DOI:10.11721/cqnuj20250409

基于 ANN 技术的 GaAs pHEMT 小信号 S 参数温度特性建模研究*

杨姝玥[1], 林 倩[1,2]
(1. 青海民族大学 智能科学与工程学院, 西宁 810007; 2. 广安理工学院 电子信息工程学院, 四川 广安 638000)

摘要:为了解决传统器件建模过程复杂、精度低的问题,采用多种人工神经网络技术对砷化镓赝配高电子迁移率晶体管(gallium arsenide pseudomorphic high electron mobility transistor, GaAs pHEMT)在不同温度下的 S 参数开展建模研究。建模时将采集所得的 S 参数随机分为训练集和测试集,分别采用双隐藏层共轭梯度反向传播神经网络(conjugate gradient backpropagation neural network, CG-BPNN)和极限学习机(extreme learning machine, ELM)建模,并给出 2 种模型的预测拟合结果和绝对误差曲线。实验结果表明,CG-BPNN 的拟合结果一般,部分数据存在较大的误差,而 ELM 预测的大部分数据都能达到理想的拟合结果。此外,CG-BPNN 和 ELM 的均方误差分别为 0.013 508 和 0.002 254 9。上述实验证明了 ELM 在不同温度下对 GaAs pHEMT 的 S 参数具有更好的建模效果。因此,所提出的建模方法可以准确、稳定地表征 GaAs pHEMT 在不同温度下的 S 参数。

关键词:CG-BPNN;ELM;S 参数;GaAs pHEMT
中图分类号:TN61 **文献标志码**:A **文章编号**:1672-6693(2025)04-0100-11

1 研究背景

微波功率器件作为通信系统的关键组成部分,它的性能状况将直接影响整个系统的质量。同时,器件模型在通信系统的设计中必不可少,它的精度是提高通信系统性能的关键因素。因此,对微波功率器件进行准确建模至关重要[1]。目前,砷化镓赝配高电子迁移率晶体管(gallium arsenide pseudomorphic high electron mobility transistor, GaAs pHEMT)因具有良好的高频特性、低噪声特性和功率特性已经成为微波集成电路应用领域最具发展前景的器件之一[2]。因此,与之相关的模型精度一直是微波工程师研究的热点,许多 GaAs pHEMT 模型也相继被提出[3-4]。1982 年,Tsironis 等人[5]首次利用等效电路方法提出了双栅金属半导体场效应晶体管微波宽带模型。2020 年,Luo 等人[6]提出多栅 GaAs pHEMT 开关模式下的精确小信号模型,测量和模拟结果在很宽的频率范围内取得了良好的一致性。2022 年,Lü 等人[7]提出一种包含 8 个元件的紧凑型 GaAs pHEMTs 栅极宽度可扩展模型,仿真结果与 GaAs pHEMT 在 40 GHz 范围内的实测结果吻合较好。然而,上述方法对器件建模所用的特定等效电路拓扑具有很强的依赖性,虽然可以准确模拟 GaAs pHEMT 的小信号,但建模过程较为复杂,且计算速度明显变慢。因此,计算机辅助设计技术(technology computer-aided design, TCAD)仿真工具应运而生[8-9]。该技术可以用来建立晶体管的几何模型,然后通过电磁仿真来分析模型的 S 参数、增益等微波特性。但是随着半导体技术的发展,晶体管的几何模型变得越来越复杂,这也增加了 TCAD 的仿真时间和计算成本。

为了解决上述问题,机器学习(machine learning, ML)逐渐应用于模拟 TCAD[10-11]。人工神经网络(artificial neural network, ANN)作为 ML 中的一种技术,因具有较强的非线性映射能力而被广泛应用于射频微波建模领域[12-13]。2010 年,Dobes 等人[14]将解析模型与 ANN 相结合,提高了 GaA pHEMT 输出特性中漏极电压电流和栅极电压电流的建模精度。2014 年,Salnikov[15]采用 ANN 技术建立 GaAs pHEMT 不同直流工作下 S 参数的频率依赖性行为模型,精度和计算速度都比较理想。2016 年,Long 等人[16]采用多路径 ANN 技术对

* **收稿日期**:2024-11-11 **修回日期**:2024-12-17 **网络出版时间**:2025-05-22T11:00
资助项目:国家自然科学基金地区科学基金项目(No. 62161046)
第一作者简介:杨姝玥,女,研究方向为微波器件人工神经网络建模,E-mail:2401754223@qq.com;**通信作者简介**:林倩,女,教授,E-mail:linqian@tju.edu.cn
网络出版地址:https://link.cnki.net/urlid/50.1165.N.20250507.1635.023

GaAs pHEMT 的大信号建模，该模型可以精确描述色散效应。2022 年，Qi 等人[17]利用 RBF 神经网络准确建立了考虑温度因子的 GaAs pHEMT 的 S 参数模型。2023 年，Lin 等人[18]利用弹性 BPNN 准确表征了 GaAs pHEMT MMIC PA 的温度行为。由此可见，GaAs pHEMT 模型主要集中于对大信号特征的研究，不同温度下的小信号特性还有待进一步研究。因此，本文结合 CG-BPNN 和 ELM 技术建立高效、高精度的不同温度下 GaAs pHEMT 小信号 S 参数模型是可行的，这对射频电路在特殊环境下工作具有重要意义。

2　建模对象和方法介绍

2.1　建模对象

2.1.1　S 参数

S 参数作为描述射频与微波网络特性的重要参数之一，在评估器件或微波电路的散射特性和预测信号传输方面发挥着重要作用，可以用来表征微波器件的小信号特性。此外，S 参数模型可以作为一个元件的行为模型，能够有效地应用于电路设计中[19]。

如图 1 所示，端口 1 的入射波、反射波分别是 a_1、b_1，端口 2 的入射波、反射波分别是 a_2、b_2。若利用端口 1 和端口 2 的入射波来分别表示它们的反射波，可以得到：

$$\begin{bmatrix} b_1 \\ b_2 \end{bmatrix} = \begin{bmatrix} S_{11} & S_{12} \\ S_{21} & S_{22} \end{bmatrix} \begin{bmatrix} a_1 \\ a_2 \end{bmatrix}, \tag{1}$$

其中：参数 S_{11} 和 S_{22} 代表反射系数，S_{21} 和 S_{22} 代表传输系数，它们统称为双端口网络的 S 参数，表达式如下：

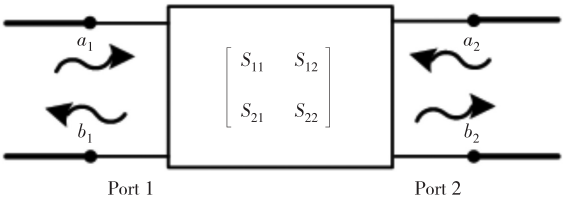

图 1　双端口网络的 S 参数模型

Fig. 1　S-parameters model of two-port network

$$S_{11} = \left.\frac{b_1}{a_1}\right|_{a_2=0}, \tag{2}$$

$$S_{22} = \left.\frac{b_2}{a_2}\right|_{a_1=0}, \tag{3}$$

$$S_{12} = \left.\frac{b_1}{a_2}\right|_{a_1=0}, \tag{4}$$

$$S_{21} = \left.\frac{b_2}{a_1}\right|_{a_2=0}。 \tag{5}$$

根据式(1)，S 参数可以表示为式(2)～(5)。其中，S_{11} 是端口 2 匹配时端口 1 的反射系数，S_{22} 是端口 1 匹配时端口 2 的反射系数，S_{12} 代表双端口网络的反向增益，S_{21} 代表双端口网络的前向增益。

2.1.2　S 参数与温度的关系

迁移率是描述载流子在电场作用下运动能力的一个参数，可以近似表示为：

$$\mu = \mu_0 \cdot \exp -\frac{T}{T_0}, \tag{6}$$

其中：μ_0 是参考温度 T_0 下的迁移率。根据式(6)可知，温度升高会导致迁移率降低。原因在于声子能量会随温度升高而增加，导致载流子与声子之间的散射作用增强，迁移率降低。此外，与 S_{11} 和 S_{22} 相关的反射系数 Γ 可表示为：

$$\Gamma = \frac{Z_L - Z_0}{Z_L + Z_0}, \tag{7}$$

其中：Z_L 是负载阻抗，Z_0 是特征阻抗。与 S_{12} 和 S_{21} 相关的传输系数 τ 可表示为：

$$\tau = \frac{2Z_0}{Z_L + Z_0}。 \tag{8}$$

结合式(6)～(8)可知，随着温度升高，迁移率降低，Z_L 增加，导致反射系数增大，而传输系数减小。这意味着晶体管的反射损耗增加，传输损耗增加。显然，温度对 GaAs pHEMT 的 S 参数有影响。

2.2 建模方法

2.2.1 CG-BPNN

BPNN技术于20世纪80年代提出[20],是目前理论最完善的神经网络技术。该技术最大特征是采用反向传播算法来计算误差,从而使每一层的神经元状态直接影响后一层的神经元状态。它应用较为广泛,能够解决风险预警[21]、故障检测[22]、图像分类[23]和语音识别[24]等非线性问题。后来使用共轭梯度算法训练BPNN可以得到共轭梯度反向传播神经网络(conjugate gradient backpropagation neural network,CG-BPNN)模型,基本结构如图2所示。

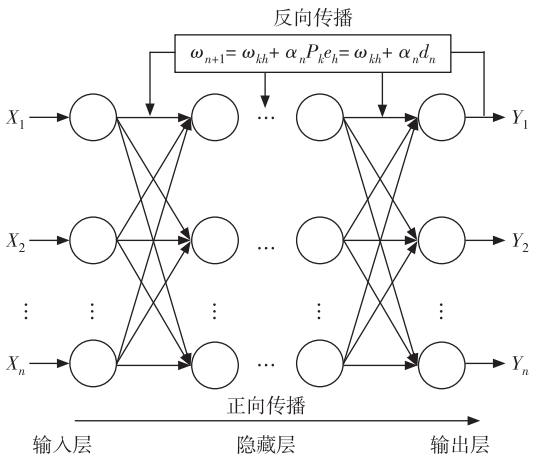

图2 CG-BPNN的基本结构

Fig. 2 Basic structure of CG-BPNN

CG-BPNN由输入层、隐藏层和输出层构成,并且各层神经元之间为全连接。输入层和输出层的神经元个数由输入数据 $\boldsymbol{X}=[X_1,X_2,\cdots,X_n]$ 和输出数据 $\boldsymbol{Y}=[Y_1,Y_2,\cdots,Y_m]$ 决定。隐藏层可以为1层或多层结构,具体层数根据解决问题的复杂程度进行设置。另外,考虑到单隐藏层CG-BPNN模型在S参数数量较多的情况下误差较大,因此本文选择了精确度更高的双隐藏层CG-BPNN模型,训练过程包括正向传递过程和反向传递过程。其中,正向传递过程是为了得到输出层的预测值,可得到输入层到第1层隐藏层的输出值:

$$H_j=F\left(\sum_{i=1}^{n}\omega_{ij}x_i+a_j\right),$$

其中:H_j 为第1层隐藏层第 j 个节点的输出,$j=1,2,\cdots,l$;F 为激励函数;ω_{ij} 为输入层和第1层隐藏层神经元间的连接权值;x_i 为输入变量;a_j 为第1层隐藏层第 j 个节点数的阈值;n 为输入层节点数。

再计算第1层隐藏层到第2层隐藏层的输出值:

$$P_k=F\left(\sum_{j=1}^{l}\omega_{jk}H_j+b_k\right),$$

其中:P_k 为第2层隐藏层第 k 个节点数的输出,$k=1,2,\cdots,q$;ω_{jk} 为第1层隐藏层与第2层隐藏层神经元间的连接权值;b_k 为第2层隐藏层第 k 个节点数的阈值。

若存在更多的隐藏层,可以使用相同的方法计算输出值。最后,得到输出层结果:

$$O_h=\sum_{k=1}^{q}P_k\omega_{kh}-c_h,$$

其中:O_h 为输出层结果;h 为输出层节点数,$h=1,2,\cdots,m$;ω_{kh} 为第2层隐藏层和输出层神经元间的权值;c_h 为输出层阈值。

正向传递过程结束后,开始进行反向传递过程,目的为反复修正权值和阈值,使得误差函数值达到最小。该过程的第1步是将正向传递过程的预测输出与期望输出进行误差计算:

$$e_h=Y_h-O_h,$$

其中:Y_h 为期望输出,$h=1,2,\cdots,m$。根据 e_h 计算的结果进行权值和阈值的更新。

CG-BPNN模型使用共轭梯度法作为优化算法来更新权值,此算法是一种迭代算法[25],可以利用梯度和历史信息来计算更新参数的方向。基于这一特点,CG-BPNN模型能够有效避免陷入局部最优解,并在相对较少的迭代次数下达到全局最优解。但它需要计算每个参数的Hessian矩阵与梯度向量乘积,这可能导致在大型网络和数据集上产生较高的计算成本。最后,权值更新如下:

$$\begin{aligned}\omega_{jk}&=\omega_{jk}+\eta P_k(1-P_k)H_j\sum_{h=1}^{m}\omega_{kh}e_h,\\ \omega_{ij}&=\omega_{ij}+\eta H_j(1-H_j)x(i)\sum_{k=1}^{q}\omega_{jk}e_h,\\ \omega_{n+1}&=\omega_{kh}+\alpha_n P_k e_h=\omega_{kh}+\alpha_n d_n,\end{aligned}\tag{9}$$

其中:ω_n 是第 n 次循环的权重,α_n 为第 n 次循环的学习率。将式(9)最小化以确定学习速度:

$$a_n=\begin{cases}d_0=-g_0,\\ d_n=-g_n+\boldsymbol{\beta}_{n-1}d_{n-1},\\ \boldsymbol{\beta}_n=\dfrac{(\boldsymbol{\beta}_n-\boldsymbol{\beta}_{n-1})^{\mathrm{T}}\boldsymbol{\beta}_n}{\boldsymbol{\beta}_{n-1}^{\mathrm{T}}\boldsymbol{\beta}_{n-1}}。\end{cases}$$

$$g_n=\frac{\partial f(w)}{\partial w}。$$

其中：g_n 为当前的梯度，$\boldsymbol{\beta}_n$ 为共轭因子。

权值更新完成后，阈值更新如下：

$$a_j=a_j+\alpha_n H_j(1-H_j)\sum_{k=1}^{q}\omega_{jk}e_h,b_k=b_k+\alpha_n P_k(1-P_k)\sum_{h=1}^{m}\omega_{kh}e_h,c_h=c_h+e_h。$$

CG-BPNN 模型不断重复着这 2 个过程，直至收敛。

2.2.2　ELM

极限学习机(extreme learning machine，ELM)神经网络由 Ma 等人[26]于 2006 年首次提出，广泛应用于模式识别[27]、回归分析[28]、分类[29]等领域。ELM 属于单隐层前馈神经网络，基本结构如图 3 所示，主要包括输入层、隐藏层和输出层，结构相对比较简单。在训练模型时，一旦计算出隐藏层的输出矩阵，输入层到隐藏层的权值和隐藏层神经元的阈值就会保持不变。因此，只要设置输入和输出的节点数，ELM 就能够快速地进行求解[30]。

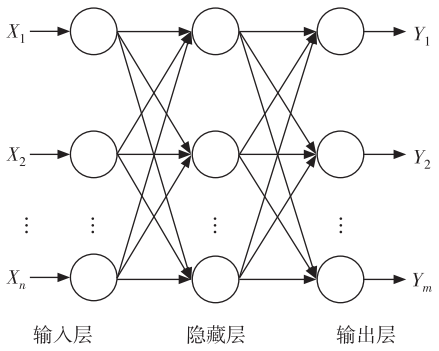

图 3　ELM 的基本结构

Fig. 3　Basic structure of ELM

ELM 训练有以下 3 个步骤。

首先，设置隐藏层神经元的数量，随机生成该神经元的权值 w 和阈值 b。

其次，根据实际应用选择合适的激活函数 f，计算隐藏层输出矩阵：

$$\boldsymbol{H}=f\left(\sum_{i=1}^{n}\omega x_i+b_j\right),$$

式中：x_i 为输入数据；j 为隐藏层神经元个数，$j=1,2,\cdots,l$；n 为输入层神经元个数；b_j 为隐藏层第 j 个神经元的阈值。

最后，输出权值矩阵：

$$\boldsymbol{\beta}=\min_{\boldsymbol{\beta}}\|\boldsymbol{H}\boldsymbol{\beta}-\boldsymbol{L}\|,$$

式中：L 为 ELM 的期望输出。总之，ELM 的学习过程可以在没有人为干预的情况下通过一次迭代完成，并且在很大程度上避免了复杂的局部最优解问题。

2.2.3　总体建模方法

如前所述，本文以不同温度下 GaAs pHEMT 的 S 参数作为建模对象，分别采用双隐藏层 CG-BPNN 和 ELM 进行建模，流程如图 4 所示，主要分为数据准备、模型构建、训练模型、测试模型和生成预测模型 5 个步骤。

第 1 步为数据准备。从国际微波研讨会官网学生竞赛栏目(https://2017.ims-ieee.org/)下载晶体管建模数据，经过数据预处理后以[频率 f，温度 T，基极电流 I_b，发射极与集电极间电压 V_{ce}]作为输入变量，并设置 f 的范围为 0～50 GHz，步长为 1 GHz；T 分别取 20、40 和 60 ℃；I_b 分别取 0.13 和 0.26 mA；V_{ce} 分别取 1 和 2 V。由 S 参数的实部和虚部作为输出变量，即[ReS_{11}，ImS_{11}，ReS_{21}，ImS_{21}，ReS_{12}，ImS_{12}，ReS_{22}，ImS_{22}]。最后，共提取 600 组 S 参数，导入建模软件后随机打乱，再选取 500 组作为训练集，剩余 100 组作为测试集。

第 2 步为模型构建。确定好输入输出后，使用对应的函数分别创建 CG-BPNN 结构和 ELM 结构，并设置神经网络输入层、隐藏层和输出层的神经元个数以及初始权值。

第 3 步为训练模型。设置好最大迭代次数、最佳学习率和最佳误差容限等训练参数后，模型开始训练，若训练参数达到预设要求或者迭代次数达到最大次数，则训练结束。

第 4 步为测试模型。使用测试集对上一步训练好的模型模拟结果进行检验，若误差大于 0.01，则重新调整神经元个数和权值，直至误差满足要求。这里选择均方误差作为判定模型精度的指标，值的大小可以反映预测

数据与真实值的偏差。均方误差的计算公式为：

$$M=\frac{1}{s}\sum_{i=1}^{s}(P_i-T_i)^2。\tag{10}$$

其中：M 为均方误差，s 为预测样本的数量，P_i 为第 i 个预测值，T_i 为对应的第 i 个期望值。此外，为了更清楚地展示误差情况，还计算了绝对误差，计算公式为：

$$E_A=|P_i-T_i|,$$

其中：E_A 为绝对误差，并以曲线图的形式展示。

第5步为生成预测模型，当误差满足精度要求时，则生成S参数预测模型，此时建模结束。

值得注意的是，ANN模型泛化数据的能力主要受超参数的支配[31]。如果参数选择不当，即使是先进的ANN模型也可能表现出较差的性能[32]。因此，为了使CG-BPNN和ELM模型准确表征S参数，必须对ANN模型的超参数进行调整。

第1组超参数与ANN模型结构的构建有关。由于所有ANN模型都有输入层和输出层，因此复杂性主要取决于隐藏层的数量和每层神经元的数量，这是构建深度学习模型的2个主要超参数。这2个超参数是根据数据集或问题的复杂性来设置和调整的。其中，CG-BPNN模型的隐藏层层数已根据数据集选为2层，而每层神经元个数的选择采用目前普遍的经验公式：

$$S=\sqrt{n+m}+\delta,$$

其中：S 为隐藏层神经元个数，n 和 m 分别为输入层及输出层的神经元个数，δ 为1～10之间的常数。为了确定最佳的隐藏层神经元个数，根据经验公式不断试验，并且以均方误差的10次预测平均值作为衡量隐藏层神经元个数优劣的标准，得到试验结果如表1所示。从表中可知2个模型的预测误差均随着隐藏层神经元个数的增加而呈高低起伏变化。其中，CG-BPNN模型隐藏层神经元个数组合为10和15时，均方误差最小。而ELM模型隐藏层神经元个数为15时，均方误差最小。因此，确定了2个模型的最佳隐藏层神经元个数。

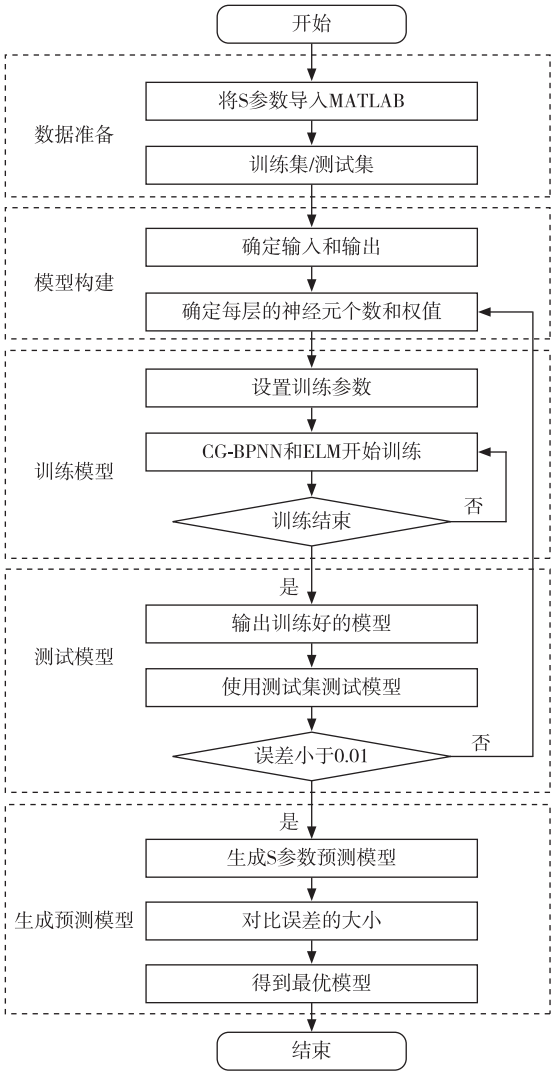

图4 GaAs pHEMT S参数的建模流程

Fig. 4 Modeling process for GaAs pHEMT S-parameters

第2个重要的超参数是用于建模非线性函数的激活函数，其中sigmoid函数和tanh函数在人工神经网络模型中应用最为广泛。本文将这2种激活函数的建模效果进行了比较，根据结果，最终选择sigmoid函数。

第3个重要的超参数是学习率，它决定了每次迭代的步长，使得目标函数收敛。较小的学习率收敛平滑，但会增加模型的训练周期。较大的学习率可以加快学习过程，但梯度可能会在局部最小值附近振荡，甚至不能收敛。因此，只有适当的学习率可以使目标函数在合理的时间内收敛到全局最小值。本文通过试凑法不断取值，最终将CG-BPNN模型和ELM模型的学习率分别设置为0.2和0.4。

3 建模结果及分析

3.1 CG-BPNN预测模型

基于双隐藏层CG-BPNN的S参数预测模型如图5所示，可以看出该模型的结构为4-11-15-8。接着，选取3种不同温度下的预测结果进行展示与分析。

当 $T=20$ ℃，$f=2$ GHz，$I_b=0.13$ mA，$V_{ce}=2$ V时，CG-BPNN模型的拟合结果如图6所示。可以看出，S_{11}、S_{12} 和 S_{22} 的实部与虚部拟合情况比较理想，误差较小。然而，S_{21} 的实部与虚部拟合情况不佳，期望输出与预测输出的偏离程度较大。

表 1　隐藏层神经元个数与 MSE 的关系

Tab. 1　The relationship between the number of hidden layer neurons and MSE

建模方法	隐藏层神经元个数	均方误差	建模方法	隐藏层神经元个数	均方误差
CG-BPNN	68	0.026 540	ELM	4	0.005 415 5
	614	0.017 518		5	0.004 267 8
	79	0.025 171		6	0.005 206 8
	714	0.020 837		7	0.008 164 4
	813	0.018 045		8	0.006 410 4
	814	0.020 824		9	0.006 067 2
	912	0.022 583		10	0.004 620 6
	915	0.016 086		11	0.007 508 1
	1 014	0.018 470		12	0.007 573 1
	1 015	0.016 010		13	0.006 530 6
	1 111	0.013 524		14	0.004 407 2
	1 115	**0.013 058**		**15**	**0.002 254 9**
	129	0.029 656		16	0.005 766 6
	1 214	0.021 439		17	0.004 979 5
	1 314	0.020 021		18	0.002 619 1
	1 315	0.028 621		19	0.003 497 1

注：加粗的数据表示最佳的隐藏层神经元个数和对应的均方误差。

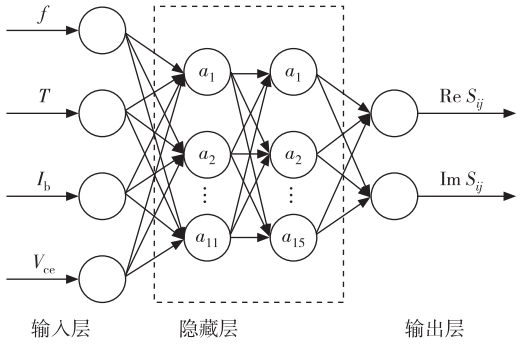

图 5　基于 CG-BPNN 技术的 S 参数预测模型

Fig. 5　S-parameters prediction model based on CG-BPNN technology

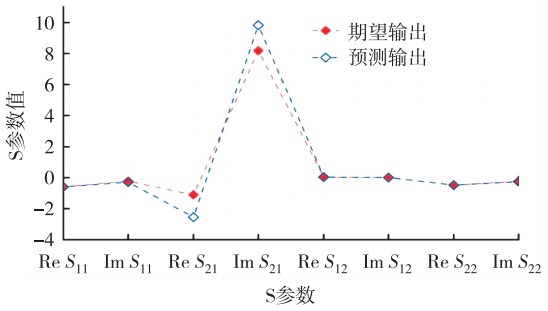

图 6　当 T=20 ℃，f=2 GHz，I_b=0.13 mA，V_{ce}=2 V 时，CG-BPNN 模型的拟合结果

Fig. 6　The fitting results of CG-BPNN model at T=20 ℃，f=2 GHz，I_b=0.13 mA，V_{ce}=2 V

当 T=40 ℃，f=7 GHz，I_b=0.26 mA，V_{ce}=1 V 时，CG-BPNN 模型的拟合结果如图 7 所示。在该组偏置条件下，除了 S_{21} 的虚部没有完全拟合，其余 S 参数的拟合结果良好。但 S_{21} 虚部的拟合误差比温度为 20 ℃时的误差小，因此 CG-BPNN 模型预测 40 ℃的 S 参数会更加准确。

当 T=60 ℃，f=6 GHz，I_b=0.26 mA，V_{ce}=2 V 时 CG-BPNN 模型的拟合结果如图 8 所示。不难看出，S_{11}、S_{12} 和 S_{22} 的实部与虚部以及 S_{21} 的虚部拟合准确度较高，几乎完全拟合。而 S_{21} 实部的拟合情况较差，但是误差在合理的范围内。由此可知，CG-BPNN 对不同温度下的 S 参数进行建模，模型准确率具有不稳定性，误差较大的情况主要出现在 S_{21} 中。

CG-BPNN 模型预测 S_{11} 的绝对误差曲线如图 9 所示。其中，S_{11} 实部的误差区间为[−0.01，0.01]，S_{11} 虚部的误差区间为[−0.07，0.01]。不难看出虚部的误差区间比实部大，并且 S_{11} 实部预测误差较大的原因在于第 1 个测试样本的拟合情况不佳。

CG-BPNN 模型预测 S_{21} 的绝对误差曲线如图 10 所示。可以看出，S_{21} 实部的误差区间为[−1.5，0.5]，S_{21} 虚部的误差区间为[−0.5，1.75]。很明显，二者的误差相差很小，且曲线趋势基本相同，均是前部分样本的误差

波动较大,后部分样本的误差波动较小。

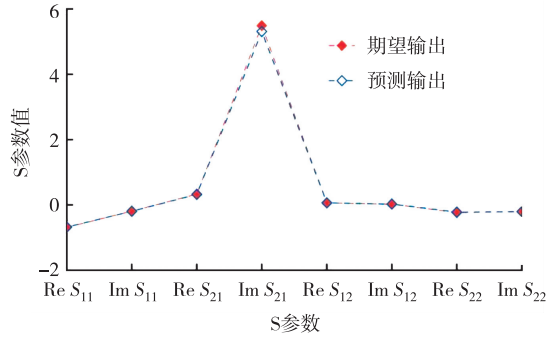

图 7　当 T=40 ℃，f=7 GHz，I_b=0.26 mA，V_{ce}=1 V 时,CG-BPNN 模型的拟合结果

Fig. 7　The fitting results of CG-BPNN model at T=40 ℃, f=7 GHz, I_b=0.26 mA, V_{ce}=1 V

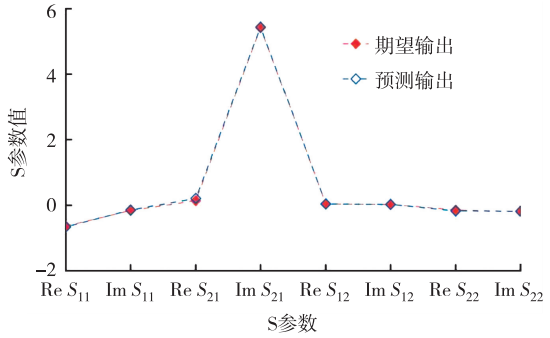

图 8　当 T=60 ℃，f=6 GHz，I_b=0.26 mA，V_{ce}=2 V 时,CG-BPNN 模型的拟合结果

Fig. 8　The fitting results of CG-BPNN model at T=60 ℃, f=6 GHz, I_b=0.26 mA, V_{ce}=2

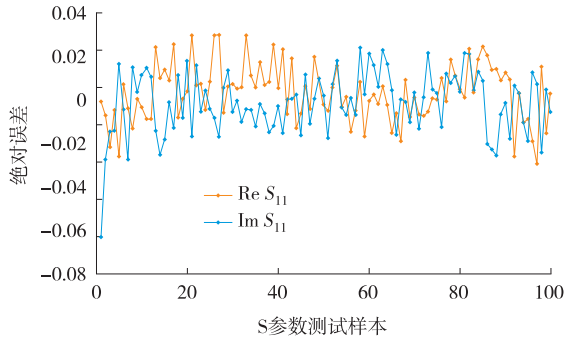

图 9　CG-BPNN 模型预测 S_{11} 的绝对误差曲线

Fig. 9　The absolute error curve of the CG-BPNN model for predicting S_{11}

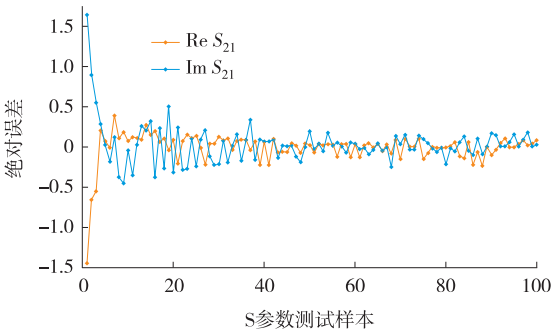

图 10　CG-BPNN 模型预测 S_{21} 的绝对误差曲线

Fig. 10　The absolute error curve of the CG-BPNN model for predicting S_{21}

CG-BPNN 模型预测 S_{12} 的绝对误差曲线如图 11 所示,S_{12} 实部的误差区间为[−0.007 5,0.012 5],S_{12} 虚部的误差区间为[−0.005,0.01]。与 S_{21} 相似,实部与虚部的曲线趋势基本相同,但 S_{12} 是前部分样本的误差波动较小,后部分样本的误差波动较大。

CG-BPNN 模型预测 S_{22} 的绝对误差曲线如图 12 所示,S_{22} 实部的误差区间为[−0.03,0.025],S_{22} 虚部的误差区间为[−0.04,0.02]。可以看出 S_{22} 虚部的误差波动略大于 S_{22} 实部。最后,根据式(10)计算出 CG-BPNN 模型预测 S 参数时的均方误差为 0.013 058。实验结果表明,CG-BPNN 对 GaAs pHEMT 的 S 参数建模时,大部分数据的预测效果良好,但存在少部分数据拟合误差较大的情况,从而导致整体的模型精度不高。

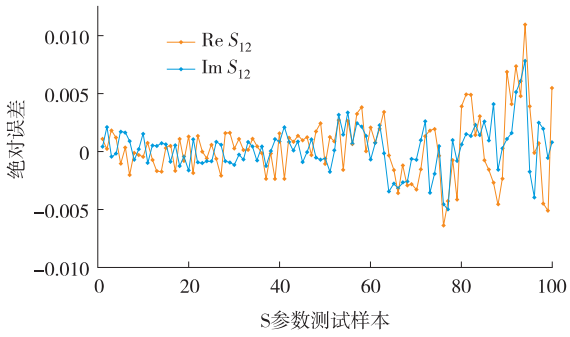

图 11　CG-BPNN 模型预测 S_{12} 的绝对误差曲线

Fig. 11　The absolute error curve of the CG-BPNN model for predicting S_{12}

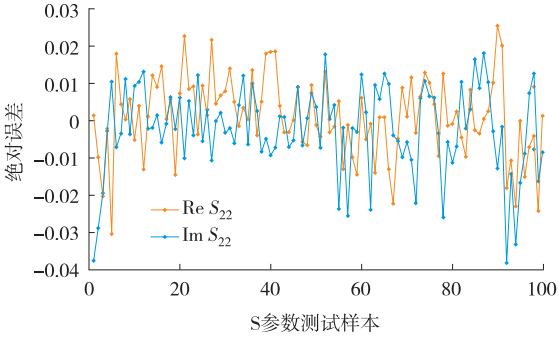

图 12　CG-BPNN 模型预测 S_{22} 的绝对误差曲线

Fig. 12　The absolute error curve of the CG-BPNN model for predicting S_{22}

3.2　ELM 预测模型

基于 ELM 的 S 参数预测模型如图 13 所示，该模型的输入输出与双隐藏层 CG-BPNN 预测模型相同，结构为 4-15-8。为了比较本文 2 种模型的建模精度，选取与 CG-BPNN 预测模型相同的 3 种温度条件下的预测结果进行展示与分析。

当 $T=20$ ℃，$f=2$ GHz，$I_b=0.13$ mA，$V_{ce}=2$ V 时，ELM 模型的拟合结果如图 14 所示。从中可以看出，在此条件下 ELM 模型的拟合结果非常理想，每个 S 参数的期望输出和预测输出都可以准确拟合。

当 $T=40$ ℃，$f=7$ GHz，$I_b=0.26$ mA，$V_{ce}=1$ V 时，ELM 模型的拟合结果如图 15 所示。结果表明，S_{21} 的实部存在轻微误差，但整体上 ELM 模型的拟合效果比较理想，各 S 参数项均能准确拟合。

当 $T=60$ ℃，$f=6$ GHz，$I_b=0.26$ mA，$V_{ce}=2$ V 时，ELM 模型的拟合结果如图 16 所示。从图中可知，S_{21} 的实部和虚部存在一定的误差，但是该误差均控制在很小的范围内。

总体而言，ELM 模型在选取的条件下可以较准确地预测 S 参数。

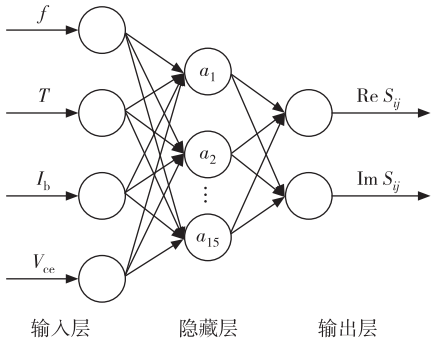

图 13　基于 ELM 的 S 参数预测模型

Fig. 13　S-parameters prediction model based on ELM technology

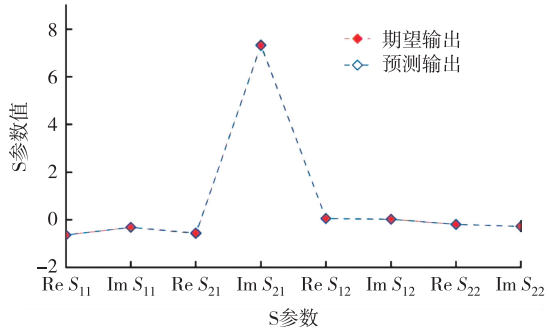

图 14　当 $T=20$ ℃，$f=2$ GHz，$I_b=0.13$ mA，$V_{ce}=2$ V 时，ELM 模型的拟合结果

Fig. 14　The fitting results of ELM model at $T=20$ ℃，$f=2$ GHz，$I_b=0.13$ mA，$V_{ce}=2$ V

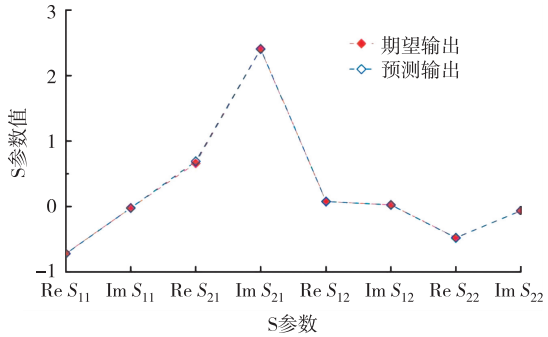

图 15　当 $T=40$ ℃，$f=7$ GHz，$I_b=0.26$ mA，$V_{ce}=1$ V 时，ELM 模型的拟合结果

Fig. 15　The fitting results of ELM model at $T=40$ ℃，$f=7$ GHz，$I_b=0.26$ mA，$V_{ce}=1$ V

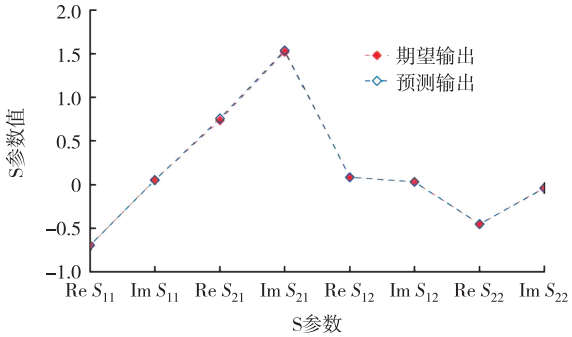

图 16　当 $T=60$ ℃，$f=6$ GHz，$I_b=0.26$ mA，$V_{ce}=2$ V 时，ELM 模型的拟合结果

Fig. 16　The fitting results of ELM model at $T=60$ ℃，$f=6$ GHz，$I_b=0.26$ mA，$V_{ce}=2$ V

在测试样本中，ELM 模型预测 S_{11} 的绝对误差曲线如图 17 所示。其中，S_{11} 实部的误差区间为[−0.02，0.025]，虚部的误差区间为[−0.015，0.025]。此外，大部分测试样本的误差均在 0.01 以下，实部的误差波动大于虚部，但是相较于 CG-BPNN 模型，基于 ELM 预测模型的误差波动得到了较好的改善。

ELM 模型预测 S_{21} 的绝对误差曲线如图 18 所示，实部的误差区间为[−0.5，0.4]，虚部的误差区间为[−0.2，0.1]，并且虚部有 97%的数据在[−0.1，0.1]范围内。由此可知，S_{21} 虚部的误差比实部小，并且误差波动比实部平缓。此外，与图 10 相比，S_{21} 整体上的误差范围较小。

当 ELM 模型预测 S_{12} 时，绝对误差曲线如图 19 所示。可以看出，S_{12} 实部的误差区间为[−0.007，0.007]，虚部的误差区间为[−0.009，0.008]。另外，S_{12} 实部和虚部的误差曲线波动程度类似，即前部分测试样本的误差在[−0.001，0.001]之间，而后部分测试样本存在误差波动较大的情况。

ELM 模型预测 S_{22} 的绝对误差曲线如图 20 所示,S_{22} 实部的误差区间为[−0.025,0.025],S_{12} 虚部的误差区间为[−0.01,0.015]。不难看出,S_{22} 虚部的误差波动要小于实部,并且虚部 92%的测试样本误差小于 0.01,仅有个别样本的误差大于 0.01。此外,计算得出 ELM 模型预测 S 参数的均方误差为 0.002 254 9,比 CG-BPNN 模型的精度提高了 17.27 倍。

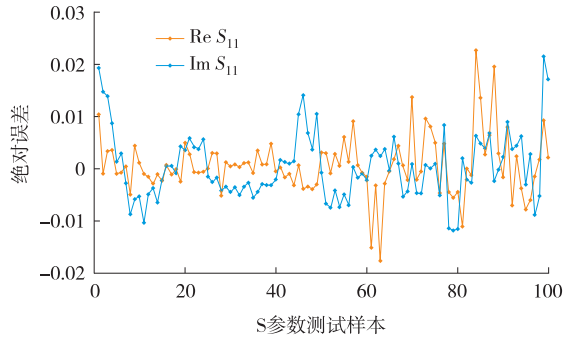

图 17 ELM 模型预测 S_{11} 的绝对误差曲线

Fig. 17 The absolute error curve of the ELM model for predicting S_{11}

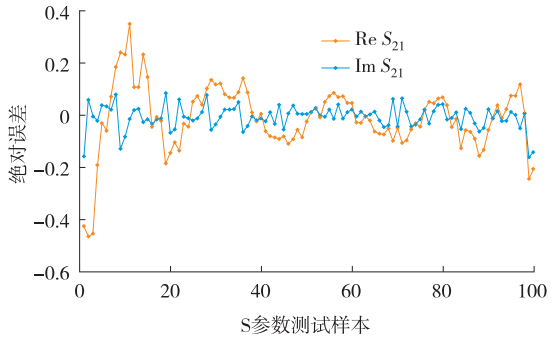

图 18 ELM 模型预测 S_{21} 的绝对误差曲线

Fig. 18 The absolute error curve of the ELM model for predicting S_{21}

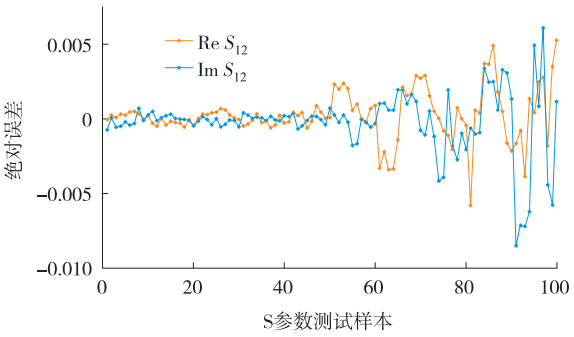

图 19 ELM 模型预测 S_{12} 的绝对误差曲线

Fig. 19 The absolute error curve of the ELM model for predicting S_{12}

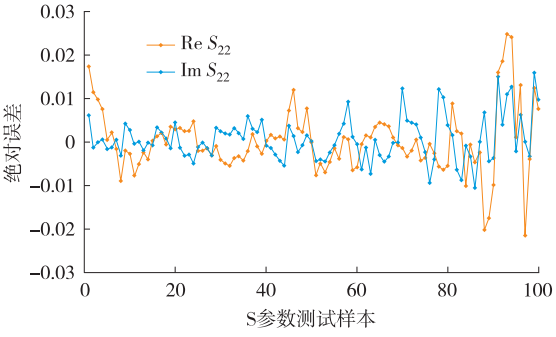

图 20 ELM 模型预测 S_{22} 的绝对误差曲线

Fig. 20 The absolute error curve of the ELM model for predicting S_{22}

3.3 2 种模型的对比分析

为了进一步验证实验的可靠性,将这 2 种建模方法的性能与其他已发布的方法进行比较,如表 2 所示。从中可以看出 ELM 的训练速度和精度均优于其他模型,具有较好的建模能力。根据训练原理,ELM 的高精度归因于简化的训练方式,即不需要通过多次迭代来调整网络参数,直接采用最小二乘法或伪逆方法求解输出层的权值。相比之下,CG-BPNN 涉及到反向传播和共轭梯度算法,容易陷入局部最小值,从而影响模型的训练效果。以上实验结果证明,ELM 具有更好的建模效果,能够对不同温度下 GaAs pHEMT 的 S 参数进行准确并且稳定的预测。

表 2 模型的性能对比

Tab. 2 Performance comparison of models

文献来源	研究对象	模型	训练时间/s	均方误差
文献[6]	GaAs pHEMT	等效电路		0.007 69
文献[10]	COMS	SVM	0.03	0.021 894
文献[11]	NSFET	LM-BPNN	5 400	0.005
本文工作	GaAs pHEMT	CG-BPNN	0.2	0.013 058
本文工作	GaAs pHEMT	ELM	0.01	0.002 254 9

4　结论

为了适应社会对高精度射频微波器件模型的日益迫切需求，本文采用双隐藏层 CG-BPNN 和 ELM 对不同温度下 GaAs pHEMT 的 S 参数进行建模，并给出拟合结果和误差曲线。实验结果表明，ELM 的均方误差为 0.002 254 9，预测模型的拟合效果和误差均优于 CG-BPNN。因此，二者相比，ELM 的建模效果更加理想，可以准确地表征不同温度下 GaAs pHEMT 的 S 参数。这为微波功率器件的小信号建模提供了一种有效方法，同时也为今后进一步开展微波功率器件建模积累了经验。

参考文献：

[1] GALAVIZ-AGUILAR J A, VARGAS-ROSALES C, TLELO-CUAUTLE E. RF-PA modeling of PAPR: a precomputed approach to reinforce spectral efficiency[J]. IEEE Access, 2020, 8: 138217-138235.

[2] ABU ZAHED CHOWDHURY S M, ABDUL ALIM M, REZAZADEH A A. Modeling of noise figure for GaAs pHEMTs based on frequency and temperature[C]//2022 2nd Asian Conference on Innovation in Technology. Piscatway: IEEE, 2022: 1-4.

[3] ALAM M S, ALIM M A, REZAZADEH A A. Measurement and modeling of GaAs based nano-pHEMT: small signal to large signal analysis[C]//2023 International Conference on Electrical, Computer and Communication Engineering. Piscatway: IEEE, 2023: 1-5.

[4] JIANG L, MCGENN W, FRANKS E M, et al. Small signal modelling of 100 nm GaAs pHEMT process in the 4 K to 293 K temperature range[C]//2023 Asia-Pacific Microwave Conference. Piscatway: IEEE, 2023: 793-795.

[5] TSIRONIS C, MEIERER R. Microwave wide-band model of GaAs dual gate MESFET's[J]. IEEE Transactions on Microwave Theory and Techniques, 1982, 30(3): 243-251.

[6] LUO L, LIU J, WANG G F, et al. Small-signal modeling and parameter extraction method for a multigate GaAs pHEMT switch [J]. Journal of Semiconductors, 2020, 41(3): 032102.

[7] LÜ Z H, XU Z W, DANG R R, et al. A compact gate-width scalable model for dual-gate GaAs pHEMT[J]. IEEE Microwave and Wireless Components Letters, 2022, 32(5): 399-402.

[8] ASADA S, MURATA K, TSUCHIDA H. Modeling of stacking faults in 4H-SiC n-type epilayer for TCAD simulation[J]. IEEE Transactions on Electron Devices, 2023, 70(4): 1757-1762.

[9] REDDY M N, PANDA D K. Performance analysis of GaN-FINFET for RFIC application with respect to different FinWidth's [J]. International Journal of Numerical Modelling: Electronic Networks, Devices and Fields, 2023, 36(5): e3098.

[10] ZHOU S H, YANG C, WANG J. Support vector machine-based model for 2.5～5.2 GHz CMOS power amplifier[J]. Micromachines, 2022, 13(7): 1012.

[11] LYU Y Y, CHEN W Y, ZHENG M Y, et al. Machine learning-assisted device modeling with process variations for advanced technology[J]. IEEE Journal of the Electron Devices Society, 2023, 11: 303-310.

[12] 谢佳楠，刘文远，王露洁，等. 一种基于神经网络的微波器件快速建模方法[J]. 微波学报，2022，38(3)：59-64.
XIE J N, LIU W Y, WANG L J, et al. A fast modeling approach for microwave devices based on artificial neural network[J]. Journal of Microwaves, 2022, 38(3): 59-64.

[13] 陈景豪，许高明，刘太君，等. 基于实值时间卷积神经网络的功放预失真研究[J]. 微波学报，2023，39(6)：65-69.
CHEN J H, XU G M, LIU T J, et al. Research on power amplifier predistortion based on real-valued temporal convolutional neural networks[J]. Journal of Microwaves, 2023, 39(6): 65-69.

[14] DOBES J, POSÍSIL L, PANKO V. Selecting an optimal structure of artificial neural networks for characterizing RF semiconductor devices[C]//2010 53rd IEEE International Midwest Symposium on Circuits and Systems. Piscatway: IEEE, 2010: 1206-1209.

[15] SALNIKOV A S. Investigation of behavioral models for MMIC elements[C]//2014 24th International Crimean Conference Microwave & Telecommunication Technology. Piscatway: IEEE, 2014: 119-120.

[16] LONG Y S, ZHONG Z, GUO Y X. A novel 4-D artificial-neural-network-based hybrid large-signal model of GaAs pHEMTs [J]. IEEE Transactions on Microwave Theory and Techniques, 2016, 64(6): 1752-1762.

[17] QI J J, LU H L, YAN S L, et al. Small-signal modeling of microwave transistors using radial basis function artificial neural network-comparison of different methods for spread constant determined[J]. International Journal of RF and Microwave Computer-Aided Engineering, 2022, 32(6): e23145.

[18] LIN Q, JIA L N, WU H F, et al. Temperature behavior modeling based on resilient BPNN for a GaAs pHEMT high gain

MMIC PA[J]. International Journal of Numerical Modelling:Electronic Networks,Devices and Fields,2024,37(2):e3161.
[19] ROOT D E, VERSPECHT J, HOM J, et al. X-parameters: characterization, modeling, and design of nonlinear RF and microwave components[M]. Cambridge:Cambridge University Press,2013.
[20] 杜涛,阮爱武,汪鹏,等.一种基于BP神经网络的集成电路PHM模型[J].计算机工程与科学,2017,39(1):55-60.
DU T,RUAN A W,WANG P,et al. A prognostics and health management model for integrated circuits based on back propagation neural network[J]. Computer Engineering & Science,2017,39(1):55-60.
[21] DU G S,LIU Z X,LU H F. Application of innovative risk early warning mode under big data technology in Internet credit financial risk assessment[J]. Journal of Computational and Applied Mathematics,2021,386:113260.
[22] YU H H,WANG T. A method for real-time fault detection of liquid rocket engine based on adaptive genetic algorithm optimizing back propagation neural network[J]. Sensors,2021,21(15):5026.
[23] ZHU J H,WU A,WANG X S,et al. Identification of grape diseases using image analysis and BP neural networks[J]. Multimedia Tools and Applications,2020,79(21):14539-14551.
[24] ZHANG Y D,DONG Z C,WU L N,et al. A hybrid method for MRI brain image classification[J]. Expert Systems with Applications,2011,38(8):10049-10053.
[25] ZHOU J H. Application of the conjugate gradient method in the BP network[J]. Computer Applications in Engineering education,1999,9(3):17-18.
[26] MA X J,CHEN L,BU J J. Extreme learning machines:a new learning scheme of feedforward neural networks[J]. IEEE Transactions on Neural Networks,2006,17(2):436-449.
[27] SAURAV S,SAINI R,SINGH S. Facial expression recognition using dynamic local ternary patterns with kernel extreme learning machine classifier[J]. IEEE Access,2021,9:120844-120868.
[28] PENG Y,KANG H,CHEN Y N. A research on stock index prediction based on multiple linear regression and ELM neural network[C]//2021 6th International Conference on Intelligent Computing and Signal Processing. Piscatway:IEEE,2021:254-259.
[29] MAO X Y,XIAO X,LU Y L. PolSAR data-based land cover classification using dual-channel watershed region-merging segmentation and bagging-ELM[J]. IEEE Geoscience and Remote Sensing Letters,2021,19:4000905.
[30] IWAHANA K,TAKEMURA T,CHENG J C,et al. MADMAX:browser-based malicious domain detection through extreme learning machine[J]. IEEE Access,2021,9:78293-78314.
[31] CALIK N,GÜNEŞ F,KOZIEL S,et al. Deep-learning-based precise characterization of microwave transistors using fully-automated regression surrogates[J]. Scientific Reports,2023,13:1445.
[32] YANG L,SHAMI A. On hyperparameter optimization of machine learning algorithms: theory and practice[J]. Neurocomputing,2020,415:295-316.

Modeling of Temperature Characteristics for GaAs pHEMT Small Signal S-parameters Based on ANN Technology

YANG Shuyue[1], LIN Qian[1,2]

(1. College of Intelligent Science and Engineering, Qinghai Minzu University, Xining 810007; 2. College of Electronic Information Engineering, Guang'an University of Science and Technology, Guang'an Sichuan 638000, China)

Abstract: In order to address the challenges of complex process and low precision in traditional device modeling, several artificial neural network technologies are used to investigate the scattering parameters (S-parameters) of gallium arsenide pseudomorphic high electron mobility transistor (GaAs PHEMT) at different temperatures. At first, the S-parameters are randomly divided into training set and test set, which are modeled by double hidden layer conjugate gradient backpropagation neural network (CG-BPNN) and extreme learning machine (ELM), respectively. Then, the fitting results and error curves of the two models in predicting the S-parameters are given. The experimental results show that the CG-BPNN has the general fitting result with large errors in some data, whilemost of the data predicted by ELM can achieve ideal fitting result. In addition, the mean square error of CG-BPNN and ELM are 0.013 508 and 0.002 254 9, respectively. Through the above experiments, it is proved that ELM has better modeling effect on the S-parameters of GaAs pHEMT at different temperatures. Therefore, the proposed modeling method can accurately and stably characterize the S-parameters of GaAs pHEMT at different temperatures.

Keywords: CG-BPNN; ELM; S-parameters; GaAs pHEMT

(责任编辑 黄 颖)