

DOI: 10.13382/j.jemi.B2205736

一维卷积神经网络超宽带天线建模方法*

南敬昌¹ 孙雯雯¹ 杜有益¹ 王明寰²

(1. 辽宁工程技术大学电子与信息工程学院 葫芦岛 125105; 2. 南京理工大学电子工程与光电技术学院 南京 210000)

摘要:为加快天线建模优化速度,提出了一种改进的一维卷积神经网络(1D-MCNN)模型。此一维神经网络的卷积核大小为2,将ReLU函数作为激活函数降低梯度弥散;利用Adam优化器与dropout技术结合,提高模型的特征学习能力和非线性函数逼近能力。本文使用1D-MCNN模型对超宽带微带单极子天线几何参数建模,以天线的8个几何参数作为特征输入,对天线的回波损耗值进行预测。实验表明,本文所提1D-MCNN模型与深层MLP网络模型、MLP网络模型、RBF神经网络模型相比,回波损耗值的平均误差分别减小了1.95%,120.27%,125.71%,拥有更高的准确度,预测能力更强,对优化超宽带天线建模可行且性能具有一定优越性。

关键词:一维卷积神经网络;超宽带单极子天线;Adam优化器;dropout技术

中图分类号: TP18 **文献标识码:** A **国家标准学科分类代码:** 510.5099

One-dimensional convolutional neural network modeling method for ultra-wideband antenna

Nan Jingchang¹ Sun Wenwen¹ Du Youyi¹ Wang Minghuan²

(1. School of Electronics and Information Engineering, Liaoning Technical University, Huludao 125105, China;

2. School of Electronic Engineering and Photoelectric Technology, Nanjing University of Science and Technology, Nanjing 210000, China)

Abstract: To speed up the optimization of antenna modeling, an improved one-dimensional convolutional neural network (1D-MCNN) model is proposed. The convolution kernel size of this one-dimensional neural network is 2, and the ReLU function is used as the activation function to reduce the gradient dispersion. The Adam optimizer is combined with dropout technology to improve the feature learning ability and nonlinear function approximation ability of the model. In this paper, the 1D-MCNN model is used to model the geometric parameters of the ultra-wideband microstrip monopole antenna. The eight geometric parameters of the antenna are used as feature inputs to predict the return loss value of the antenna. Experiments show that compared with the deep MLP network model, MLP network model, and RBF neural network model, the average error of the return loss value of the 1D-MCNN model proposed in this paper is reduced by 1.95%, 120.27%, and 125.71% respectively. It has higher accuracy and stronger prediction ability. It is feasible to optimize the modeling of ultra-wideband antennas and has certain advantages.

Keywords: one-dimensional convolutional neural network; the UWB monopole antenna; Adam optimizer; dropout technology

0 引言

应时代发展要求,无线通信已然走进千家万户,渐渐融入到人们的生活中。在短距离通信中,超宽带(ultra-wideband, UWB)无线通信系统凭着传输速率高、成本低

以及系统设计简单等优点,被应用到各大领域^[1-3]。天线作为无线通信系统中重要的组成部分,其设计方法和实现效率一直是学者专研的课题。传统的天线设计方法可以对天线的各种性能进行精确的模拟仿真,如有限元法(finite element method, FEM)^[4-5]、有限积分法(finite integral technology, FIT)^[6]、矩量法(method of moments,

收稿日期: 2022-08-09 Received Date: 2022-08-09

* 基金项目: 国家自然科学基金(61971210)、企业合作课题: 射频 LDMOS 功放器件研究测试(21-2-32)项目资助

MoM)^[7]等数值分析法,但是针对复杂天线的多参数变量优化,需要大量的计算资源,长时间的调参和试错阻碍了天线大规模参数优化的普遍应用。

计算机科学及其硬件的发展令人工神经网络(artificial neural network, ANN)^[8-9]从一众机器学习算法中脱颖而出,回归到人们的视野中,用神经网络解决无线通信系统问题也就成为了一种有效手段。与传统的电磁仿真软件相比,使用 ANN 模型设计天线不需要具备更多的专业知识和工作经验,仅凭借输入输出数据的非线性就可以实现天线性能参数的预测^[10]。

文献[11]提出一种3层感知器(multilayer perceptron, MLP)神经网络模型,能够快速的训练出射频频微同轴器件尺寸参数与 S 参数的非线性关系,并且结合 HFSS 设计出特征阻抗可以匹配到 50Ω 的器件。文献[12]采用融合 MLP 和先验知识(KPI)神经网络模型代替电磁仿真软件,对可重构微带天线的参数进行优化。文献[13]提出一种粒子群优化算法(particle swarm optimization, PSO)优化 ANN 建模方法,首先通过训练 ANN 模型,得到一个含有分形天线设计参数和相应工作特性的黑匣子,再将 PSO 算法作为优化器来寻找天线的尺寸。文献[14]以发射阵列为设计对象,提出一种遗传算法(genetic algorithm, GA)优化神经网络逆向模型,该模型解决了输入输出数据的非线性关系,但建模过程些许繁琐。在设计高维参数空间天线问题上,文献[15]提供了一种基于新型反向传播(back propagation, BP)神经网络模型,实现了神经网络对天线的快速设计,但 BP 神经网络极易陷入局部最优。文献[16]利用差分进化算法对天线几何参数进行优化,得到一款性能良好的变容二极管加载微带天线,整个过程简单且快速。

神经网络的加入提高了电磁仿真软件的工作效率,简化了其设计流程,但在面对电磁器件的复杂内部结构时,简单的网络模型难以精准的建立器件结构参数与电磁响应之间的非线性关系。深度学习因为其具有解决高维,非线性问题的能力,引用进了各领域中,例如卷积神经网络^[17]在计算机视觉中大放异彩,循环神经网络^[18]在自然语言处理中也表现出色,最近新架构 transformer^[19]在这两个领域也呈现出惊人的效果。卷积神经网络在图像识别和计算机视觉中是佼佼者,但在无线通信系统中属于初学者。本文引用一维卷积神经网络加速天线优化过程^[20],区别于标准的卷积神经网络,引入了 ReLU 函数弱化网络梯度下降存在的问题,在网络层中添加 dropout 技术,根据丢弃率使神经元短暂的停止训练,同时采用 Adam 优化器迭代更新参数,防止过拟合;使用从 HFSS 中提取的几百组数据,通过卷积神经网络训练成功之后得到相应超宽带单极子天线网络模型,输入其余数千组数据进此模型中,快速求取相应结果,从而达到加速天线

建模优化的效果。

1 改进一维卷积神经网络

1.1 一维卷积神经网络 1D-CNN

卷积神经网络(convolutional neural networks, CNN)^[21]于1979年首次实现,它是一种特殊的前馈神经网络,通常由输入层、卷积层、池化层、全连接层和输出层组成,标准的卷积神经网络架构如图1所示。

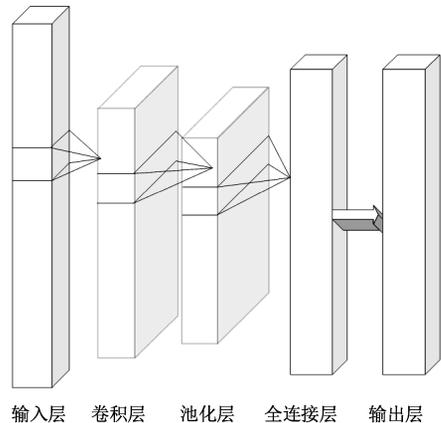


图1 标准卷积神经网络架构

Fig. 1 Standard convolutional neural network architecture

以天线的结构参数为特征图,由输入层进入卷积层,卷积层中的卷积核与上一层的特征图进行局部卷积计算。由于权值共享机制,计算后的每个卷积核都会产生相对应的特征图,且输出特征图的深度取决于卷积核大小。卷积层输出公式为:

$$\mathbf{y}^l = f(\mathbf{w}^l \otimes \mathbf{x}^{l-1} + \mathbf{b}^l) \quad (1)$$

式中: \mathbf{y}^l 为第 l 层卷积层的输出; \mathbf{w}^l 为第 l 层卷积层的卷积核; \mathbf{x}^{l-1} 为第 $l-1$ 层即上一层的输出; \mathbf{b}^l 为第 l 层的偏置; \otimes 为卷积运算。

$f(\cdot)$ 为激活函数,用来解决模型中的输入输出非线性关系,故激励函数通常选用非线性函数。本文选择校正线性单元(rectified linear unit, ReLU)函数为激励函数,其函数表达式如下:

$$f_{\text{ReLU}}(x) = \max(0, x) \quad (2)$$

经过 ReLU 函数非线性变化,特征图通过池化窗口进入池化层,利用池化操作减少神经元数量以及参数,简化模型计算,同时保留重要特征。池化操作分最大池化、均值池化、随机池化,本文采用最大池化操作,即将上一层的输出特征图在池化接受域的最大值作为池化层的输出,具体计算公式如下:

$$h^{l+1} = \max_{(j-1)S+1 < t < jS} \{g^l(t)\} \quad (3)$$

式中: h^{l+1} 为第 $l+1$ 层输出值; j 为步长; S 为池化核大小;

$g^l(t)$ 为第 l 层第 t 个神经元的输出值。

全连接层接收到前面卷积层与池化层交替输出的结果,将特征图重新整合提取,重新排列成一个一维特征向量,传递到输出层。全连接的运算过程如下:

$$\mathbf{y}^r = f(\mathbf{w}^r \cdot \mathbf{y}^{r-1} + \mathbf{b}^r) \quad (4)$$

式中: \mathbf{y}^r 为第 r 层全连接层的输出; $f(\cdot)$ 为激活函数; \mathbf{w}^r 为第 r 层的权重矩阵; \mathbf{y}^{r-1} 为第 $r-1$ 层的输出; \mathbf{b}^r 为第 r 层的偏置项; \cdot 为矩阵点乘。

CNN 作为特殊的深度神经网络,可以通过有监督学习进行训练,选择反向传播算法计算输出层结果与实际数据的误差梯度,以此更新网络的权值和阈值,满足误差条件即完成学习。定义网络损失函数(loss function)如下:

$$E_{Loss} = \frac{1}{n} \sum_{i=1}^n (y_{actual}^i - y_{predict}^i)^2 \quad (5)$$

式中: y_{actual}^i 为原始数据, $y_{predict}^i$ 为网络预测输出值。

1.2 Adam 优化器

Adam 优化器是在 RMSProp 和 AdaGrad 的基础上改进的一种算法,将目标函数的梯度更新设计独立的自适应学习率,使得训练过程中参数可以朝着当前梯度的反方向平稳的变化,避免出现梯度消失或梯度爆炸问题。Adam 优化器梯度结合之前的运动状态选择更新下降方向,不受梯度伸缩变换影响,更适合应用大规模的数据计算,而且 Adam 优化器对内存需求少,实现平台容易,计算过程简单,具体梯度下降实现过程如下。

权重矩阵 \mathbf{w} 为网络更新的对象,设上述损失函数 E_{Loss} 为目标函数,记为 $E^t(\mathbf{w})$,它表示参数 \mathbf{w} 在第 t 次迭代时的函数,则权重矩阵的梯度计算公式如下:

$$g^t = \nabla_{\mathbf{w}} E^t(\mathbf{w}) \quad (6)$$

对参数 \mathbf{w} 分别求指数梯度平均值 m^t 和梯度平方 v^t ,计算公式如下:

$$m^t = \beta_1 m^{t-1} + (1 - \beta_1) g^t \quad (7)$$

$$v^t = \beta_2 v^{t-1} + (1 - \beta_2) g^{t2} \quad (8)$$

式中: m^{t-1} 和 v^{t-1} 分别代表 $t-1$ 次更新的指数梯度均值和梯度平方; β_1 和 β_2 为 $[0, 1]$ 区间的平滑常数。

根据上式计算得到 $t=0$ 时,指数梯度均值为 0,而 β 趋于 1,此时需要对指数移动均值 m^t 和梯度平方 v^t 进行偏差纠正,纠正后的表达式为:

$$\hat{m}_t = \frac{m_t}{1 - (\beta_1)^t} \quad (9)$$

$$\hat{v}_t = \frac{v_t}{1 - (\beta_2)^t} \quad (10)$$

式中: t 为更新迭代次数。

由式(9)和(10)推导得到参数 \mathbf{w} 的更新公式为:

$$\mathbf{w}^{t+1} = \mathbf{w}^t - \eta \frac{\hat{m}_t}{\sqrt{\hat{v}_t + \varepsilon}} \quad (11)$$

式中: η 为学习率; ε 为定量常数,目的是防止分母为 0。

1.3 改进一维卷积神经网络构建

本文在标准 CNN 的基础上提出一种改进的一维卷积神经网络(1D-MCNN)超宽带单极子天线建模方法,具体模型如图 2 所示。网络模型包含 4 个卷积层,2 个池化层,1 个 Flatten 层以及 1 个全连接层,各层之间的连接为前向传播和后向传播。相较于标准 CNN 模型,1D-MCNN 模型优化方案如下。

1) 将原本的 Sigmoid 函数改为 ReLU 函数,有效缓解了梯度爆炸或者梯度消失的问题。

2) 为防止网络训练过程出现过拟合现象,在 1D-MCNN 模型中引入 dropout 技术,使得卷积神经网络前向传播时部分神经元停止工作,减少冗余量,即有些神经元以概率 p 临时被网络剔除,其操作公式为:

$$p = p(a = 1 | x) = \sum_{i,j \in N_a} \frac{\exp(w_{i,j}^l \cdot x_j^{l-1} + b_i^l)}{1 + \exp(\sum_{i,j \in N_a} w_{i,j}^l \cdot x_j^{l-1} + b_i^l)} \quad (12)$$

式中: a 为样本; N_a 为样本数量; $w_{i,j}^l$ 为第 l 层第 i 个通道第 j 个神经元的权重; x_j^{l-1} 为第 l 层第 j 个神经元的输出; b 为第 l 层第 i 个通道的偏置。则经过 dropout 操作得到的输出公式为:

$$\mathbf{y}^l = f(p \cdot \mathbf{w}^l \otimes \mathbf{x}^{l-1} + \mathbf{b}^l) \quad (13)$$

3) 使用 Adam 优化器计算和更新 1D-MCNN 模型的网络参数。借助 Adam 算法梯度的对角缩放特性,求解大批量的数据集或参数,处理电磁器件内部电路的非线性关系。

1D-MCNN 模型的构建以天线的结构参数作为输入。首先,使用卷积核为 2 的卷积层降低特征维度,通过卷积层和池化层交替的组合进行前向训练,完成结构参数特征提取。为了确保网络良好的泛化性和拟合能力,1D-MCNN 模型每两层进行一次 dropout 操作,剔除上一层的神经元,降低模型传播维度。此外,本文利用 Adam 优化器进行梯度更新,对网络参数进行微调,得到最优的网络模型,加快了模型的运算速度。

2 1D-MCNN 单极子天线建模优化算法

2.1 超宽带微带单极子天线特性

以超宽带阶梯形微带单极子天线作为本文所提算法的实验对象,具体结构如图 3 所示,左侧为天线顶部,右侧为天线底部^[22]。该天线尺寸为 13 mm,宽为 22 mm,介质基板厚度为 0.8 mm。为了实现单极子天线小型化,将原有的矩形微带馈电线改进为 50 Ω 三段阶梯形,微带馈电总长度为 10 mm,部分接地平面长度为 8.7 mm。同时,采用缺陷地面结构(DGS)去耦,在矩形辐射贴片底边

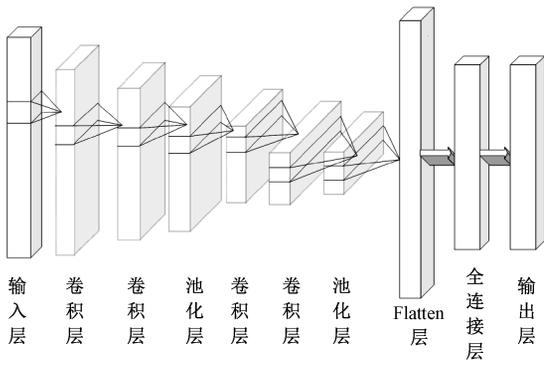


图2 改进一维卷积神经网络架构

Fig. 2 Modified one-dimensional convolutional neural network architecture

开三角形槽,部分接地平面开矩形槽和上三角槽,增大了天线表面电流路径,有效的提高天线带宽。贴片长为12 mm,截去的三角形槽长为4.108~4.216 mm,宽为3~3.5 mm,矩形槽长为3.6~4 mm。单极子天线的工作频段在2.6~22.1 GHz,在此频段内回波损耗小于-10 dB,电压驻波比VSWR小于2。

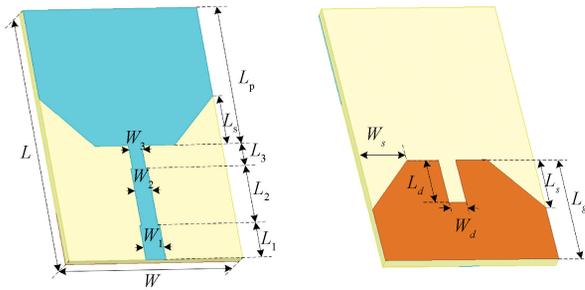


图3 超宽带阶梯形微带单极子天线结构

Fig. 3 Structure diagram of ultra-wideband stepped microstrip monopole antenna

2.2 1D-MCNN 超宽带微带单极子天线建模算法过程

1D-MCNN 超宽带微带单极子天线建模的具体过程如下所述。

步骤1) 通过 HFSS 软件仿真提取天线参数,按照8:1:1的比例分为训练样本,测试样本和验证样本。具体样本如表1所示。

表1 单极子天线结构参数取值范围

Table 1 Range of structural parameters of monopole antenna

参数	取值范围/mm	参数	取值范围/mm
W_1	1.0~2.0	W_d	1.0~1.5
W_2	1.0~1.5	L_g	8.0~9.0
W_3	0.9~1.0	W_s	3.0~3.5
L_d	3.5~4.0	L_s	4.0~4.5

步骤2) 数据预处理。为了统一各参数的规格,对数

据集进行归一化处理,得到网络输出结果后恢复数据。归一化公式表达式为:

$$x_i = \frac{x - x_{\min}}{x_{\max} - x_{\min}} \quad (14)$$

式中: x_i 为归一化后的输出结果; x_{\max} 和 x_{\min} 分别为 x 的最大值和最小值。

步骤3) 建立一维卷积神经网络模型。本文使用 Pytorch 语言搭建4层卷积层,再连接全连接层,每2层卷积层连接之间夹杂池化层,用来保证去除冗余信息、对特征进行压缩、简化网络复杂度。并在每2层之间加入 dropout 技术,防止过拟合现象。

步骤4) 设置超参数。初始化 1D-MCNN 模型权重 w^l 和偏置 b^l , 并且设置模型参数,其中包括 batch-size、learning rate、dropout 丢弃比例、损失函数类型等。

步骤5) 训练 1D-MCNN 模型。将处理后的数据集导入模型,进行前向传播,再利用 Adam 优化器进行梯度更新,优化模型参数。

步骤6) 判断训练是否成功。如果损失函数值 E_{loss} 满足所设阈值或是达到最大迭代次数,则训练结束。否则回到步骤4),调整网络和超参数后重新训练。通过损失函数检验模型性能的好坏,找到符合损失函数的值最小的权值阈值,最后输出预测结果以及误差。1D-MCNN 模型建模流程图如图4所示。

3 实验与结果分析

使用 HFSS 软件将此单极子天线仿真出的回波损耗 S_{11} 为例。本文所使用的 1D-MCNN 模型建模的预测结果与深层 MLP (DMLP) 网络,MLP 网络,RBF 网络的预测结果做出对比,以此来验证一维卷积神经网络的优越性,其中 DLMP 模型中改进方法与本文均采用了 dropout 技术剃掉隐藏层部分神经元,以及利用 Adam 优化器更新 MLP 网络的参数。本实验在 Pytorch1.8 版本上完成4种网络模型的搭建和训练。

本文以该天线的8个结构参数为输入,天线回波损耗 S_{11} 为输出,即建立 1D-MCNN 模型训练出单极子天线的特性曲线。在 HFSS 中完成对单极子天线的仿真,导出天线结构参数对应的回波损耗数据集。按照表1的采样点变量情况,设置扫频范围为2~22 GHz,步长为0.5 GHz,最后共生成2000组数据,1600组作为训练样本,其余400组分别为训练样本和测试样本。本文所提 1D-MCNN 模型及做对比实验的训练模型均采用同一组数据集。

1D-MCNN 模型与 DMLP 模型,MLP 网络模型,RBF 网络模型都执行20000轮次迭代,从图5中可以看出本文所搭建的 1D-MCNN 模型收敛速度远远高于其他3种

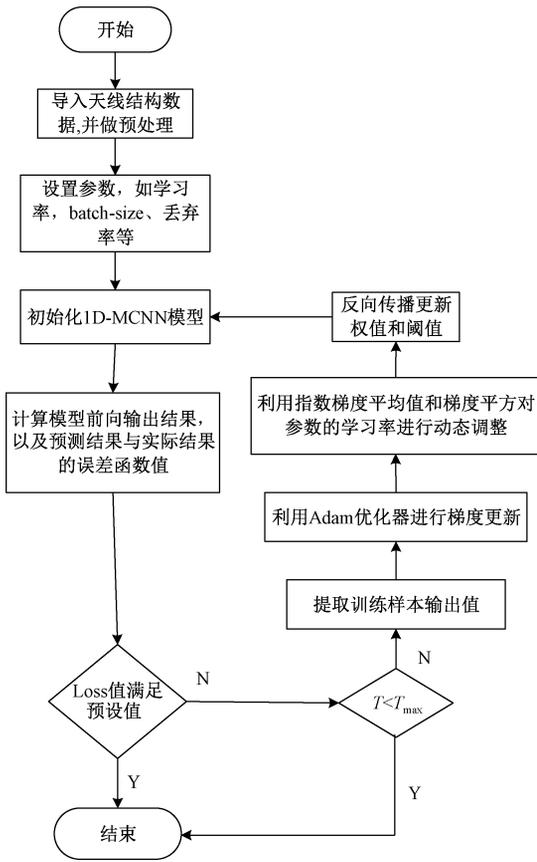


图 4 1D-MCNN 建模流程

Fig. 4 1D-MCNN modeling flow chart

网络, 到达 10^{-3} 精度所用的拟合轮次比普通 MLP 网络, RBF 网络分别提前 2 500 轮次, 600 轮次, 达到 10^{-4} 精度所用的拟合轮次比深度 MLP 网络提前 3 000 轮次。收敛精度远远高于 MLP 网络和 RBF 网络, 1D-MCNN 网络最低点为 5×10^{-5} 左右, DMLP 网络最低点为 9×10^{-5} 左右, 精度较之提高了近 1/2。由此可看出一维卷积神经网络的性能远超前于 MLP 网络和 RBF 网络, 大幅度领先 MLP 网络。

图 6 为本文提出模型与 DMLP 模型、MLP 模型、RBF 网络模型对单极子天线的 S₁₁ 预测结果。可以看出, HFSS 仿真得到的天线工作频段在 2.6~22.1 GHz, 使用 4 种神经网络的预测天线回波损耗在 -10 dB 以下的工作频段为 3~22.4 GHz。从图 6 可以看出, 4 种神经网络模型中, 在陷落 4~6 GHz 处, MLP 模型、RBF 网络模型与实际仿真结果相差太大, 本文所提和 DLMP 模型预测结果可以和 HFSS 仿真结果拟合, 但 1D-MCNN 模型更接近与仿真结果, 说明所提模型预测精度更高, 鲁棒性和泛化能力更好。

表 2 从平均绝对误差 (MAE)、均方根误差 (RMSE)、相对误差 (MRE) 和最大误差 4 个指标衡量 4 种网络的性

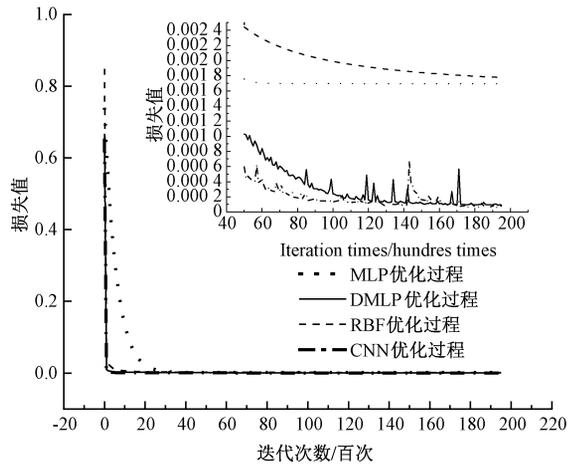


图 5 4 种网络模型优化过程

Fig. 5 Four network model optimization processes

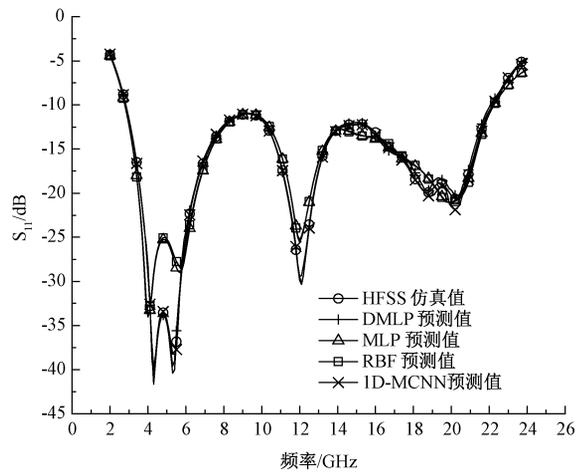


图 6 4 种网络的预测曲线及其 HFSS 仿真曲线拟合情况

Fig. 6 Prediction curve and HFSS simulation curve fitting of four networks

能情况。通过训练可知, 1D-MCNN 模型的 MAE 值为 0.266 5, RMSE 值为 0.322 7, MRE 值为 1.552 4。以回波损耗的 RMSE 值为例, 1D-MCNN 模型的预测精度比 DMLP 模型高 18.26%, 比 MLP 模型高 85.01%, 比 RBF 模型高 85.51%。综上所述本文所提 1D-MCNN 模型对比 DMLP 神经网络的拟合精度拥有小幅度领先, 对 MLP 网络与 RBF 网络有大幅度领先, 可以更好的进行无监督学习, 处理大批量数据。

表 2 4 种网络模型性能指标

模型	MAE	RMSE	MRE	最大误差
1D-MCNN	0.266 5	0.322 7	1.552 4	1.237
DMLP	0.286 0	0.394 8	1.670 1	1.877
MLP	1.469 2	2.820 8	7.035 9	13.30
RBF	1.523 6	2.917 1	7.306 7	13.78

4 结 论

根据传统仿真建模方法,使用 HFSS 等电磁仿真软件,对一组几何参数进行仿真需要十几分钟到几十分钟,当设计天线的具体参数时需要对多组几何参数进行微调已到所需求的性能,或者寻找到更优性能,但是天线具体参数微调带来的是指数上升的几何参数组合数,所花费的时间与运算资源想当高。

本文设计的一维卷积神经网络,基于深度学习框架对天线的几何参数进行建模,优化改进了传统神经网络对多参数复杂任务的处理精度和处理速度,卷积神经网络所特有的特征提取方法对比全连接网络在提取速度上拥有这巨大的优势,拓宽了电磁仿真方法的探索道路。为天线的快速设计提供了一个有效的工具。设计一组神经网络,提取训练数据,训练神经网络,调整神经网络结构参数,所消耗的时间可能需要几天或者十几天。但是神经网络训练成功之后,就可以使用此网络仿真来代替电磁仿真软件对大数据量仿真所需求的动辄几个月的训练时间和几十万元的服务器平台,正是引入神经网络技术对传统仿真技术的巨大优势的体现。

参考文献

- [1] VERMA S, KUMAR P. Printed Newton's egg curved monopole antenna for ultrawideband applications [J]. IET Microwaves, Antennas & Propagation, 2014, 8(4): 278-286.
- [2] 王生霄, 侯兴松, 黑夏萌. 嵌入 CBAM 结构的改进 YOLOv3 超宽带雷达生命信号检测算法 [J]. 国外电子测量技术, 2020, 39(3): 1-6.
WANG SH X, HOU X S, HEI X M. Improved YOLOv3 UWB radar life signal detection algorithm embedded in CBAM structure [J]. Foreign Electronic Measurement Technology, 2020, 39(3): 1-6.
- [3] SHIH W T, WEN C K, TSAI S H, et al. Fast antenna and beam switching method for mmWave handsets with hand blockage [J]. IEEE Transactions on Wireless Communications, 2021, 20(12): 8134-8148.
- [4] 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.
- [5] WANG J, YANG X S, DING X, et al. Antenna radiation characteristics optimization by a hybrid topological method [J]. IEEE Transactions on Antennas and Propagation, 2017, 65(6): 2843-2854.
- [6] JOUNG J. Machine learning-based antenna selection in

- wireless communications [J]. IEEE Communications Letters, 2016, 20(11): 2241-2244.
- [7] 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(1): 295-298.
- [8] 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.
JIAO L CH, YANG SH Y, LIU F, et al. Seventy years beyond neural networks: Retrospect and prospect [J]. Chinese Journal of Computer, 2016, 39(8): 1697-1716.
- [9] 李征, 房宏才, 柯熙政, 等. 滑动平均算法在 MEMS 陀螺信号趋势项提取中的应用 [J]. 电子测量与仪器学报, 2019, 33(7): 43-49.
LI ZH, FANG H C, KE X ZH, et al. Application of sliding average method to MEMS gyroscope signal trend extraction [J]. Journal of Electronic Measurement and Instrumentation, 2019, 33(7): 43-49.
- [10] 许达. 基于相似日选择联合 PSO-RBF 的光伏出力预测方法 [J]. 电子测量技术, 2020, 43(23): 78-83.
XU D. Photovoltaic output prediction method based on similar day selection combined with PSO-RBF [J]. Electronic Measurement Technology, 2020, 43(23): 78-83.
- [11] TIAN Y, LI N, WANG H, et al. Right-angled micro-coaxial bends for Si-based RF/microwave integrated circuits [J]. IEEE Transactions on Components, Packaging and Manufacturing Technology, 2016, 6(2): 290-297.
- [12] AOAD A. Reconfigurable microstrip antenna optimization through artificial neural networks [C]. 2020 International Conference on Electrical, Communication and Computer Engineering (ICECCE), Istanbul, Turkey: IEEE, 2020: 12-13.
- [13] PATNAIK A, SINHA S N. Design of custom-made fractal multi-band antennas using ANN-PSO [J]. IEEE Antennas and Propagation Magazine, 2011, 53(4): 94-101.
- [14] GOSAL G, MCNAMARA D, YAGOUB M. Transmitarray antenna design using forward and inverse neural network modeling [J]. IEEE Antennas and Wireless Propagation Letters, 2015, 15: 1483-1486.
- [15] 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-objective antenna design based on improved back propagation neural network surrogate model [J]. Journal of Electronic & Information Technology, 2018, 40(11): 2712-2719.

- [16] MAHOUTI P. Design optimization of a pattern reconfigurable microstrip antenna using differential evolution and 3D EM simulation-based neural network model [J]. *International Journal of RF and Microwave Computer-Aided Engineering*, 2019, 29(8): 1-10.
- [17] ROSKA T, CHUA L O. The CNN universal machine: An analogic array computer [J]. *IEEE Transactions on Circuits & Systems II Analog & Digital Signal Processing*, 2015, 40(3): 163-173.
- [18] GRAVES A, MOHAMED A R, HINTON G. Speech recognition with deep recurrent neural networks [C]. 2013 IEEE International Conference on Acoustics, Speech and Signal Processing, Vancouver, Canada; IEEE, 2013: 6645-6649.
- [19] VASWANI A, SHAZEER N, PARMAR N, et al. Attention is all you need [J]. *Advances in Neural Information Processing Systems*, 2017, 30.
- [20] 宋晓凯. 基于卷积神经网络 DOA 估计的测控系统空域抗干扰方法研究 [D]. 哈尔滨: 哈尔滨工业大学, 2020.
SONG X K. Research on anti-jamming method of TT&CIN airspace based on DOA estimation of convolutional neural network [D]. Harbin: Harbin Institute of Technology, 2020.
- [21] 宋芳兵. 卷积神经网络建模研究及应用 [D]. 北京: 华北电力大学, 2021.
SONG F B. Research and application of convolutional neural network modeling [D]. Beijing: North China Electric Power University, 2021.
- [22] 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 CH, WANG M H. Design and research of UWB stepped microstrip monopole antenna [J]. *Journal of Radio Science*, 2021, 36(2): 225-230.

作者简介



南敬昌, 分别在 1993 年、2003 年于辽宁工程技术大学获得学士学位及硕士学位, 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。

E-mail: nanjc886@sina.com

Nan Jingchang received his B. Sc. and M. Sc. degrees both from Liaoning Technical University in 1993 and 2003, Ph. D. degree from Beijing University of Posts and Telecommunications in 2007, respectively. Now he is a professor in Liaoning Technical University. His main research interests include RF circuits and devices, multimedia information coding and communication system simulation.



孙雯雯 (通信作者), 2019 年于渤海大学获得学士学位, 现为辽宁工程技术大学硕士研究生, 主要研究方向为深度学习与射频模块建模等。

E-mail: 472020527@stu.lntu.edu.cn

Sun Wenwen (Corresponding author) received a B. Sc. degree from Bohai University in 2019. She is now a M. Sc. candidate at Liaoning Technical University. Her main research interests include deep learning and RF module modeling design.



杜有益, 2020 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, 主要研究方向为深度学习优化电磁器件建模等。

E-mail: 491887202@qq.com

Du Youyi received a B. Sc. degree from Liaoning Technical University in 2020. He is now a M. Sc. candidate at Liaoning Technical University. His main research interest includes deep learning optimizes electromagnetic device modeling.



王明寰, 分别在 2019 年、2022 年于辽宁工程技术大学获得学士学位及硕士学位, 现为南京理工大学博士研究生, 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: 944959060@qq.com

Wang Minghuan received his both B. Sc. and M. Sc. degrees from Liaoning Technical in 2019 and 2022. He is now a Ph. D. candidate at Nanjing University of Science and Technology. His main research interests include miniaturized ultra-wideband antennas and multiple-input multiple-output antennas.