

邵丽萍, 杨正亿, 罗双, 等. 基于BP神经网络算法的模拟电路硬故障诊断[J]. 智能计算机与应用, 2025, 15(5): 90-96.
DOI: 10.20169/j.issn.2095-2163.24090203

基于BP神经网络算法的模拟电路硬故障诊断

邵丽萍¹, 杨正亿¹, 罗双², 吴丽娟¹, 赵芳云¹

(1 贵州工程应用技术学院 信息工程学院, 贵州 毕节 551700; 2 贵州工程应用技术学院 理学院, 贵州 毕节 551700)

摘要: 作为电子系统的重要组成部分, 对模拟电路进行故障诊断研究很有必要, 而模拟电路元件具有的非线性、离散型、可用于检测的节点数量少等因素, 传统的故障诊断方法效果并不理想。因此, 进一步探究模拟电路故障诊断方法就已然成为关注重点。神经网络技术因其特性在模拟电路的故障诊断方面表现良好, 但传统的神经网络算法的局限性影响了其在实际诊断中的应用。针对反向传播(Back Propagation, BP)神经网络存在的固有缺陷: 收敛速度慢、容易陷入局部极小, 本研究采用Levenberg-Marquardt(LM)算法对BP神经网络进行训练, 代替了传统的BP神经网络学习算法中的梯度下降法, 进而寻找最优的网络连接权值。通过仿真实验表明, 此方法能够改善BP神经网络的稳定性和学习效率, 大幅提升了对模拟电路故障诊断的准确度, 同时也有效加快了网络的收敛速度。

关键词: 模拟电路; 故障诊断; BP神经网络; LM算法; 梯度下降法

中图分类号: TP391

文献标志码: A

文章编号: 2095-2163(2025)05-0090-07

Hard fault diagnosis of analog circuit based on BP neural network

SHAO Liping¹, YANG Zhengyi¹, LUO Shuang², WU Lijuan¹, ZHAO Fangyun¹

(1 School of Information Engineering, Guizhou University of Engineering Science, Bijie 551700, Guizhou, China;

2 School of Science, Guizhou University of Engineering Science, Bijie 551700, Guizhou, China)

Abstract: As an important part of electronic systems, it is necessary to study fault diagnosis of analog circuits. However, traditional fault diagnosis methods are not ideal to the nonlinearity, discreteness of analog circuit components, and the limited number of nodes available for testing. Therefore, it is particularly important to further explore fault diagnosis in analog circuits. Neural network technology has performed well in fault diagnosis of analog circuits due to its characteristics. However, the limitations of traditional neural network have affected their application in actual diagnosis. To overcome the inherent defects of Back Propagation (BP) neural networks, such as slow convergence and tendency to get trapped in local minima, study employs the Levenberg-Marquardt (LM) algorithm to train the BP neural network, replacing the traditional gradient descent method in BP neural network learning, thereby seeking the optimal network connection weights. The simulation results show that this method can effectively improve the stability and learning efficiency of BP neural network, greatly improve the accuracy of analog circuit fault diagnosis, and accelerate the convergence rate of the network.

Key words: analog circuit; fault diagnosis; BP neural networks; LM algorithm; the gradient descent method

0 引言

目前, 由于电子系统的快速发展和用途广泛, 系统能否正常运行的主要因素就是电子系统的可靠性。相对于模拟电路而言, 数字电路具有电路结构简单、精度高、集成度高、抗干扰能力强等优点, 而模拟电路的工作状态复杂, 静态工作点的设置容易影

响电路的动态范围, 因此, 对模拟电路进行故障诊断更有难度。随着现代电子系统结构的日益复杂化, 传统的模拟电路故障诊断方法已不能取得理想的诊断效果^[1]。故障字典法、参数识别法、专家系统法等是典型的模拟电路故障诊断方法, 但故障字典法在故障模拟、特征提取时离不开大量的人工操作; 参数识别法计算过程相当繁杂; 专家系统法存在自适

基金项目: 贵州省教育厅高等学校科学研究项目(黔教技[2022]402号); 毕节市科学技术项目(毕科联合[2023]50号); 贵州省教育厅2024年度自然科学研究项目(黔教技[2024]256号)。

作者简介: 邵丽萍(1996—), 女, 硕士研究生, 主要研究方向: 通信与信息系统。Email: slinghe163@163.com。

收稿日期: 2024-09-02

应能力差、精确度跳跃等情况。随着对模拟电路故障诊断的研究日趋深入,诊断方法逐步从机器学习的浅层神经网络向基于深度学习的神经网络发展。神经网络技术具有实时处理各种传感器信息、非线性映射、良好的自适应学习性,以及自动识别目标等特性,在模拟电路的故障诊断方面表现尤为出色。文怡婷等学者^[2]提出一种自适应 RBF 神经网络学习算法,实现模拟电路故障的检测及定位,RBF 神经网络算法中的学习率和动量因子固定不变,给收敛速度带来了一定的影响,对于复杂问题,算法仍需要较长的训练时间。范海花等学者^[3]提出一种基于二维卷积神经网络(2D-CNN)的模拟电路故障诊断方法,简化了故障诊断流程,具有较好的泛化能力。Chen 等学者^[4]提出了基于非线性谱和改进卷积神经网络的模拟电路故障诊断方法,但改进卷积神经网络不具有函数逼近能力,完全依赖于数据学习,使复杂的非线性故障诊断结果受到较大影响。研究表明,BP 神经网络是适合模拟电路故障诊断的有效方法之一^[5]。然而,传统的 BP 神经网络算法适用于局部搜索,当要解决复杂非线性问题时,会陷入局部极值,收敛速度慢,网络结构选择不合适会出现过拟合或不收敛等问题。影响了 BP 神经网络在实际模拟电路故障诊断中的进一步应用^[6]。因此,针对模拟电路硬故障诊断问题,本研究采用一种优化 BP 神经网络算法的诊断方案,通过对训练样本、算法等方面的优化改进,进而得到理想的诊断效果。

1 模拟电路故障诊断

模拟电路故障诊断方法如图 1 所示。由图 1 可知,模拟电路故障诊断传统方式有测前仿真法和测后仿真法两种类型^[7]。其中,测前仿真就是对电路模拟、分析、测量后再和之前的数据进行对比实现故障诊断,通常使用概率统计法和故障字典法。这里,故障字典法测试点较少,使用灵活,适用于在线诊断,但难以应用于大规模测试。测后仿真是根据电路测试后的信息进行电路模拟、诊断,常使用故障验证法和参数识别法。这里,参数识别法通过求解方程组确定元件参数值,但计算十分复杂;故障验证法通过激励信号采集可测点数据,依据相应的标准进行验证。而智能化的诊断方法^[8]是随着人工智能技术的快速发展背景下应运而生的,主要包含专家系统、基于神经网络、机器学习等方法,本文主要研究基于神经网络技术的模拟电路故障诊断方法。

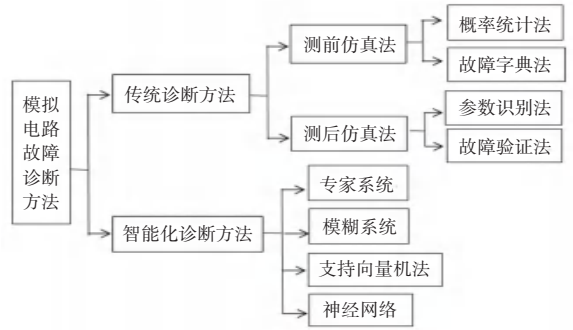


图 1 模拟电路故障诊断方法

Fig. 1 Analog circuit fault diagnosis method

研究可知,利用构建出的不同模拟电路的故障集对神经网络进行训练后,神经网络具有的自适应学习性就能发现电路的故障规律,适用于不同的模拟电路故障诊断,具有广泛的应用性。神经网络的非线性映射可以识别电路结构、元件参数导致的电路故障,并且在没有额外增加采样点时,利用输入、输出信号中的故障特征就能识别大部分故障。因此,将神经网络技术应用于模拟电路故障诊断具有重要的研究意义,针对不同的模拟电路都可遵循故障诊断流程进行诊断^[9]。基于神经网络的模拟电路故障诊断流程如图 2 所示。

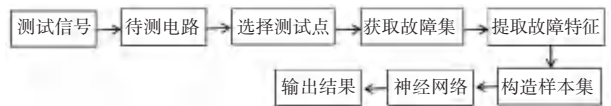


图 2 基于神经网络的模拟电路故障诊断流程图

Fig. 2 Flowchart of analog circuit fault diagnosis based on neural network

模拟电路故障一般是因为使用的元件出现老化、磨损等情况使得元件参数的变化区间超过了设计的范围,还可能导致元件短路、开路等问题。模拟电路故障可分成硬故障和软故障两种类型。其中,硬故障指电路受到不可预测因素影响引发元件短路或者开路的情况,最终会影响整个电路的性能甚至无法工作。软故障则是在电路正常工作过程中,可能由于元器件老化或其他原因而导致器件参数超出正常容差范围时引发的故障^[10]。本文主要针对模拟电路的硬故障诊断进行研究。

模拟电路的故障数据是电路异常时获取到的数据,可通过下列方法采集:实验对象为实际的模拟电路,通过对实际电路加热,或加入故障元件等方式制造故障,利用适当的激励信号对电路的测试点进行测量,重复上述操作采集大量的故障数据。但此方法耗时耗力,加入故障元件时也很难将所有的故障

情况都模拟出来,难以得到全面的故障数据。另一种方法的实验对象是虚拟的电路,利用相关的电路仿真软件构建模拟电路,通过激励信号、电路容差范围的设置、元件参数的修改等方式模拟实际电路的运行环境,运用电脑软件获取电路故障数据。相较于上一种方法,该方法可针对性地进行各种故障情况仿真,操作起来更加灵活、便捷。

2 BP神经网络诊断原理

2.1 BP神经网络模型

BP神经网络的模型结构如图3所示。由图3可知,网络结构主要包含输出层、输入层以及隐藏层三部分,是一种根据误差逆传播算法训练的多层前馈型网络。BP神经网络的隐藏层可设置多层,但研究表明^[11],单隐藏层的BP神经网络已经具备了任意精度的函数逼近能力。因此,在本研究中只含单个隐藏层,具体运行过程如下:假设输入层向量为 $\mathbf{X} = (x_1, x_2, \dots, x_n)$,隐藏层向量为 $\mathbf{H} = (h_1, h_2, \dots, h_n)$,输出层向量为 $\mathbf{Y} = (y_1, y_2, \dots, y_n)$ 。其中,故障征兆层为向量 \mathbf{X} ,而由输入故障征兆参数组成的输入节点为 $x_i (i = 1, 2, \dots, n)$,向量 \mathbf{H} 则是用来提取信号中的高阶相关特性,故障类别层为向量 \mathbf{Y} ,每组的输出矢量都代表了一种故障类型。




图3 BP神经网络的模型结构

Fig. 3 Model structure of BP neural network

BP神经网络的学习过程包括信息的正向传播和误差的反向传播两个过程^[12-13]。输入层的神经元接收到输入信号后随即传递至内部信息处理层,也就是隐藏层的神经元进行信息变换,而隐藏层可根据需求设计成单隐藏层或多隐藏层。当隐藏层将信息传递给输出层处理、输出结果后就完成了一次正向传播过程。如果输出层输出的结果与期望值不符就会进入误差的反向传播,通过期望输出与实际输出之间的误差来调整网络权值,直至获得可接受的结果。

2.2 BP神经网络算法步骤

具体步骤如下:

(1) 设置各权值、阈值的初始值: $u_{ji}(0)$ 和 $\theta_j(0)$

为小的随机数值;

(2) 提供训练样本: 输入矢量 $\mathbf{x}_k, (k = 1, 2, \dots, p)$; 期望输出为 $d_k, (k = 1, 2, \dots, p)$; 对每个输出样本进行步骤(3)和(5)的迭代;

(3) 计算网络的实际输出及隐藏单元的状态, 数学公式如下^[14-15]:

$$o_{kj} = f_j \left(\sum u_{ji} o_{ki} + \theta_j \right) \quad (1)$$

(4) 得到的训练误差为:

$$\delta_{kj} = o_{kj} (1 - o_{kj}) (t_{kj} + o_{kj}) \quad (\text{输入层}) \quad (2)$$

$$\delta_{kj} = o_{kj} (1 - o_{kj}) \sum \delta_{km} u_{mj} \quad (\text{隐藏层}) \quad (3)$$

(5) 修正阈值、权值。定义公式为:

$$\theta_j(t+1) = \theta_j(t) + \eta \delta_j + \alpha [\theta_j(t) - \theta_j(t-1)] \quad (4)$$

$$u_{ji}(t+1) = u_{ji} + \eta \delta_j o_{ki} + \alpha [u_{ji}(t) - u_{ji}(t-1)] \quad (5)$$

(6) 当 k 每经历 1 至 p 后, 判断指标是否满足精度要求: $E \leq \varepsilon$, 其中 ε 为精度。

2.3 BP神经网络的不足

随着BP神经网络在领域实践中的广泛应用,其自身存在的不足和缺点也值得关注^[16]。主要涉及以下几个方面:

(1) 网络结构会影响网络的逼近能力。当网络结构选择过小时,可能导致网络不收敛;而网络结构过大时,出现过拟合现象,容错性下降。

(2) 针对复杂非线性问题时,对BP神经网络的权值进行局部修改,容易收敛到局部极小值,且不同的初始网络权重会使其收敛于不同的局部极小值,导致出现不同的训练结果。

(3) 在面对复杂的目标函数时,BP神经网络使用的梯度下降法会产生锯齿形现象从而导致算法低效,学习速率的固定使得网络收敛速度慢,学习速率过小时大大延长了训练时间。

(4) BP神经网络的学习和记忆具有不稳定性。

3 改进的BP神经网络算法及实现流程

3.1 LM算法原理

传统的BP神经网络算法采用梯度下降法,因是线性收敛,故收敛速度慢。而LM优化算法^[17]是一种快速算法,是将梯度下降法与高斯-牛顿法相结合^[18],利用标准数值优化技术,综合了二者的优势。远离极值点的搜索方向是沿着误差曲面的,具备了梯度下降法的全局特性,而接近极值点时又利用了高斯-牛顿法的局部收敛性,且局部搜索能力

要优于 BP 神经网络。LM 优化算法改变了标准神经网络系统只沿一个负梯度方向修正的局部寻优问题,使整个模型具备自适应调整性能,优化网络模型的连接权值,克服权值修正量很小的问题,有效提高网络模型的收敛速度和泛化鲁棒能力^[19-20]。

LM 优化算法的网络模型误差通过牛顿梯度下降法进行修正调整,对各层神经元连接通道的实际权值和阈值修正量为:

$$\Delta u = (J^T J + \mu)^{-1} J^T e \quad (6)$$

其中, μ 表示各层神经元间负梯度下降运算的约束系数; e 表示 BP 神经网络模型综合输出的误差向量; J 表示网络误差对权值导数的 Jacobian 矩阵。

3.2 改进的 BP 神经网络步骤

算法流程如图 4 所示。流程步骤具体如下:

- (1) 已知系数 β 、 μ 、阈值向量 u_0 、初始化权值,设定训练误差允许值 ε ,并使 $\mu = \mu_0, k = 0$;
- (2) 计算控制量;
- (3) 计算误差指数函数 $E(u_k)$;
- (4) 计算雅克比矩阵 $J(u)$;
- (5) 假如 $E(u_k) < \varepsilon$,转到步骤(7);否则,将 u_{k+1} 作为权值和阈值来计算误差函数 $E(u_{k+1})$;
- (6) 如 $E(u_k) < E(u_{k+1})$,则本次不更新阈值,也不更新权值,并使 $\mu = \mu \cdot \beta$ 、 $u_{k+1} = u_k$,转到步骤(3);若相反,令 $\mu = \mu/\beta$ 、 $k = k + 1$,转到步骤(2);
- (7) 结束。

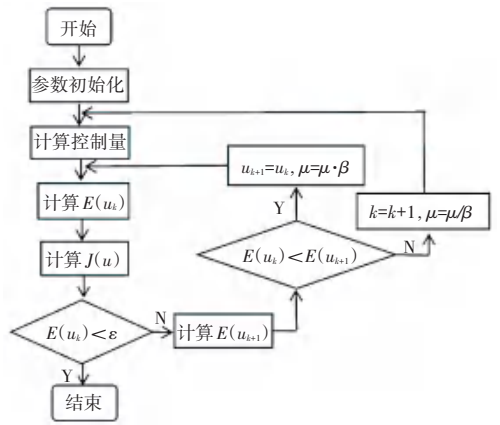


图 4 改进的算法流程图

Fig. 4 Flowchart of improved algorithm

4 仿真结果与分析

为验证改进算法的有效性,研发了仿真诊断电路如图 5 所示。诊断电路为 Sallen-Key 带通滤波器,电压幅值是 10 V、频率是 1 kHz 的正弦电压源作为电路的激励。在诊断电路中,1、3 是可达节点,对于电路的各种故障、正常状态,通过 PsPice 软件分析可达点,归一化处理可达点的电压计算值后,得到了各状态下的特征值,并将其作为训练样本数据。训练样本数据见表 1。通过在元件容差为 5% 的均匀分布情况下,对非故障元件在容差范围内随机取值做 50 次的 MonteCarlo 分析^[21]。最终获得在容差影响下, U_1 、 U_3 的各种状态上下边界诊断特征值,而测试样本数据就是 U_1 、 U_3 的边界特征值。测试样本数据参见表 1。




图 5 诊断电路

Fig. 5 Diagnostic circuit

表1 训练样本和测试样本
Table 1 Training and testing samples

样本序号	状态	训练样本数据			测试样本数据	
		节点1的电压值/mV	节点3的电压值/mV	输出(Y)	节点1的电压值/mV	节点3的电压值/mV
1	正常	5 305	665	1	5 304	532
2	R_1 开路	0	0	2	6	12
3	R_1 短路	7 071	887	3	7 070	710
4	R_2 开路	7 043	883	4	7 051	708
5	R_4 开路	5 298	332	5	5 299	266
6	C_1 击穿	6 058	12 116	6	5 821	11 641

本研究分别采用 BP 网络和 BP-LM 神经网络来训练表 1 中的样本数据,搭建的神经网络框架如图 6、图 7 所示。

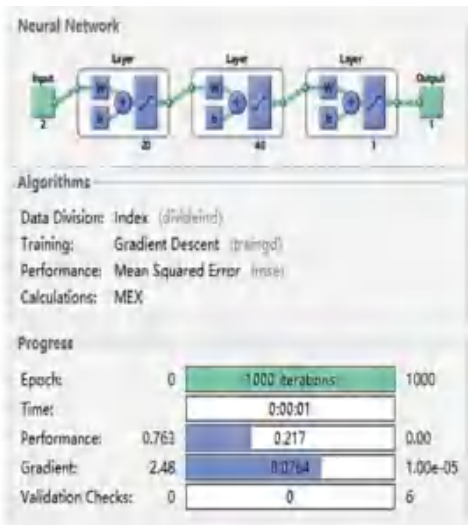


图6 传统 BP 神经网络的结构框图

Fig. 6 Structure diagram of traditional BP neural network



图7 BP-LM 神经网络结构框图

Fig. 7 Structure diagram of BP-LM neural network

训练后的 BP 神经网络和 BP-LM 神经网络收敛特性曲线如图 8、图 9 所示。相应的测试结果如图 10、图 11 所示。其中,网络结构都选为 2-20-40-1,学习算法采用 LM 算法训练神经网络。从图 8、图 9 可知,同等情况下,BP-LM 网络训练了 13 次得到目标函数小于 10^{-3} ,BP 神经网络训练了 1 000 次还未使得目标函数小于 10^{-1} 。对图 8、图 9 进行比较可得,BP-LM 神经网络的训练时间得到了极大缩短,模拟电路故障诊断的速度也有所提高,且收敛速度明显优于传统的 BP 神经网络。

Best Validation Performance is 0.199 38 at epoch 1 000




图8 传统 BP 神经网络训练结果

Fig. 8 Training results of traditional BP neural network

Best Validation Performance is 0.001 296 8 at epoch 13

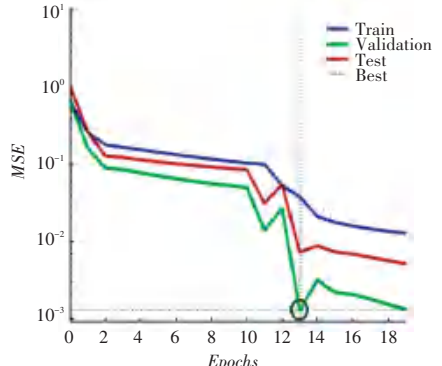


图9 BP-LM 神经网络训练结果

Fig. 9 Training results of BP-LM neural network

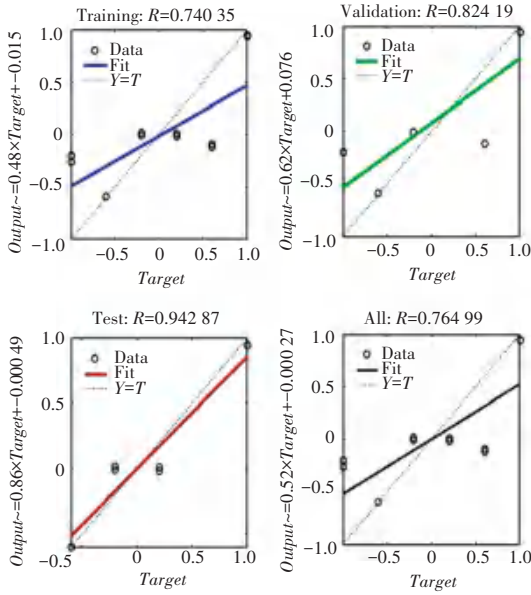


图 10 传统 BP 神经网络测试结果

Fig. 10 Test results of traditional BP neural network

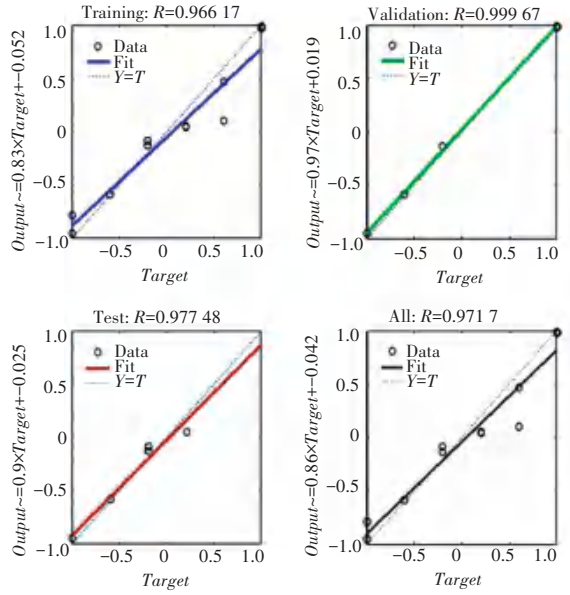


图 11 BP-LM 神经网络测试结果

Fig. 11 Test results of BP-LM neural network

模型检测准确率对比见表 2。由表 2 可知, BP-LM 神经网络的综合准确率达到 93.56%, 比传统的 BP 神经网络提升了 6.73%。为了验证对比试验的完整性, 同时也对比了当前通用的机器学习算

法。对比结果表明, 逻辑回归算法的综合准确率为 85.26%, 而线性回归算法检测效果最差, 综合准确率仅为 78.86%, BP-LM 神经网络均比以上 2 种算法在检测准确度上有了很大提升。

表 2 模型对比结果

Table 2 Model comparison results

模型	状态 1	状态 2	状态 3	状态 4	状态 5	状态 6	mAP
逻辑回归	82.46	96.02	76.12	77.85	85.55	93.56	85.26
线性回归	78.26	92.44	68.62	65.84	82.63	85.39	78.86
BP 神经网络	86.67	95.82	81.53	82.23	84.42	93.27	87.32
BP-LM 神经网络	96.10	97.52	88.23	90.05	91.26	98.21	93.56

5 结束语

研究仿真实验可知, 通过将神经网络方法引入到模拟电路的故障诊断中, 可以极大地提高模拟电路故障诊断效果。采用传统的 BP 算法, 会因其自身存在的缺陷, 如收敛速度较慢、针对复杂非线性问题容易收敛到局部极小值、学习和记忆的不稳定性等, 致使收敛精度难以达到要求。而本研究采用的 LM 优化算法能够实现快速收敛, 并让网络达到了全局最小值, 解决了传统 BP 算法的固有缺陷。对于训练样本相当庞大的模拟电路故障诊断也具有较好的研究价值。从本研究的仿真结果中可以看到, BP-LM 神经网络相对于传统的 BP 神经网络而言, 收敛速度在同等精度情况下明显有较大提升, 表现极为出色。从理论、仿真两方面来看, 针对模拟电路

的故障诊断而言, 采用 BP-LM 神经网络的效果明显优于传统的 BP 神经网络。

参考文献

- [1] 蒋雄, 邓佳. 模拟电路故障分析及诊断方法[J]. 价值工程, 2014, 33(21): 58-59.
- [2] 文怡婷, 严太山, 李文彬. 自适应 RBF 神经网络在模拟电路故障诊断中的应用[J]. 现代计算机, 2019(21): 23-27.
- [3] 范海花, 尚玉玲. 基于二维卷积神经网络的模拟电路故障诊断方法[J]. 桂林电子科技大学学报, 2023, 43(6): 493-500.
- [4] CHEN Lerui, KHAN U S, KHATTAK M K, et al. An effective approach based on nonlinear spectrum and improved convolution neural network for analog circuit fault diagnosis[J]. Review of Scientific Instruments, 2023, 94(5): 054709.
- [5] 庞志华, 孟宪鸿, 卢帅华, 等. 基于 BP 神经网络的便携式模拟电路故障诊断系统研究[J]. 北华航天工业学院学报, 2020, 30(3): 16-19.
- [6] 师彪, 李郁侠, 于新花, 等. 动态调整蚁群-BP 神经网络模型在短期负荷预测中的应用[J]. 水力发电学报, 2011, 30(3):

- 5-9.
- [7] 姜云威. 面向模拟电路故障诊断的深度学习研究方法研究[D]. 桂林: 桂林电子科技大学, 2022.
- [8] 徐万洲. 深度集合型模拟电路故障诊断方法研究[D]. 沈阳: 沈阳理工大学, 2022.
- [9] 郝春燕. 基于神经网络的模拟电路故障诊断方法的研究[D]. 南京: 东南大学, 2018.
- [10] TADEUSIEWICZ M, HALGAS S. Diagnosis of a soft short and local variations of parameters occurring simultaneously in analog CMOS circuits[J]. *Microelectronics Reliability*, 2017, 72: 90-97.
- [11] 赵德赞, 邢军, 王智森. 基于嵌入式系统的BP神经网络及其在模拟电路故障诊断中的应用[J]. *大连工业大学学报*, 2016, 35(1): 57-61.
- [12] 郑力达, 张玉成. 基于优化BP神经网络的冷水机组故障监测研究[J]. *信息技术与标准化*, 2024(7): 32-35.
- [13] 熊兴俊. 基于BP神经网络的大气污染物浓度预测模型[J]. *智能计算机与应用*, 2024, 14(8): 129-132.
- [14] 董珍珍, 杨云. 采摘机器人目标识别分类方法研究: 基于LM优化算法和BP神经网络[J]. *农机化研究*, 2022, 44(8): 25-29.
- [15] 李徐, 张帆, 唐超, 等. 一种基于神经网络梯度下降的多目标优化算法[J]. *智能计算机与应用*, 2024, 14(6): 224-229.
- [16] 李婷. 基于BP神经网络的住院费用建模研究[D]. 唐山: 华北煤炭医学院, 2010.
- [17] 梁乐. 基于LM算法的继电保护装置稳定性自动化检测方法[J]. *自动化应用*, 2024, 65(9): 203-205.
- [18] 陈悦, 张少白. LM算法在神经网络脑电信号分类中的研究[J]. *计算机技术与发展*, 2013, 23(2): 119-122.
- [19] 王炳萱. LM优化算法和神经网络预测控制在非线性系统中的研究[D]. 太原: 太原理工大学, 2016.
- [20] 张钰玲. 基于GA改进的LM-BP神经网络模拟滤波电路故障诊断[D]. 南宁: 广西大学, 2012.
- [21] 姜封国, 周玉明, 于正, 等. 基于神经网络-Monte Carlo法的结构系统可靠性分析[J]. *黑龙江科技大学学报*, 2023, 33(3): 418-423.