

专栏:电磁波传输与调控

【特约主持人】张明高:中国工程院院士、电波传播专家

【主持人按语】对电磁波的传输和调控技术的研究是现代通信技术基础研究之一,也是基于物联网和 5G 通信技术的信息社会和数字经济时代不可或缺的组成部分.电磁波的传输与调控技术是雷达遥感技术、电离层探测技术及无线通信技术中的重要组成部分,影响着国计民生的方方面面,对人类社会和科学技术的发展起到了至关重要的作用.我国也高度重视电磁波相关技术的发展,并将其列为国家重点发展领域之一.政府层面加大投入,同时提供了相关政策和法律保障,促进了电磁波相关技术的快速发展.

专栏文章《基于神经网络的微波滤波器设计综述》对神经网络在微波滤波器设计领域的方法进行了系统的综述,并提出了基于训练和精调神经网络的 LC 电路参数提取方法、基于数据自生成神经网络的结构参数估计方法和带宽可重构的滤波器设计方法.利用神经网络学习滤波器设计参数与频率响应之间的关系,可以在较短时间内预测出满足设计要求的 LC 电路参数/器件结构参数.相比较传统的滤波器设计方法能够有效减少设计成本,提高设计效率.

专栏文章《墙体中金属细导体目标的电磁散射特性研究》针对实际工程应用中建筑物墙体结构探测雷达工作场景建立了物理模型.在此基础上利用分层介质中偶极子公式结合边界条件和矩量法提出了一种墙体中金属细导体目标的偶极子源计算方法,该工作将分层媒质目标的散射问题由三维演变成二维问题,首次利用解析方法分析了墙体中金属细导体的散射问题,并可以为超宽带雷达成像新方法研究和电磁学反演方法研究提供理论支持和参考依据.

基于神经网络的微波滤波器设计综述

张安学,杜浩,戴新月,杨倩,郭诚,廖学文

(西安交通大学 电子与信息学部,西安 710049)

摘要:随着微波器件结构复杂度和性能要求的提高,建模和设计过程的时间成本也逐渐增大.在设计过程中引入优化算法可以有效地提高微波器件的设计效率.对神经网络在微波滤波器设计领域的方法进行了系统的综述,提出了基于训练和精调神经网络的 LC 电路参数提取方法、基于数据自生成神经网络的结构参数估计方法和带宽可重构的滤波器设计方法.实验结果表明,神经网络可以利用滤波器的 S 参数信息,在较短时间内预测出满足设计要求的 LC 电路参数/器件结构参数,有效减少设计成本,提高设计效率.

关键词:神经网络;精调;结构参数估计;带通滤波器;可重构

中图分类号:TP391

文献标志码:A

收稿日期:2022-07-09;**修回日期:**2022-10-20.

基金项目:国家自然科学基金(61801367);陕西省深空探测智能信息技术重点实验室资助(2021SYS-04).

作者简介:张安学(1972-),男,河南安阳人,西安交通大学教授,研究方向为天线和电磁波传播、射频和微波电路设计、超材料及其在雷达和无线通信中的应用,E-mail:anxuezhang@mail.xjtu.edu.cn.

通信作者:杜浩,E-mail:duhao1992@stu.xjtu.edu.cn.

在微波领域的迅速发展,目前已经出现很多新型的滤波器结构^[1-2],主要研究方向是通过寻找新的结构或材料,实现可重构或可支撑性和小型化.随着微波滤波器领域研究的不断深入,也越来越需要寻找新的建模技术^[3-4].通用的数值方法使用商业软件创建微波器件的3维模型,但计算过程十分耗时,当微波器件结构复杂时,计算可能需要数小时甚至数天^[5-6].

基于以上所述的缺点,在微波器件领域中除了传统方法之外,基于神经网络的方法也被广泛应用.深度学习作为人工智能技术的分支,已经成功地应用在众多领域,如图像处理^[7]、声音处理^[8]和金融市场预测^[9].神经网络是深度学习的基础,它是受到人类大脑结构启发而诞生的一种算法,具有可以精确地模拟任意非线性函数的能力.经过学习的神经网络可以轻松地模拟复杂的非线性关系.凭借这种优势,基于神经网络的研究方法已经广泛地应用于微波领域^[10-15].与传统的微波器件设计方法相比,基于神经网络的设计方法可以大大加快分析或合成微波器件的过程^[16-17],在更短时间内设计出满足设计要求的器件模型.

本文在介绍了神经网络基础的模型结构和常用的训练方法之后,对现有的基于神经网络的微波器件设计方法进行了对比和综述.在此基础上,提出一种基于训练和精调的神经网络方法,在双通带滤波器 LC 电路的参数提取实验中验证其有效性.提出一种基于数据自生成的神经网络方法,在带通滤波器的结构参数估计和带宽可重构带通滤波器的设计实验中进行了实例验证.实验结果表明,神经网络可以有效利用滤波器的 S 参数信息,经过学习训练之后,准确的预测出满足设计要求的 LC 电路参数/器件结构参数,减少滤波器设计过程的人工干预,实现更加快速高效的器件设计过程.

1 神经网络概述

1.1 神经网络的结构

神经网络的基本结构包括输入层、隐含层和输出层.输入层是神经网络的第一层,用于输入特征矩阵,每个神经元上都是一个特征向量;隐含层至少一层,前后连接输入层和输出层,隐含层中任意 2 层的神经元都是互相连接的,每个神经元上都有一个激活函数,第 $N+1$ 层的神经元处理的是第 N 层神经元经过激活函数之后的数据;输出层是神经网络的最后一层,用于输出神经网络的预测结果.在实际应用中,隐含层的层数以及每层的神经元个数如何设定会影响最终的训练精度和算法最终的学习效果,需要根据设计要求来确定.

如图 1 所示的神经网络结构,输入层包含 2 个神经元 x_1, x_2 ,输出层包含 3 个神经元 y_1, y_2, y_3 ,隐含层有 $N-1$ 层,第 n 层隐含层的神经元个数为 $K^{(n)}$,第 n 层的第 k_n 个神经元表示为 $c_{k_n}^{(n)}$,其中 $n=1, 2, \dots, N-1$, $k_n=1, 2, \dots, K^{(n)}$,神经元 $c_{k_n}^{(n)}$ 的输出根据传输函数 $y_{k_n}^{(n)}$ 定义, $y_{k_{n+1}}^{(n+1)} = f(\sum_{k_n=1}^{K^{(n)}} \omega_{k_{n+1}, k_n}^{(n+1), n} y_{k_n}^{(n)} + b_{k_{n+1}}^{(n+1)})$,其中 $f(x)$ 表示 Sigmoid 激活函数 $f(x) = (1 + e^{-x})^{-1}$, $\omega_{k_{n+1}, k_n}^{(n+1), n}$ 和 $b_{k_{n+1}}^{(n+1)}$ 分别表示神经元 $c_{k_{n+1}}^{(n+1)}$ 和神经元 $c_{k_n}^{(n)}$ 之间的连接权重和偏置.

1.2 神经网络的训练

基于神经网络的优化算法中最重要的步骤就是对网络的训练,训练的主要目的是最小化训练误差.训练过程中不断更新网络权重,降到要求的误差之内后得到最终输出结果.

训练误差是用来判断神经网络是否训练完成的一个重要指标,误差函数 $L(\omega) = E(y_{\text{output}}, y_{\text{label}})$,其中 y_{output} 和 y_{label} 分别表示神经网络真实的输出和期望的输出; E 表示均方误差函数, $E(X, Y) = \frac{1}{n} \sum_{i=1}^n (x_i - y_i)^2$.

更新网络权重通常使用反向传播算法^[18]、拟牛顿法^[19]和共轭梯度法等.这些方法可以有效降低训练误差.针对容易陷入局部最小的复杂优化问题,可以使用全局优化算法来解决,如遗传算法^[20]、模拟退火算法^[21]等.

神经网络的训练方式包括在线训练和离线训练 2 种.在线训练又称逐样本训练,当神经网络输入一个训




图1 神经网络结构图

Fig.1 The structure of the neural network

练样本时更新权重;离线训练又称批量训练模式,给神经网络输入全部训练样本之后再对权重进行一次更新。

2 基于神经网络的微波器件设计方法

2.1 传统神经网络建模方法

结构参数的优化是微波设计中不可回避的重要任务,但随着滤波器参数个数的增加,优化时间也随之增加。因此,基于神经网络的微波器件设计方法受到广泛关注和研究。早在1993年,就有文献中提出将神经网络应用于微带电路的设计中^[22]。之后,有大量文献中提出神经网络在模拟电磁仿真的学习之后,根据滤波器的结构参数计算频率特性,可以作为耗时的电磁仿真软件的替代模型,加快滤波器优化过程^[23-29]。针对复杂的微波器件,神经网络的输入输出关系也会更加复杂、在不增加网络结构复杂度的情况下,建立神经网络正向模型,更新正向模型的输入参数,使模型输出与理想输出的误差达到最小^[30]。

2.2 基于极限学习机的设计方法

极限学习机是一种单隐层神经网络,它适用于无微分激活函数,并在很大程度上避免了训练会遇到的某些问题,如停止准则、学习率、训练时间和局部最小^[31]。极限学习机通过固定输入层和隐含层的网络权重,将学习过程转化为矩阵计算,相比传统神经网络中的反向传播算法其学习速度更快^[32]。由于这种方法的计算效率较高,目前已经较好地应用于微波器件的设计^[33-34]。内核极限学习机是极限学习机的扩展版本^[35],与极限学习机相比引入了内核函数,且隐含层的节点个数是没有限制的,通过引入的核函数可以获得较好的泛化性能,并且降低计算成本。动态调整内核极限学习机^[36]中包含增加学习、简化学习和混合学习,当训练数据的样本数过少导致神经网络无法获得准确结果时,使用增加学习来解决欠拟合问题,当样本数过多而无法获得准确的结果时,使用简化学习来解决过拟合问题,当训练数据需要替换和扩展,则使用增加学习和简化学习相结合的混合学习,直接获得最终结果。

2.3 基于知识神经网络的设计方法

基于知识的神经网络^[37]是一种将经验信息融入神经网络内部结构,将先验知识与神经网络的学习能力相结合的建模方法。在微波器件设计应用中,先验微波知识被嵌入到神经网络内部,微波知识通过提供额外的信息,如解析表达式^[38],经验模型^[39],或等效电路^[40],补充了神经网络的学习和泛化能力。相比现有神经网络模型学习输入-输出关系的复杂性,基于知识神经网络的差分法和先验知识输入法具有更高的准确度^[41]。先验知识输入法神经网络将等效电路的 S 参数作为先验知识与神经网络相结合进行训练,可以获得更高的训练精度^[42]。当训练数据的样本数量有限时,在神经网络中增加经验知识可以补充其学习能力和泛化能力,减少收集大量训练数据的时间成本,加快建模速度^[37,43]。针对先验知识获取困难的问题,采用将神经网络与仿真软件相结合的方法,将ADS和电磁仿真软件HFSS的仿真结果作为神经网络的先验知识和指导信息,可以有效降低神经网络结构的复杂度^[44]。

2.4 神经网络和传递函数结合的设计方法

神经网络和传递函数的结合是电磁响应参数化建模的一种先进方法。在没有精确的等效电路或经验模型的情况下,用传递函数表示微波器件电磁响应随频率的变化。这种神经网络和传递函数相结合的方式也可以很好地用于电磁响应的参数化建模^[45]。

这种建模方法利用向量拟合技术获得电磁响应对应的传递函数系数作为神经网络的训练数据^[46]。神经网络的输入是器件结构的几何变量,输出是微波器件电磁仿真的 S 参数,经过训练,神经网络可以学习到传递函数系数与几何参数之间的非线性未知关系^[47]。

3 基于神经网络的带通滤波器设计

3.1 基于训练和精调的LC电路参数提取方法

上述大多基于神经网络的微波器件设计方法只对网络进行了训练过程,但是往往不能在短时间内达到较高的精度。基于深度信念网络^[48-49]的思想,对神经网络采用先预训练后微调的学习算法,提出一种基于神经网络的双通带带通滤波器(DB-BPF, dual-band bandpass filter)的LC电路参数提取方法^[50-51]。

如图 2 所示,该参数提取方法由 2 个阶段组成.第一个阶段是用数据集对网络进行预训练,经过预训练的神经网络可以获得接近最优值的 LC 电路参数的初始值;第 2 个阶段是根据期望的频率响应对网络进行微调,微调的过程是对预先训练好的网络进行优化,以提高提取参数的精度,从而获得 LC 电路参数的最优值.训练数据除了 S 参数的幅度信息,还加上了相位信息,以提高网络提取参数的能力.

预训练的神经网络结构如图 3 所示,由于 LC 电路参数与滤波器频率响应之间是一种复杂的非线性关系,因此选择非线性表达能力较好的全连接层网络结构.前 2 层由全连接层、块归一化^[52]和 ReLU 激活函数组成,第 3 层是输出层,没有激活函数.块归一化是一种归一化网络层,可以加快训练速度,提高网络的泛化能力.ReLU 激活函数可以使网络收敛更快.

神经网络预训练的数据集包括输入数据和标签.标签是 LC 电路中的电感值和电容值,定义为 $\mathbf{P} = p_1, p_2, \dots, p_N$,其中 N 表示 LC 电路参数的总个数.输入数据是根据 $\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}$ 矩阵计算得到的频率响应.根据不同的电感和电容值,获得不同的 S 参数,收集 10 万组数据作为预训练的数据集.

如图 2 参数提取的第一阶段用 N 个网络分别预测 N 个 LC 电路参数,其中每个网络的结构如图 3 所示.使用 Adam 优化算法^[53]更新各个网络的权值.训练过程中的损失函数为 $L_{\text{Train}} = \text{MSE}(P_{\text{output}}, P_{\text{label}})$. N 个神经网络经过预训练后,以目标 S 参数为输入,分别输出 N 个准确度不高的 LC 电路参数值.

使用第一阶段预训练的 N 个神经网络作为第 2 阶段的初始网络.参数提取的第 2 阶段是对神经网络进行微调,如图 2 所示,每个网络以目标 S 参数为输入,输出 N 个 LC 电路参数的预测值.然后通过求解 LC 电路的 $\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}$ 矩阵方程,根据 LC 电路参数的预测值计算对应的 S 参数.每个网络的权值由损失函数 $L_{\text{Fine-tuning}} = \text{MSE}(S_{\text{calculated}}, S_{\text{desired}})$ 来更新,重复上述迭代步骤,直到计算 S 参数与目标 S 参数基本一致.迭代停止准则是 $L_{\text{Fine-tuning}} < 0.000 1$.经过微调后, N 个网络可以分别输出 N 个最优 LC 电路参数值,最优 LC 电路参数值对应的频率响应与目标频率响应基本相同,满足设计要求.

为了进一步验证该方法的有效性,设计 2 个不同中心频率的 7 阶窄带 DB-BPF.对广义切比雪夫插入损耗响应进行修正, $F_N = \cosh\{N_1 \cosh^{-1}[\omega(\frac{\omega_1^2 - 1}{\omega_1^2 - \omega^2})^{\frac{1}{2}}] + N_2 \cosh^{-1}[\omega(\frac{\omega_2^2 - 1}{\omega_2^2 - \omega^2})^{\frac{1}{2}}] + N_3 \cosh^{-1}\omega\}$,传输零点在 $\pm \omega_1$ 时为 N_1 阶,在 $\pm \omega_{12}$ 时为 N_2 阶,在无穷远处为 N_3 阶.

设计指标: $N_{\text{order}} = 7.0, N_1 = 2.0, N_2 = 4.0, N_3 = 1.7$ 阶低通原型及其响应如图 4(a)和图 4(b)所示.已知电路参数 $L_{lp1} = 0.770 \text{ nH}, L_{lp2} = 0.380 \text{ nH}, L_{lp3} = 1.073 \text{ nH}, L_{lp4} = 2.160 \text{ nH}, C_{lp1} = 1.110 \text{ pF}, C_{lp2} = 0.446 \text{ pF}$.根据低通到双通带的频率转换方法得到如图 4(c)所示的 7 阶双通带电路.电路参数可以根据设计要求计算得出.该电路给出了在微调阶段作为网络输入目标 S 参数(包括 S_{11}, S_{21} 的幅值和 S_{11} 的相位).将图 4(c)中的并联模块转化为 4 个并联串联谐振模块^[54],得到如图 4(d)所示的转换双频 LC 电路.对于该电路来说,需要提取的 LC 电路参数个数 $N = 16$,其中包括 8 个电容值和 8 个电感值,定义为 $C_1, C_2, \dots, C_8, L_1, L_2, \dots, L_8$.根据这些参数使用 $\mathbf{A}, \mathbf{B}, \mathbf{C}, \mathbf{D}$ 矩阵计算 S 参数,作为神经网络预训练的标签.神经网络预训练的数据集是在 L 和 C 的取值范围内均匀采样得到的,其中电容值范围是 $0.01 \sim 30.00 \text{ pF}$,电感值范围 $0.1 \sim 500.0 \text{ nH}$.

第 1 个 7 阶窄带 DB-BPF, 2 个通带的中心频率分别为 1.0 GHz 和 2.5 GHz , 2 个通带的分数带宽分别为 8.60% 和 8.56% .带内回波损耗 20 dB , 4 个传输零点分别位于 $0.928 \text{ GHz}, 1.060 \text{ GHz}, 2.348 \text{ GHz}$ 和

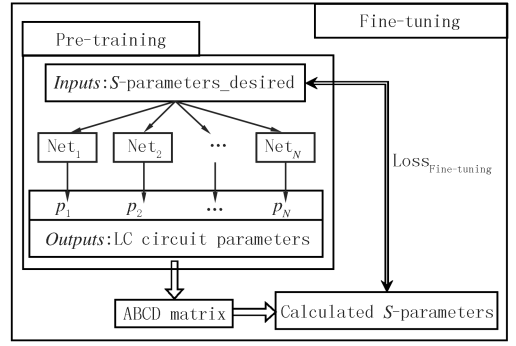


图2 优化方法流程图

Fig. 2 Optimization method flow chart

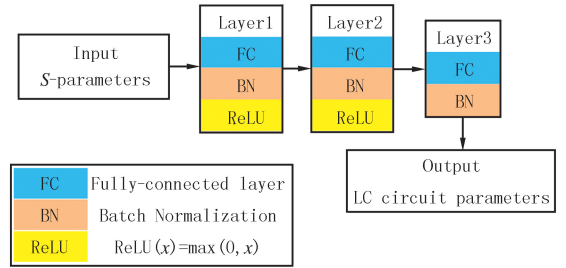




图3 预训练的神经网络结构

Fig. 3 Pretrained neural network model


2.679 GHz.图 4(c)所示的电路参数计算得: $L_{s2}=20.424\ 9\ \text{nH}$, $C_{s2}=0.496\ 1\ \text{pF}$, $L_{p2}=18.382\ 4\ \text{nH}$, $C_{p2}=0.551\ 2\ \text{pF}$, $L_{s5}=28.462\ 2\ \text{nH}$, $C_{s5}=0.356\ 0\ \text{pF}$, $L_{p5}=25.616\ 0\ \text{nH}$, $C_{p5}=0.395\ 5\ \text{pF}$,在 $0\sim 3\ \text{GHz}$ 频带范围内以 $0.001\ \text{GHz}$ 的间隔计算 S 参数;第 2 个 7 阶窄带 DB-BPF,2 个通带的中心频率分别为 $1\ \text{GHz}$ 和 $3\ \text{GHz}$,2 个通带的分数带宽分别为 10.04% 和 10.07% .带内回波损耗 $20\ \text{dB}$,4 个传输零点分别位于 $0.915\ \text{GHz}$, $1.073\ \text{GHz}$, $2.790\ \text{GHz}$ 和 $3.247\ \text{GHz}$.电路参数: $L_{s2}=15.318\ 7\ \text{nH}$, $C_{s2}=0.551\ 2\ \text{pF}$, $L_{p2}=20.424\ 9\ \text{nH}$, $C_{p2}=0.413\ 4\ \text{pF}$, $L_{s5}=21.346\ 6\ \text{nH}$, $C_{s5}=0.395\ 5\ \text{pF}$, $L_{p5}=28.462\ 2\ \text{nH}$, $C_{p5}=0.296\ 6\ \text{pF}$,在 $0\sim 3.5\ \text{GHz}$ 频带范围内以 $0.001\ \text{GHz}$ 的间隔计算 S 参数.




(a) 7阶低通原型



(b) 7阶低通原型的频率响应



(c) 7阶双通带电路



(d) 转换的双频LC电路

图4 7阶窄带DB-BPF的电路

Fig.4 The 7-order narrowband DB-BPF circuit

对于这 2 个 7 阶 DB-BPFs,通过上述的 LC 电路参数提取方法,经过 $>10\ \text{min}$ 的训练和 $<10\ \text{min}$ 的微调,提取出 LC 电路参数的最优值如表 1 所示,对是否使用相位信息的结果也进行对比.根据表 1 的 LC 参数计算得到的频率响应如图 5 所示.

实验结果表明,基于训练和精调的神经网络可以利用相位信息在短时间内获得不同中心频率、不同带宽的 DB-BPF 的最优 LC 电路参数.由最优 LC 电路参数计算得到的频率响应与期望频率响应几乎一致.这种方法还可以扩展应用到其他类型的滤波器的电路.

表 1 不同中心频率的 7 阶窄带 DB-BPFs 的 LC 电路参数

Tab. 1 LC circuit parameters for 7-order narrowband DB-BPFs with different center frequencies

中心频率/GHz	i	(使用/不使用相位信息提取的电容 C_i)/pF	(使用/不使用相位信息提取的电感 F_i)/nH	中心频率/GHz	i	(使用/不使用相位信息提取的电容 C_i)/pF	(使用/不使用相位信息提取的电感 F_i)/nH
1/2.5	1	0.430/0.600	67.75/48.75	1/3	1	0.510/0.470	58.40/63.50
	2	0.293/0.450	76.42/49.70		2	0.341/0.350	64.30/62.50
	3	0.132/0.090	34.73/51.10		3	0.135/0.130	24.10/25.10
	4	0.149/0.110	23.65/32.00		4	0.145/0.140	16.50/17.07
	5	0.069/0.049	399.05/568.05		5	0.087/0.101	323.40/279.70
	6	0.054/0.034	428.32/683.32		6	0.066/0.049	347.90/469.10
	7	0.025/0.032	179.85/138.10		7	0.025/0.031	124.10/100.30
	8	0.027/0.031	139.65/119.15		8	0.025/0.035	101.30/72.15

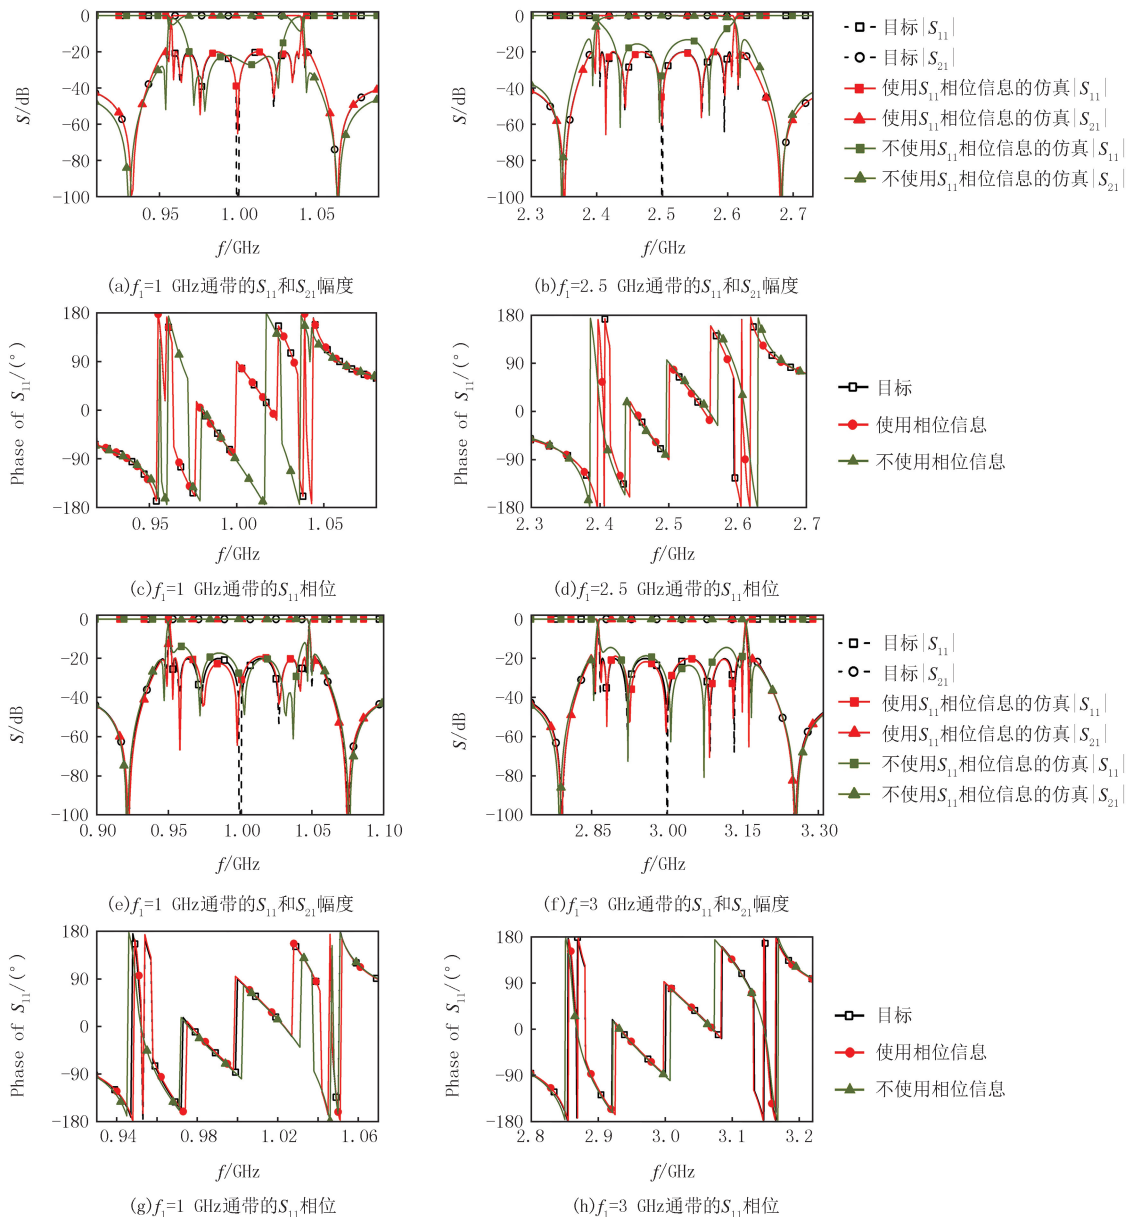


图5 7阶窄带DB-BPF根据表1中LC电路参数计算的频率响应与目标频率响应的比较曲线

Fig. 5 The comparison curves between the frequency response calculated by the LC circuit parameters in Tab.1 and the desired frequency response of the 7-order narrowband DB-BPFs

3.2 基于数据自生成的结构参数估计方法

对于前面综述的大多数方法,在滤波器设计中使用的基于训练的神经网络的方法,收集数据集都是一个烦琐的过程,需要耗费大量的时间和精力,尤其是在参数数量较大的情况下成本倍增。

针对上述难题,提出一种基于数据自生成的微带带通滤波器(BPF)的结构参数估计方法^[55]。设计一种神经网络 MS-Net,如图 6 所示,包括主网络 Main-Net 和子网络 Sub-Net,分别用于估计 BPF 的结构参数和频率响应。与其他基于神经网络的优化方法相比,MS-Net 可以在学习过程中生成自己的数据,而不需要收集数据集和对网络进行预训练。MS-Net 在每一次学习时,主网络输出的估计结构参数可以作为子网络的学习数据和标签。在迭代学习过程中,主网估计的结构参数将逐渐满足设计要求。

基于神经网络的微带带通滤波器的设计过程为:

1)目标 S 参数是神经网络的学习目标,根据需要的滤波器的理想耦合矩阵或理想滤波特性函数计算获得;

2)主网络以目标 S 参数作为输入,输出滤波器的估计结构参数,并将其送入电磁仿真得到仿真的 S 参数。之后,子网络将主网络的输出和相应的仿真 S 参数作为自己的学习数据和标签,对电磁仿真过程进行建模。MS-Net 的整个学习过程也是数据自生成的过程,不需要在开始学习之前进行额外的数据收集过程;

3)当仿真 S 参数,即对主网络输出的预测结构参数进行电磁仿真得到的频率响应,满足滤波器的设计要求时,学习停止;

4)学习完成之后,根据主网络输出的预测滤波器结构参数,对滤波器结构进行建模,设计完成。

在学习过程中,主网络的损失函数 L_{M-Net} 是目标 S 参数和预测 S 参数的均方误差,子网络的损失函数 L_{S-Net} 是仿真 S 参数和预测 S 参数的 MSE。 $L_{M-Net} = \text{MSE}(S_{\text{predicted}}, S_{\text{desired}})$, $L_{S-Net} = \text{MSE}(S_{\text{predicted}}, S_{\text{simulated}})$ 。MS-Net 利用 Adam 算法^[53] 根据计算的误差更新权重。当子网络的训练误差逐渐降低,其模拟电磁仿真过程的能力越强;当通过主网络估计的结构参数进行电磁仿真得到的仿真 S 参数越来越逼近于目标 S 参数时,主网估计的结构参数将逐渐满足设计规范。

基于上述结构参数估计方法分别设计 1 个 3 阶窄带 BPF 和 1 个 5 阶宽带 BPF。主网络的输入 $x_{\text{main}} = (S_{11,\text{desired}}, S_{21,\text{desired}})$, 输出是 $y_{\text{main}} = (y_1, y_2, \dots, y_L)$, 其中 L 表示待估计的结构参数个数。子网络的输入是主网络的输出 $x_{\text{sub}} = y_{\text{main}}$, 输出是 $y_{\text{sub}} = (S_{11,\text{predicted}}, S_{21,\text{predicted}})$ 。

第一个例子是并联耦合结构的微带 BPF,如图 7 所示。需要估计的结构参数的数量 $L=4$,各参数的取值范围如表 2 所示。滤波器的设计要求^[56] 是中心频率 3 GHz,分数带宽 FBW 为 5%,带内回波损耗 RL 为 16 dB,传输零点 3.3 GHz。使用 2 个 5 层神经网络作为 MS-Net 的主网络和子网络,每层的神经元个数如表 3 所示。目标 S 参数根据理想耦合矩阵计算得到。学习过程在 1 h 内,得到一组满足设计要求的结构参数

(表 1)。其电磁仿真频率响应如图 8 所示,带内回波损耗可以优于 -20 dB,虚线表示目标频率响应。与文献^[14]相比,该方法无需收集数据集来训练神经网络,在节省大量时间成本的同时很快实现了滤波器模型的设计。

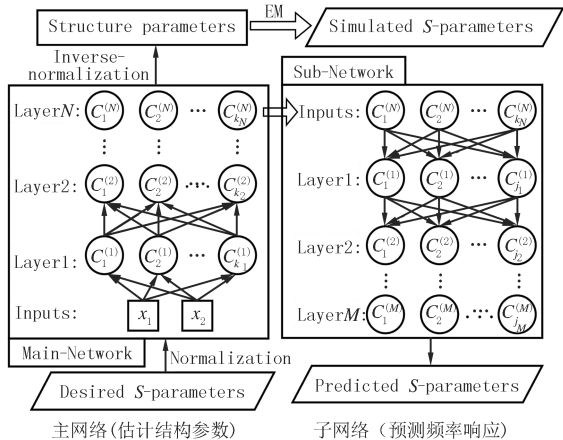


图6 MS-Net结构
Fig. 6 MS-Net Structure




图7 3阶微带BPF模型
Fig. 7 Layout of the 3-order microstrip BPF

表 2 3 阶带通滤波器的结构参数范围

Tab. 2 Range of structure parameters of the 3-order BPF

结构参数	y_1	y_2	y_3	y_4	结构参数	y_1	y_2	y_3	y_4
取值范围/mm	32.5~35.5	32.5~35.5	0.5~3.5	11.0~15.0	取值/mm	33.6	33.1	2.5	12.4

表 3 用于 3 阶带通滤波器的 MS-Net 中每层神经元数

Tab. 3 Number of neurons per layer in MS-Net used for 3-order BPF

$K^{(n)}$	主网络输入	$K^{(1)}$	$K^{(2)}$	$K^{(3)}$	$K^{(4)}$	$K^{(5)}$	$J^{(m)}$	子网络输入	$J^{(1)}$	$J^{(2)}$	$J^{(3)}$	$J^{(4)}$	$J^{(5)}$
神经元个数	2	4	8	16	8	4	神经元个数	4	8	16	8	4	2

第 2 个例子是宽带 BPF,如图 9 所示,需要估计的结构参数的数量 $L=9$,各参数的取值范围如表 5 所示.设计的滤波器中心频率 2 GHz,分数带宽 40%,带内损耗 15 dB,2 个传输零点分别位于 1.53 GHz 和 2.55 GHz.

使用 2 个 6 层全连接网络作为 MS-Net 的主网络和子网络,每层的神经元数量如表 6 所示.目标 S 参数是根据理想滤波特性函数计算得到的.因为这个例子中需要估计的结构参数的数量相比 3 阶 BPF 更多,所以使用更多的网络层数和更多的神经元.在 3.5 h 内得到一组满足设计要求的结构参数(见表 4).为了实现该设计,使用介电常数 2.65,厚度为 0.1 mm 的基板(图 10).根据实验结果表明,采用该方法估计的结构参数设计的滤波器可以很好地达到预期的效果.




图 8 3 阶微带 BPF 目标频率响应(虚线)与根据图中所示的结构参数仿真的频率响应(实线)的对比曲线图

Fig. 8 The comparison curves between the desired(dash lines) and estimated (solid lines) frequency responses of the 3-order microstrip BPF designed with the structure parameters in figure




图 9 5 阶微带带通滤波器模型

Fig. 9 Layout of the 5-order microstrip BPF

表 4 5 阶带通滤波器的结构参数范围

Tab. 4 Range of structure parameters of the 5-order BPF

结构参数	y_1	y_2	y_3	y_4	y_5	y_6	y_7	y_8	y_9
取值范围/mm	2~4	10~13	1.6~2.4	6.5~10.0	25~29	3~7	2~5	4~8	4~8
取值/mm	4.0	9.9	2.2	7.4	28.0	2.8	4.8	6.6	4.0

表 5 用于 5 阶带通滤波器的 MS-Net 中每层神经元数

Tab. 5 Number of neurons per layer in MS-Net for 5-order BPF

主网络输入	$K^{(1)}$	$K^{(2)}$	$K^{(3)}$	$K^{(4)}$	$K^{(5)}$	$K^{(6)}$	子网络输入	$J^{(1)}$	$J^{(2)}$	$J^{(3)}$	$J^{(4)}$	$J^{(5)}$	$J^{(6)}$
2	4	8	16	32	16	9	9	16	32	16	8	4	2

这 2 个实验表明,提出的基于数据自生成的结构参数估计方法可以有效地根据滤波器的目标 S 参数估计结构参数.最先进的优化方法与本工作的比较见表 7.除了使用理想的 S 参数作为神经网络的输入外,阈值

和置信区间也可以作为神经网络的输入.该子网络能够在每个学习步骤中使用主网络的生成数据,不需要额外的收集数据集,可以省去网络预训练的工作,减少时间成本.

表 6 不同优化方法的比较

Tab. 6 Comparison of the different optimization methods

方法	滤波器的阶数	需要优化参数的个数	迭代次数	总时间/h	方法	滤波器的阶数	需要优化参数的个数	迭代次数	总时间/h
文献[57]电磁优化方法	4	5	6+150	0.5	文献[56]训练+测试	3	4	—	—
	5	7	9+441	2.7					
文献[58]训练+测试	4	3	—	5.46	基于数据自生成	3	4	15	0.8
	4	3	—	17.20	的直接学习方法	5	9	26	3.2

3.3 基于神经网络的带宽可重构滤波器设计方法

可重构滤波器是无线通信系统的重要组成部分.可以实现可重构功能的方法包括半导体变容管、射频微机电系统等^[59-60].此外,一种基于集总元件的可调滤波器^[61],由串联 LC 和阻抗逆变器组成.使用分支线型谐振器的 3 比特可重构带通滤波器^[62],可以实现低插入损耗.为满足不同系统的需要,提出一种可调通带边缘和带宽的可重构带通滤波器,可以使 2 个通带独立可调^[63].通过选择谐振腔上负载变容二极管的特定位置,设计一种具有恒定绝对带宽的高选择性可调谐平衡带通滤波器^[64].首次设计了一种中心频率、带宽和零点控制的 3 极可调组合带通滤波器^[65].

不同于上述的可重构滤波器设计方法,提出一种基于神经网络的带宽可重构滤波器设计方法^[66].采用集总元件电路设计可重构 BPF,电路由 5 个串联 LC 电路组成.3 个串联支路可以提供 3 个传输极点,而 2 个并联支路可以引入 2 个相同的传输零点.利用神经网络优化 LC 电路的电感和电容值来达到中心频率可调、绝对带宽恒定的设计要求.单次参数优化可在 30 次迭代内完成.

具体包括 2 个步骤.第一步是在确定的设计要求下优化 LC 电路参数(电容值和电感值).第 2 步是保持 LC 电路中的电感值不变,与第一步优化方法相同,但是只优化电容值,以达到恒定带宽改变中心频率的效果.这 2 个设计步骤中都采用 3 层全连接网络作为 LC 电路参数的优化工具.如图 11 所示的算法流程图,网络的输入是滤波器的设计要求,输出 6 个电路参数值.然后根据神经网络输出的 LC 电路参数值计算相应的 S 参数.以计算得到的 S 参数与设计要求的误差函数作为损失函数,更新网络权值.误差函数包含绝对带宽误差、回波损耗误差和中心频率误差, $L = E(ABW, ABW') + E(RL, RL') + E(CF, CF')$, 其中 ABW' 、 RL' 和 CF' 分别表示满足设计要求的绝对带宽、回波损耗和中心频率,函数 E 是平均绝对误差.经过迭代学习之后,网络输出满足设计要求的电路参数值.




图 10 5阶微带BPF目标频率响应(虚线),根据照片的结构参数仿真的频率响应(实线)以及实测结果(点线)
Fig. 10 The comparison curves between the desired(dash lines), estimated(solid lines) and measured(dot lines) frequency responses of the 5-order microstrip BPF designed with the structure parameters in the photo

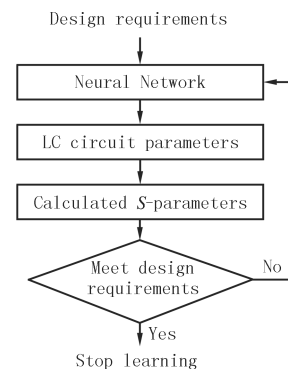


图 11 算法流程图
Fig. 11 The frame of algorithm

如图 12 所示, BPF 的 LC 电路基于广义切比雪夫 BPF^[67] 改进的对称结构, LC 电路参数包括 3 个电感值 L_1 、 L_2 、 L_3 和 3 个电容值 C_1 、 C_2 、 C_3 。这个电路是对称的, 3 个串联支路(L_1 和 C_1 , L_3 和 C_3 , L_1 和 C_1) 实现 3 个传输极点, 传输零点是由 L_2 和 C_2 在其共振频率处的并联的串联支路短路引起的。




图12 BPF的LC电路

Fig. 12 LC circuit structure of BPF

根据 \mathbf{A} 、 \mathbf{B} 、 \mathbf{C} 、 \mathbf{D} 矩阵与 S 参数之间的关系, 由这 6 个 LC 电路参数可以计算出各频率点上 BPF 的 S 参数, 计算过程为: $\mathbf{A}_1 = \begin{bmatrix} 1 & i\omega L_1 + \frac{1}{i\omega C_1} \\ 0 & 1 \end{bmatrix}$, $\mathbf{A}_2 = \begin{bmatrix} 1 & 0 \\ \frac{i\omega C_2}{1 - \omega^2 L_2 C_2} & 1 \end{bmatrix}$, $\mathbf{A}_3 = \begin{bmatrix} 1 & i\omega L_3 + \frac{1}{i\omega C_3} \\ 0 & 1 \end{bmatrix}$, $\omega = 2\pi f$. $\mathbf{A} = \mathbf{A}_1 \mathbf{A}_2 \mathbf{A}_3 \mathbf{A}_2 \mathbf{A}_1$, $S_{11} = \frac{A(1,1) + (A(1,2)/50) - A(2,1) \times 50 - A(2,2)}{A(1,1) + (A(1,2)/50) + A(2,1) \times 50 + A(2,2)}$, $S_{21} = 2 / (A(1,1) + (A(1,2)/50) + A(2,1) \times 50 + A(2,2))$.

为了验证该方法, 设计一种适用于高速数据通信的可重构带通滤波器。设计要求: 绝对带宽 300 MHz, 回波损耗 20 dB, 中心频率 5.45 GHz。优化出一组满足要求的参数值: $C_1 = 0.0335$ pF, $C_2 = 0.0629$ pF, $C_3 = 0.0336$ pF, $L_1 = 24.85$ nH, $L_2 = 15.27$ nH, $L_3 = 23.65$ nH。对应的频率响应如图 13 所示, 满足设计要求。

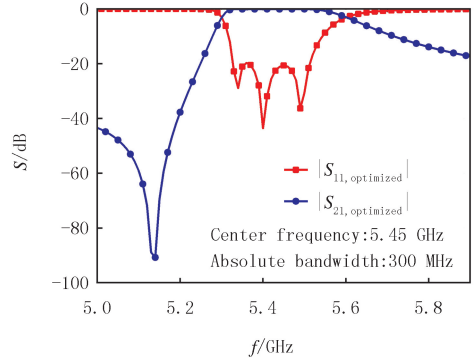


图13 中心频率5.45 GHz、绝对带宽为300 MHz的带通滤波器的传输系数和反射系数

Fig. 13 The transmission and reflection coefficients of the BPF with the center frequency of 5.45 GHz and the absolute bandwidth of 300 MHz

在可重构滤波器设计中, 由于电感值不能调节, 因此仍然使用第一步得到的 3 个电感值保持不变, 只优化 3 个电容值。对绝对带宽和回波损耗的要求与前面相同。中心频率要求为 4.85~6.05 GHz 之间的一个频率点, 间隔 0.3 GHz。在绝对带宽为 300 MHz 时, 不同中心频率下的频率响应如图 14 所示。优化得到的满足设计要求的 3 组电容值、绝对带宽和分数带宽的范围分别列在表 8 中。每组电容值在 30 次迭代内得到。

以上实验结果表明, 绝对带宽为 300 MHz 的可重构带通滤波器, 其中心频率可在 0.6~0.8 GHz(5.45~6.05 GHz) 之间调谐。这种基于神经网络的可重构滤波器设计方法能够在相同 ABW、不同中心频率的情况下, 有效、准确地优化满足设计要求的多个 BPF 的 LC 电路参数, 证明了该方法的有效性。这种方法将深度学习方法应用于可重构滤波器设计领域, 验证了深度学习方法可应用在不同的微波器件设计中, 加快设计速度和提高设计效率。

4 结论

本文描述了神经网络的基础模型结构和常用的训练方法, 从传统神经网络建模方法、基于极限学习机的设计方法、基于知识神经网络的设计方法、神经网络和传递函数相结合的设计方法这 4 个方面对基于神经网络的优化算法在微波器件领域中的应用进行综述和比较, 阐述了在微波器件设计中引入基于神经网络优化方法的优势。基于此, 提出 3 种基于神经网络的带通滤波器设计方法:

1) 基于训练和精调的神经网络方法, 在双通带滤波器的 LC 电路参数提取任务中, 利用滤波器 S 参数的

相位信息在短时间内获得不同阶数、不同中心频率、不同带宽的最优电路参数。

2) 基于数据自生成神经网络的带通滤波器结构参数估计方法,有效地根据滤波器的目标 S 参数估计出最佳的滤波器结构参数,无需网络的预训练过程,缩短了设计时间。

3) 带宽可重构的带通滤波器设计方法,可以在较短时间内准确的设计出相同绝对带宽、不同中心频率的带通滤波器。

这些方法验证了基于神经网络的优化方法可以应用于不同的微波器件设计任务,不仅可以获得较高的设计精度,还能降低数学复杂度、加速设计速度,有效降低设计成本。

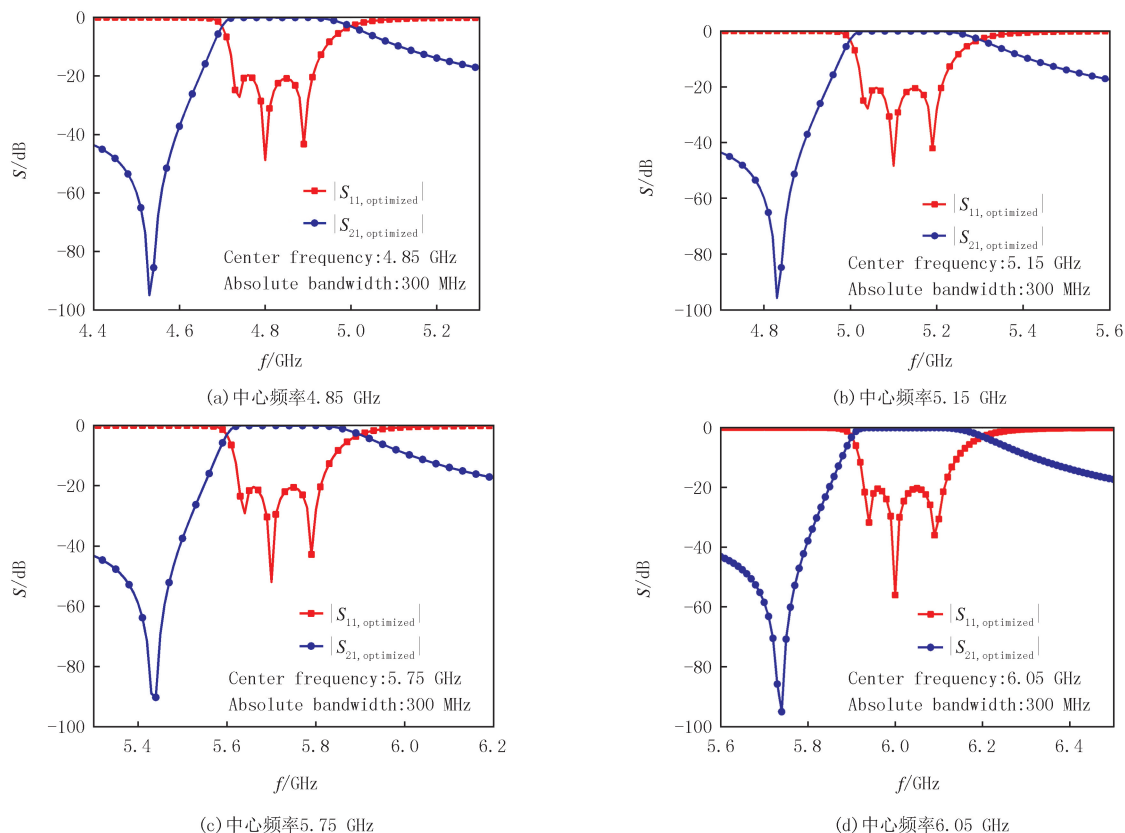


图14 绝对带宽300 MHz,不同中心频率的BPF的传输系数和反射系数

Fig. 14 The transmission and reflection coefficients of the BPFs with different center frequencies and the same absolute bandwidth of 300 MHz

表 7 不同中心频率、ABW 和 FBW 范围下的电容

Tab. 7 Capacitance values at different center frequencies range of ABW and FBW

C_1 /pF	C_2 /pF	C_3 /pF	中心频率/GHz	ABW/GHz	FBW/%
0.033 5	0.062 9	0.033 6	5.45	5.3~5.6	5.50
0.042 2	0.080 7	0.042 1	4.85	4.7~5.0	6.19
0.037 5	0.071 0	0.037 5	5.15	5.0~5.3	5.83
0.030 2	0.056 2	0.030 3	5.75	5.6~5.9	5.22
0.027 2	0.050 4	0.027 5	6.05	5.9~6.2	4.96

注: ABW-Absolute bandwidth, FBW-3 dB Fractional bandwidth.

参 考 文 献

[1] YILDIZÖ F, THOMSEN O, BOCHARD M, et al. Vertically integrated microwave-filters using functional via structures in LTCC[C]//2020 50th European Microwave Conference. Utrecht: IEEE, 2021: 966-969.

[2] FU W, LI Z M, CHCNG J W, et al. A review of microwave filter designs based on CMRC[C]//2020 IEEE MTT-S International Wireless

- Symposium, Shanghai: IEEE, 2021: 1-3.
- [3] LIU S, ZHANG G C, WAN T, et al. Numerical simulation of electromagnetic-thermal effect of microwave devices[C]//2019 International Applied Computational Electromagnetics Society Symposium-China. Nanjing: IEEE, 2020: 1-2.
- [4] FLYNN D, MARPE D, NACCARI M, et al. Overview of the range extensions for the HEVC standard: tools, profiles, and performance[J]. IEEE Transactions on Circuits and Systems for Video Technology, 2015, 26(1): 4-19.
- [5] PLONIS D, KATKEVIČIUS A, KRUKONIS A, et al. Predicting the frequency characteristics of hybrid meander systems using a feed-forward backpropagation network[J]. Electronics, 2019, 8(1): 85.
- [6] MARINKOVIC Z, KIM T, MARKOVIĆ V, et al. Artificial Neural Network based Design of RF MEMS Capacitive Shunt Switches[J]. Applied Computational Electromagnetics Society Journal, 2016, 31: 756-764.
- [7] CHEN Y F, WANG S, GE Y P. A survey on the applications of image classification based on convolution neural network[C]//2022 IEEE Asia-Pacific Conference on Image Processing, Electronics and Computers. Dalian: IEEE, 2022: 381-384.
- [8] LI H, CHEN K A, WANG L, et al. Sound source separation mechanisms of different deep networks explained from the perspective of auditory perception[J]. Applied Sciences, 2022, 12(2): 832.
- [9] KHANDELWAL R, MARFATIA P, SHAH S, et al. Financial data time series forecasting using neural networks and a comparative study [C]//2022 International Conference for Advancement in Technology (ICONAT). Goa: IEEE, 2022: 1-6.
- [10] 易鸿. 一种基于神经网络的微波智能天线系统设计[J]. 重庆文理学院学报(自然科学版), 2008(2): 32-35.
- YI H. One design of microwave intelligent antenna based on neural network[J]. Journal of Chongqing University of Arts and Sciences (Natural Science Edition), 2008(2): 32-35.
- [11] 黄文柔. 人工神经网络在微波领域的应用[J]. 中阿科技论坛, 2021(5): 112-114.
- HUANG W R. Application of artificial neural network in microwave field[J]. China-Arab States Science and Technology Forum, 2021(5): 112-114.
- [12] 戚军军, 吕红亮, 张玉明, 等. 基于人工神经网络的有源器件建模概述[J]. 微纳电子与智能制造, 2021, 3(2): 36-41.
- QI J J, LYU H L, ZHANG Y M, et al. Review of active device modeling based on Artificial Neural Network[J]. Micro/Nano Electronics and Intelligent Manufacturing, 2021, 3(2): 36-41.
- [13] 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.
- [14] TRAVASSOS X L, AVILA S L, IDA N. Artificial Neural Networks and Machine Learning techniques applied to Ground Penetrating Radar: a review[J]. Applied Computing and Informatics, 2021, 17(2): 296-308.
- [15] KABIR H, ZHANG L, YU M, et al. Smart modeling of microwave devices[J]. IEEE Microwave Magazine, 2010, 11(3): 105-118.
- [16] RUSEN V, KRUKONIS A, PLONIS D. Prediction of parameters of semiconductor band-pass filters using artificial neural network[C]//2020 IEEE 8th Workshop on Advances in Information, Electronic and Electrical Engineering (AIEEE). Vilnius: IEEE, 2021: 1-4.
- [17] ZHAO Z H, FENG F, ZHANG W, et al. Parametric modeling of EM behavior of microwave components using combined neural networks and hybrid-based transfer functions[J]. IEEE Access, 2020, 8: 93922-93938.
- [18] RUMELHART D E, HINTON G E, WILLIAMS R J. Learning Internal Representations by Error Propagation[J]. Readings in Cognitive Science, 1988, 323: 399-421.
- [19] BROYDEN C G. Quasi-Newton methods and their application to function minimisation[J]. Mathematics of Computation, 1967, 21(99): 368-381.
- [20] GOLDBERG D, HOLLAND J. Genetic Algorithms and Machine Learning[J]. Machine Learning, 1988, 3(2/3): 95-99.
- [21] KIRKPATRICK S, GELATT D, VECCHI M. Optimization by Simulated Annealing[J]. Science, 1983, 42(3): 671-680.
- [22] HORNG T S, WANG C C, ALEXOPOULOS N G. Microstrip circuit design using neural networks[C]//1993 IEEE MTT-S International Microwave Symposium Digest. Atlanta: IEEE, 2002: 413-416.
- [23] VAI M M, WU S C, LI B, et al. Reverse modeling of microwave circuits with bidirectional neural network models[J]. IEEE Transactions on Microwave Theory and Techniques, 1998, 46(10): 1492-1494.
- [24] BURRASCANO P, FIORI S, MONGIARDO M. A review of artificial neural networks applications in microwave computer-aided design [J]. International Journal of RF and Microwave Computer-Aided Engineering, 1999, 9(3): 158-174.
- [25] 周力, 毛钧杰, 姚德森. 基于神经网络的 S 参数估计法[J]. 电子与信息学报, 2001, 23(3): 304-307.
- ZHOU L, MAO J J, YAO D M. A method based on neural network to estimate scattering parameter[J]. Journal of Electronics and Information Technology, 2001, 23(3): 304-307.
- [26] STEER M B, BANDLER J W, SNOWDEN C M. Computer-aided design of RF and microwave circuits and systems[J]. IEEE Transactions on Microwave Theory and Techniques, 2002, 50(3): 996-1005.
- [27] ZHANG Q J, GUPTA K C, DEVABHAKTUNI V K. Artificial neural networks for RF and microwave design—from theory to practice[J]. IEEE Transactions on Microwave Theory and Techniques, 2003, 51(4): 1339-1350.
- [28] RIZZOLI V, COSTANZO A, MASOTTI D, et al. Computer-aided optimization of nonlinear microwave circuits with the aid of electromagnetic simulation[J]. IEEE Transactions on Microwave Theory and Techniques, 2004, 52(1): 362-377.

- [29] 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, San Diego: IEEE, 2017: 159-160.
- [30] 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.
- 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.
- [31] HUANG G B, ZHU Q Y, SIEW C K. Extreme learning machine: theory and applications[J]. Neurocomputing, 2006, 70(1/2/3): 489-501.
- [32] SHI X, WANG J, LIU G, et al. Application of extreme learning machine and neural networks in total organic carbon content prediction in organic shale with wire line logs[J]. Journal of Natural Gas Science and Engineering, 2016, 33: 687-702.
- [33] ZHANG C Y, ZHU Y Y, CHENG Q F, et al. Extreme learning machine for the behavioral modeling of RF power amplifiers[C]//2017 IEEE MTT-S International Microwave Symposium, Honolulu: IEEE, 2017: 558-561.
- [34] XIAO L Y, SHAO W, LIANG T L, et al. Efficient extreme learning machine with transfer functions for filter design[C]//2017 IEEE MTT-S International Microwave Symposium, Honolulu: IEEE, 2017: 555-557.
- [35] HUANG G B, WANG D H, LAN Y. Extreme learning machines: a survey[J]. International Journal of Machine Learning and Cybernetics, 2011, 2(2): 107-122.
- [36] XIAO L Y, SHAO W, DING X, et al. Dynamic adjustment kernel extreme learning machine for microwave component design[J]. IEEE Transactions on Microwave Theory and Techniques, 2018, 66(10): 4452-4461.
- [37] WANG F, ZHANG Q J. Knowledge-based neural models for microwave design[J]. IEEE Transactions on Microwave Theory and Techniques, 1997, 45(12): 2333-2343.
- [38] DEVABHAKTUNI V K, CHATTARAJ B, YAGOUB M C E, et al. Advanced microwave modeling framework exploiting automatic model generation, knowledge neural networks, and space mapping[J]. IEEE Transactions on Microwave Theory and Techniques, 2003, 51(7): 1822-1833.
- [39] DING X L, DEVABHAKTUNI V K, CHATTARAJ B, et al. Neural-network approaches to electromagnetic-based modeling of passive components and their applications to high-frequency and high-speed nonlinear circuit optimization[J]. IEEE Transactions on Microwave Theory and Techniques, 2004, 52(1): 436-449.
- [40] RAYAS-SANCHEZ J E, GUTIERREZ-AYALA V. EM-based Monte Carlo analysis and yield prediction of microwave circuits using linear-input neural-output space mapping[J]. IEEE Transactions on Microwave Theory and Techniques, 2006, 54(12): 4528-4537.
- [41] WATSON P M, GUPTA K C, MAHAJAN R L. Development of knowledge based artificial neural network models for microwave components[C]//1998 IEEE MTT-S International Microwave Symposium Digest, Baltimore: IEEE, 2002: 9-12.
- [42] MARINKOVIĆ Z, PRONIĆ-RANČIĆ O, MARKOVIĆ V. Bias-dependent hybrid PKI empirical-neural model of microwave FETs[J]. International Journal of Electronics, 2011, 98(10): 1399-1409.
- [43] NA W C, ZHANG Q J. Unified automated knowledge-based neural network modeling for microwave devices[C]//2015 IEEE MTT-S International Conference on Numerical Electromagnetic and Multiphysics Modeling and Optimization(NEMO), Ottawa: IEEE, 2016: 1-3.
- [44] 陈艺, 车久菊, 田雨波. 基于 ADS 的 KBNN 在带通滤波器优化设计中的应用[J]. 江苏科技大学学报(自然科学版), 2018, 32(1): 83-87.
- CHEN Y, CHE J J, TIAN Y B. ADS-based KBNN to optimize the band-pass filter[J]. Journal of Jiangsu University of Science and Technology(Natural Science Edition), 2018, 32(1): 83-87.
- [45] GUO Z Y, GAO J J, CAO Y Z, et al. Passivity enforcement for passive component modeling subject to variations of geometrical parameters using neural networks[C]//2012 IEEE/MTT-S International Microwave Symposium Digest, Montreal: IEEE, 2012: 1-3.
- [46] GUSTAVSEN B, SEMLYEN A. Rational approximation of frequency domain responses by vector fitting[J]. IEEE Transactions on Power Delivery, 1999, 14(3): 1052-1061.
- [47] FENG F, ZHANG C, MA J G, et al. Parametric Modeling of EM Behavior of Microwave Components Using Combined Neural Networks and Pole-Residue-Based Transfer Functions[J]. IEEE Transactions on Microwave Theory and Techniques, 2016, 64(1): 60-77.
- [48] HINTON G E, SALAKHUTDINOV R R. Reducing the dimensionality of data with neural networks[J]. Science, 2006, 313(5786): 504-507.
- [49] HINTON G E, OSINDERO S, TEH Y W. A fast learning algorithm for deep belief nets[J]. Neural Computation, 2006, 18(7): 1527-1554.
- [50] DU H, YANG Q, DAI X Y, et al. A parameter extraction method for LC circuit of DB-BPF based on fully connected network[J]. IEEE Transactions on Computer-Aided Design of Integrated Circuits and Systems, 2022, 41(10): 3558-3562.
- [51] 杜浩, 杨倩, 舒敏杰, 等. 一种基于神经网络的波导带通滤波器设计方法[C]//2020 年全国微波毫米波会议. 上海: [出版者不详], 2020: 455-457.
- [52] IOFFE S, SZEGEDY C. Batch normalization: Accelerating deep network training by reducing internal covariate shift[J]. International Conference on Machine Learning, ICML 2015, 2015, 1: 448-456.
- [53] KINGMA D, BA J. Adam: Adam, a method for stochastic optimization[C]//2015 International Conference on Learning Representations, San Diego: [s.n.], 2015: 1-4.
- [54] DAI X Y, YANG Q, DU H, et al. Direct synthesis method for dual-band bandpass filters with wide fractional bandwidth range and center frequency ratio[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2021, 68(8): 2755-2759.

- [55] DU H, YANG Q, DAI X Y, et al. A structure parameter estimation method for microstrip BPF based on multilayer FCN[J]. IEEE Microwave and Wireless Components Letters, 2020, 30(6): 581-584.
- [56] OHIRA M, YAMASHITA A, MA Z W, et al. A novel eigenmode-based neural network for fully automated microstrip bandpass filter design[C]//2017 IEEE MTT-S International Microwave Symposium. Honolulu; IEEE, 2017: 1628-1631.
- [57] FENG F, ZHANG C, NA W C, et al. Adaptive feature zero assisted surrogate-based EM optimization for microwave filter design[J]. IEEE Microwave and Wireless Components Letters, 2019, 29(1): 2-4.
- [58] SADROSSADAT S A, CAO Y Z, ZHANG Q J. Parametric modeling of microwave passive components using sensitivity-analysis-based adjoint neural-network technique[J]. IEEE Transactions on Microwave Theory and Techniques, 2013, 61(5): 1733-1747.
- [59] YAMAO Y, OHTSUKA J I, MORI H, et al. Multi-bit reconfigurable resonator using tapped transmission line and RF switches[C]//2009 European Microwave Conference. Rome; IEEE, 2009: 1223-1226.
- [60] BHAT S, KULKARNI R G. Electronically tunable dual band microwave filter[C]//2019 IEEE 5th International Conference for Convergence in Technology. Bombay; IEEE, 2020: 1-4.
- [61] KHOLODNYAK D, TURGALIEV V, BASKAKOVA A. A method to design lumped-element tunable bandpass filters with constant absolute bandwidth[C]//2014 44th European Microwave Conference. Rome; IEEE, 2014: 335-338.
- [62] KOBAYASHI R, KATO T, YAMAO Y. A compact three-bit reconfigurable resonator consisting of lumped elements[C]//2014 IEEE Radio and Wireless Symposium. Newport Beach; IEEE, 2014: 169-171.
- [63] SHANG Y X, FENG W J, CHE W Q. Wideband reconfigurable bandpass filter using coupled lines loaded with varactor loaded stubs[J]. International Journal of RF and Microwave Computer-Aided Engineering, 2018, 28(2): e21195.
- [64] ZHOU W J, CHEN J X. High-selectivity tunable balanced bandpass filter with constant absolute bandwidth[J]. IEEE Transactions on Circuits and Systems II: Express Briefs, 2017, 64(8): 917-921.
- [65] CHIOU Y C, REBEIZ G M. A tunable three-pole 1.5-2.2 GHz bandpass filter with bandwidth and transmission zero control[J]. IEEE Transactions on Microwave Theory and Techniques, 2011, 59(11): 2872-2878.
- [66] YANG Q A, DU H, DAI X Y, et al. Reconfigurable bandpass filter with constant absolute bandwidth based on neural network[J]. International Journal of RF and Microwave Computer-Aided Engineering, 2022, 32(1): e22932.
- [67] BUDIMIR D, LALAHPARVAR L, NIKOLIC N. Design of generalized Chebyshev lumped element filters by computer optimisation[C]//11th IEEE Mediterranean Electrotechnical Conference. Cairo; IEEE, 2002: 475-478.

Review of microwave device design based on neural network

Zhang Anxue, Du Hao, Dai Xinyue, Yang Qian, Guo Cheng, Liao Xuewen

(Department of Electronic and Information Engineering, Xi'an Jiaotong University, Xi'an 710049, China)

Abstract: With the increase of the structure complexity and the performance requirements of the microwave devices, the time cost of the modeling and the design process increases gradually. The design efficiency of microwave devices can be improved by introducing optimization algorithm in the design process. In this paper, the methods of the neural network in the field of microwave filter design are systematically reviewed, and the LC circuit parameter extraction method based on training and fine-tuning neural network is proposed. A method for estimating the structural parameters of the bandpass filters and designing the bandpass filters with bandwidth reconfigurable is proposed based on the self-generated neural networks. The experimental results show that the neural network can use the S parameter information of the filter to predict the LC circuit parameters/structure parameters that meet the design requirements in a relatively short time, reduce the design cost effectively and improve the design efficiency.

Keywords: neural network; fine-tuning; structural parameter estimation; bandpass filter; reconfigurable

[责任编辑 杨浦 刘洋]

本期专家介绍



张明高院士,1999年当选为中国工程院院士。部级有突出贡献专家,享受国务院政府特殊津贴。先后主持完成了十几项重大科研项目和国防重点工程。其中对信息与电子工程系统中关键的电波技术有独到深入的研究,取得了一系列具有国际先进水平的创造性成果,先后获国家级和部级科技进步奖5项,光华科技基金一等奖。特别是改进和发展了5项国际电联建议书中的关键技术模式,得到了世界各国电波传播领域权威专家的公认;在对流层散射通信、卫星通信、航天飞船通信、陆地移动通信、固定通信等诸多方面发挥了重大作用,从多方面推动了高新技术的发展,为我国

赢得了国际声誉。

张安学,西安交通大学教授,博士生导师,电磁与信息技术研究所所长,现为中国天线学会专业委员会委员,中国电磁环境效应产业技术创新战略联盟理事,超高速电路设计与电磁兼容教育部重点实验室学术委员会委员,陕西省天线与控制技术重点实验室学术委员会委员,多功能材料与结构教育部重点实验室和陕西省深空探测智能信号处理重点实验室学科带头人,科技部重点研发计划评审专家,探月工程有效载荷评审专家,中国电子学会优秀博士论文指导教师。主持国家自然科学基金2项、863项目1项、总装探索和预研项目8项、研究所及企业合作项目40余项;授权中国发明专利25件、美国发明专利1件,发表论文300余篇,其中SCI收录200余篇。获省部级科技进步二等奖2项,省高校科学技术研究优秀成果特等奖和一等奖各1项,多项研究成果得到推广应用。目前的研究方向涉及新型天线与微波器件设计、雷达信号处理、多天线通信系统与阵列信号处理、微波测试理论与系统设计等。



孙林,天津科技大学特聘教授、天科人才,博士后,博士生导师,获得“河南省科技创新杰出青年”(省杰青)、“河南省高层次人才”、“河南省教育厅学术技术带头人”、“河南省高等学校青年骨干教师”等称号。2003年和2007年毕业于河南师范大学,分别获计算机科学与技术专业学士和硕士学位。现为中国人工智能学会粒计算与知识发现专业委员会委员、知识工程与分布式智能专业委员会青年委员。主要研究方向为大数据挖掘技术与应用、粒计算理论与应用、机器学习、生物信息学。近5年以第一作者在国际国内顶级科技期刊 *Information Fusion*、*IEEE Transactions on Fuzzy Systems*、《软件学报》等期刊上发表高水平学术论文30余篇(SCI影响因子 ≥ 4),包括4篇ESI、16篇Top、7篇SCI一区 and 18篇SCI二区,以及1篇一级顶尖中文期刊;授权发明专利30余件;在科学出版社出版学术专著4部。主持国家自然科学基金项目(面上基金2项、青年基金1项)、中国博士后科学基金面上项目、河南省科技创新人才计划、河南省重点科技攻关计划等10余项。荣获河南省自然科学学术奖一等奖5项和二等奖3项、河南省高等教育省级教学成果一等奖3项。于2019—2023年连续荣获“河南师范大学优秀硕士学位论文指导教师”,并于2020年、2022年和2023年分别荣获“河南省优秀硕士学位论文指导教师”。



孙林,天津科技大学特聘教授、天科人才,博士后,博士生导师,获得“河南省科技创新杰出青年”(省杰青)、“河南省高层次人才”、“河南省教育厅学术技术带头人”、“河南省高等学校青年骨干教师”等称号。2003年和2007年毕业于河南师范大学,分别获计算机科学与技术专业学士和硕士学位。现为中国人工智能学会粒计算与知识发现专业委员会委员、知识工程与分布式智能专业委员会青年委员。主要研究方向为大数据挖掘技术与应用、粒计算理论与应用、机器学习、生物信息学。近5年以第一作者在国际国内顶级科技期刊 *Information Fusion*、*IEEE Transactions on Fuzzy Systems*、《软件学报》等期刊上发表高水平学术论文30余篇(SCI影响因子 ≥ 4),包括4篇ESI、16篇Top、7篇SCI一区 and 18篇SCI二区,以及1篇一级顶尖中文期刊;授权发明专利30余件;在科学出版社出版学术专著4部。主持国家自然科学基金项目(面上基金2项、青年基金1项)、中国博士后科学基金面上项目、河南省科技创新人才计划、河南省重点科技攻关计划等10余项。荣获河南省自然科学学术奖一等奖5项和二等奖3项、河南省高等教育省级教学成果一等奖3项。于2019—2023年连续荣获“河南师范大学优秀硕士学位论文指导教师”,并于2020年、2022年和2023年分别荣获“河南省优秀硕士学位论文指导教师”。