diagram of ultra-wideband stepped microstrip monopole antenna. (a) Front antenna; (b) back antenna

表1 天线具体几何参数

Table 1 Specific geometric parameters of antenna unit: mm

Parameter	Value	Parameter	Value	Parameter	Value
L	22	W	13	H	0.8
W_1	1.5	W_2	1.3	W_3	1
L_1	3	L_2	5	L_3	2
L_p	12	L_s	4.216	W_s	3.5
L_g	8.7	L_d	3.6	W_d	1.295

单极子天线进行建模仿真。图 5 为该天线的 S11 特性曲线仿真结果图,可以看出,S11 值小于 -10 dB 时,带宽范围在 2.9~22.1 GHz 之间。




图5 超宽带阶梯形微带单极子天线 S11 特性曲线 HFSS 仿真结果

Fig. 5 HFSS simulation result of S11 characteristic curve of ultra-wideband stepped microstrip monopole antenna

3.2 新型 DMLP 的天线建模优化过程

新型 DMLP 的超宽带阶梯形微带单极子天线建模过程如下。

1) 通过 HFSS 软件建模,优化分析天线的 8 个几何参数,从中提取出总共 127296 个样本,具体样本数如表 2 所示。

2) 采集样本之后需要对数据进行预处理,由于采集样本参数各不相同,所以需要对数据进行归一化处理,在输出时再做恢复处理。

数据归一化公式表示为

$$x_n = \frac{x - \min(x)}{\max(x) - \min(x)} \quad (13)$$

恢复公式表示为

$$x = x_n[\max(x) - \min(x)] + \min(x) \quad (14)$$

表 2 采样点变量情况

Table 2 Sampling point variables

Geometric parameter	Minimum value	Maximum value	Sampling step size	Number of samples
W_1 /mm	1.4	1.6	0.1	3
W_2 /mm	1.20	1.30	0.05	3
W_3 /mm	0.9	1.0	0.1	2
L_D /mm	3.6	3.7	0.1	2
W_D /mm	1.270	1.295	0.025	2
L_C /mm	8.6	8.7	0.1	2
W_S /mm	3.4	3.5	0.1	2
L_S /mm	4.108	4.216	0.108	2
Frequency /GHz	2	24	0.1	221

3) 建立 DMLP 网络模型, 本文使用 Pytorch 深度学习框架搭建了此神经网络架构模型, 7 层全连接层, 每层连接之间使用 ReLU 激活函数, 并在每层之间加入

drop-out 操作。

4) 设定超参数, 主要设定超参数有 batch-size、learning rate、drop-out 丢弃比例、loss 函数及其 epochs。

5) 将数据输入导入 DMLP 模型中进行训练, 利用 Adam 优化器对进行梯度的更新, 优化网络所有的权值阈值, drop-out 随机丢弃节点, 保证其不陷入局部最优解。

6) 判断输出结果是否符合预期, 若符合, 则完成训练, 保存权值阈值; 若不符合, 则判断是否到达最大迭代次数。若没达到, 则回到步骤 5 循环, 迭代次数加一, 直到达到最大迭代次数; 若达到最大迭代次数, 则结束训练, 观察损失值下降趋势, 判断是否有下降可能。若有可能, 则增大 epochs 值; 若无可能且还未达到预期, 则回到步骤 4, 适当调整超参数或者网络架构。

具体流程如图 6 所示, 训练完毕后进行验证。

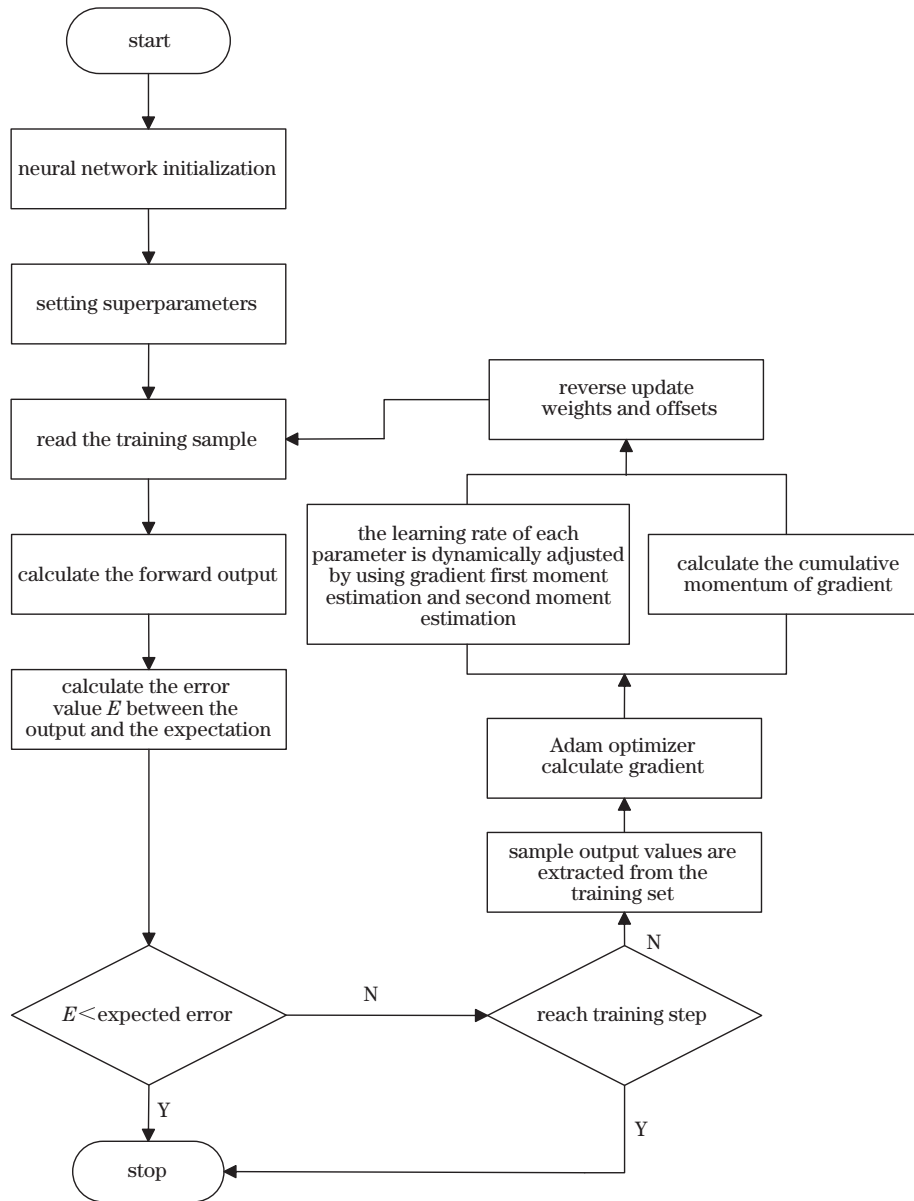


图 6 DMLP 神经网络流程图

Fig. 6 Flow chart of DMLP neural network

4 实验仿真及其结果

以 HFSS 软件将超宽带阶梯形微带单极子天线建模仿真出来的 S11 参数为例,将本文 DMLP 网络建模的预测结果与传统 MLP 网络、RBF 网络所预测结果进行比较分析,以验证本文 DMLP 网络的优越性。实验在 Pytorch1.8 版本 cuda11.0 上实现三种网络建模的构建及其训练。

根据上文建模步骤,用 HFSS 生成 127296 个样本之后,转置每 211 行 S11 使其变为 1 行,几何参数变为每 221 行保留 1 行,把 8 个几何参数作为输入,221 个 S11 数据作为输出,其意义为 8 个几何参数映射出一条关于 S11 的函数曲线,使得数据处理变成 576 行,其中 80% 作为训练集,20% 作为测试集。DMLP 网络建模、MLP 网络建模和 RBF 网络建模使用相同的数据集。

本文建模方式和 MLP、RBF 均执行 20000 轮次迭代,从图 7 可以看出,DMLP 网络的损失曲线在前 100 轮次中急速下降收敛至 1×10^{-2} 位次,用时 8.3 s。在 20000 轮次迭代之后达到底部 9×10^{-5} 左右,此后趋于平滑,用时 27 min 53.3 s。传统 MLP 网络的损失曲线在前 3000 轮次中缓速下降,在 6000 轮次左右下降到底部 1.6×10^{-3} 之后不再下降,用时 3 min 42.4 s,每百轮次用时约为 3.7 s。RBF 网络的损失曲线在 500 轮次时下降到 1×10^{-2} 位次,再到 15000 轮次之间缓速下降,到达底部 1.8×10^{-3} ,每百轮次用时 3.9 s,RBF 网络相比 MLP 网络拥有更快的收敛速度,但是精度有所不及。由此可见,DMLP 网络不仅收敛速度要比传统 MLP 网络以及 RBF 网络收敛速度快,而且收敛精度也提高了接近一个位次。

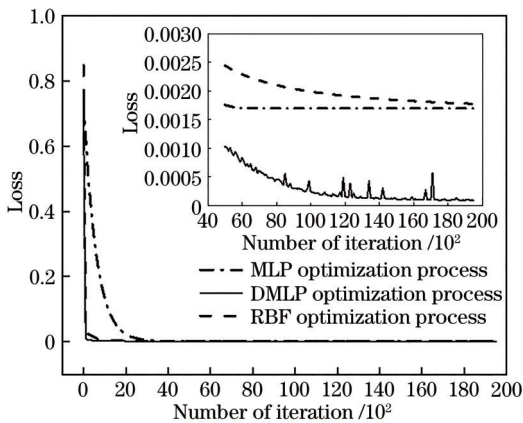


图 7 DMLP 网络、RBF 网络以及 MLP 网络优化过程
Fig. 7 Optimization process of DMLP network, RBF network, and MLP network

使用天线原本数据进行预测,利用 DMLP、MLP 和 RBF 求出相应天线参数对应的 S11 曲线,实际输出拟合曲线如图 8 所示。可以得知,DMLP 网络所得出

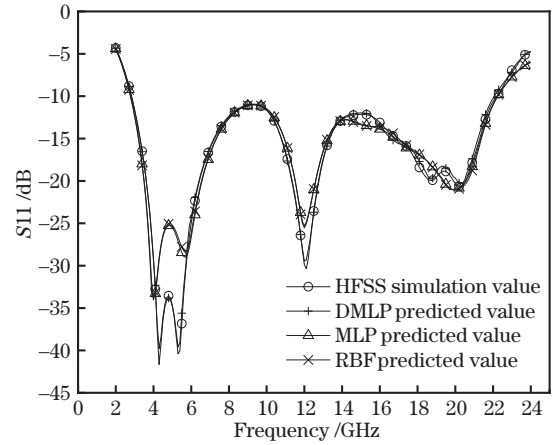


图 8 在原数据中三种网络的预测曲线及其 HFSS 仿真曲线拟合情况
Fig. 8 Prediction curves of three kinds of networks and their HFSS simulation curves fitting in original data

Fig. 8 Prediction curves of three kinds of networks and their HFSS simulation curves fitting in original data

的 S11 曲线对 HFSS 仿真 S11 曲线的拟合程度大幅度领先于 MLP 网络、RBF 网络所得出的 S11 曲线。为了保证网络的泛化能力和鲁棒性,本文挑选了一条不在训练集中的插值再一次进行验证。结果如图 9 所示,可以看出,DMLP 网络对比 MLP 网络、RBF 网络同样具有优越性,证明了 DMLP 网络性能优于 MLP 网络、RBF 网络。




图 9 在插值数据中三种网络的预测曲线及其 HFSS 仿真曲线拟合情况
Fig. 9 Prediction curves of three kinds of networks and their HFSS simulation curves fitting in interpolation data

Fig. 9 Prediction curves of three kinds of networks and their HFSS simulation curves fitting in interpolation data

表 3 是三种网络的具体性能比较,对比三种网络训练数据值可知,DMLP 网络较 MLP 网络、RBF 网络

表 3 三种网络性能比较

Table 3 Performance comparison of three networks

Neural network model	MAE	RMSE	MRE	Maximum relative error
DMLP	0.2860	0.3948	1.6701	1.877
MLP	1.4692	2.8208	7.0359	13.300
RBF	1.5236	2.9171	7.3067	13.780

对所预测值从平均误差(MAE)、均方根误差(RMSE)和平均相对误差(MRE)来看,DMLP神经网络对超宽带阶梯形微带单极子天线的拟合精度拥有巨大领先优势。

5 结 论

本文设计的DMLP神经网络,应用了多种先进深度学习手段,如Adam优化器、drop-out数据处理等,解决了传统MLP神经网络对于复杂多参数非线性任务拟合精度不够的问题。通过对超宽带阶梯形微带单极子天线的S11值进行拟合的实验可以看出,由于加入Adam优化器及其ReLU激活函数,DMLP网络拟合速度大幅度提升,所使用的梯度式深层全连接网络结构使得对天线的几何参数所具备特征的学习能力以及映射能力大幅度提升,拟合精度也大幅度上升,drop-out技术既有效避免了选入局部最优解的困局,又增加了网络的鲁棒性。与MLP和RBF的对比实验证明了DMLP网络在射频器件优化设计中有更好的表现,该网络为天线的快速设计提供了一个有效的工具。

参 考 文 献

- [1] Liang J, Guo L, Chiau C C, et al. Study of CPW-fed circular disc monopole antenna for ultra wideband applications[J]. IEE Proceedings-Microwaves, Antennas and Propagation, 2005, 152(6): 520-526.
- [2] Maini S, Marwaha A. Modeling and simulation of novel antenna for the treatment of hepatocellular carcinoma using finite element method[J]. Electromagnetic Biology and Medicine, 2013, 32(3): 373-381.
- [3] 祝言菊, 李永明, 俞集辉, 等. 不同车载天线电磁特性的仿真研究[J]. 系统仿真学报, 2009, 21(24): 7956-7960.
Zhu Y J, Li Y M, Yu J H, et al. Simulation of electromagnetic characters of different automotive antennas [J]. Journal of System Simulation, 2009, 21(24): 7956-7960.
- [4] Wang W T, Gong S X, Wang X, et al. Differential evolution algorithm and method of moments for the design of low-RCS antenna[J]. IEEE Antennas and Wireless Propagation Letters, 2010, 9: 295-298.
- [5] Wu Q, Cao Y, Wang H M, et al. Machine-learning-assisted optimization and its application to antenna designs: opportunities and challenges[J]. China Communications, 2020, 17(4): 152-164.
- [6] 蒋妮, 周海洋, 余飞鸿. 基于计算机视觉的目标计数方法综述[J]. 激光与光电子学进展, 2021, 58(14): 1400002.
Jiang N, Zhou H Y, Yu F H. Review of computer vision based object counting methods[J]. Laser & Optoelectronics Progress, 2021, 58(14): 1400002.
- [7] 李鸿彬, 孟庆浩, 孙玉哲, 等. 基于深度学习门牌检测的机器人室内定位方法[J]. 激光与光电子学进展, 2021, 58(14): 1415005.
Li H B, Meng Q H, Sun Y Z, et al. Deep learning-based doorplate detection for mobile robot localization in indoor environments[J]. Laser & Optoelectronics Progress, 2021, 58(14): 1415005.
- [8] 周子纯, 刘琨, 江俊峰, 等. 基于卷积长短期记忆全连接神经网络的光纤振动传感事件识别[J]. 光学学报, 2021, 41(13): 1306019.
Zhou Z C, Liu K, Jiang J F, et al. Optical fiber vibration-sensing event recognition based on CLDNN[J]. Acta Optica Sinica, 2021, 41(13): 1306019.
- [9] Wang T Q, Wen C K, Wang H Q, et al. Deep learning for wireless physical layer: opportunities and challenges [J]. China Communications, 2017, 14(11): 92-111.
- [10] da F Silva P H, Oliveira E E C, D' Assunção A G. Using a multilayer perceptrons for accurate modeling of quasi-fractal patch antennas[C]//2010 International Workshop on Antenna Technology (iWAT), March 1-3, 2010, Lisbon, Portugal. New York: IEEE Press, 2010: 11305864.
- [11] Xiao L Y, Shao W, Liang T L, et al. Artificial neural network with data mining techniques for antenna design [C]//2017 IEEE International Symposium on Antennas and Propagation & USNC/URSI National Radio Science Meeting, July 9-14, 2017, San Diego, CA, USA. New York: IEEE Press, 2017: 159-160.
- [12] Calik N, Belen M A, Mahouti P. Deep learning base modified MLP model for precise scattering parameter prediction of capacitive feed antenna[J]. International Journal of Numerical Modelling: Electronic Networks, Devices and Fields, 2020, 33(2): e2682.
- [13] Sharma S, Thakare V V. Resonant frequency analysis of circular microstrip patch antenna design with u-slot using artificial neural networks[J]. International Journal of Science, Engineering and Technology Research, 2016, 5 (8): 2585-2590.
- [14] 周志华. 机器学习[M]. 北京: 清华大学出版社, 2016: 425.
Zhou Z H. Machine learning[M]. Beijing: Tsinghua University Press, 2016: 425.
- [15] Kingma D P, Ba J. Adam: a method for stochastic optimization[EB/OL]. (2014-12-22) [2021-05-04]. <https://arxiv.org/abs/1412.6980>.
- [16] Szegedy C, Vanhoucke V, Ioffe S, et al. Rethinking the inception architecture for computer vision[C]//2016 IEEE Conference on Computer Vision and Pattern Recognition, June 27-30, 2016, Las Vegas, NV, USA. New York: IEEE Press, 2016: 2818-2826.
- [17] 南敬昌, 王明寰. 超宽带阶梯形微带单极子天线的设计与研究[J]. 电波科学学报, 2021, 36(2): 225-230.
Nan J C, Wang M H. Design and research of ultra-wideband stepped microstrip monopole antenna[J]. Chinese Journal of Radio Science, 2021, 36(2): 225-230.