

基于选择性集成神经网络的电路板故障智能诊断

于 敏, 马丽华, 卢朝梁

(空军工程大学信息与导航学院, 陕西西安, 710077)

摘要 针对基于红外图像的电路板故障诊断准确率较低、检测灵敏度差等缺陷, 分析了基于神经网络的智能诊断方法。该方法结合多分类器转化为二分类器思想, 设计了一种基于 BP 神经网络的集成神经网络诊断模型, 并且对于同一类故障采取范围化样本进行训练, 每组被测故障数据根据特征阈值选择相关几个子网络进行诊断。最后利用 Matlab 软件进行实例仿真和测试。结果表明: 该网络对于电路板多故障模式的识别准确率较高, 检测灵敏度可以提高 1.74 倍, 而预测误差可以降低到原来的 17.6%, 为电路板故障诊断的实用化提供了理论依据。

关键词 红外热图像; BP; 选择性集成神经网络; 智能诊断

DOI 10.3969/j.issn.1009-3516.2014.06.015

中图分类号 TP206+.3 **文献标志码** A **文章编号** 1009-3516(2014)06-0067-05

Intelligent Diagnosis of Circuit Board Failure Based on Selective Integrated-neural-network

YU Min, MA Li-hua, LU Chao-liang

(Information and Navigation College, Air Force Engineering University, Xi'an 710077, China)

Abstract: In view of limitations of the circuit board fault diagnosis technology on infrared images, in this paper, the intelligent diagnosis method is analyzed. In the method of neural networks, the multiple classifiers are turned into a dichotomous thinking, and an integrated neural network diagnosis model is designed based on BP neural network. For the same type of faults, samples within a range are trained in the network, and for each group of the measured fault data and the several sub-threshold selected, the diagnosis is made according to the characteristics. Finally, the living examples are simulated and tested by using MATLAB. The results show that the recognition accuracy is improved, the detection sensitivity can be increased by 1.74 times, and the prediction error is decreased to 17.6 % of the original prediction error of the more-fault-mode network. This provides a theoretical basis for the practical circuit fault diagnosis.

Key words: infrared images; BP; selective integrated-neural-network; intelligent diagnosis

电路板逐渐成为电子设备中越来越复杂的大系统, 因此如何对其进行高效快速的故障诊断, 使其保持良好的工作状态, 具有重要意义。目前, 红外热敏

成像技术已应用于电路板故障检测^[1]。它进行故障检测的理论依据是差分检测法, 由于电路板多故障的复杂性, 基于差分检测法的红外故障诊断技术往

收稿日期: 2014-06-12

基金项目: 陕西省自然科学基金资助项目(2013JQ8013)

作者简介: 于 敏(1989-), 女, 山东泰安人, 硕士生, 主要从事人工智能技术应用, 红外图像故障诊断研究。E-mail: ymzx8303248@163.com

引用格式: 于敏, 马丽华, 卢朝梁. 基于选择性集成神经网络的电路板故障智能诊断[J]. 空军工程大学学报: 自然科学版, 2014, 15(6): 67-71. YU Min, MA Lihua, LU Chaoliang. Intelligent diagnosis of circuit board failure based on selective integrated-neural-network[J]. Journal of air force engineering university: natural science edition, 2014, 15(6): 67-71.

往检测到的只是温度异常的元件,并非故障源。神经网络技术^[2]代表了一种新的方法体系,它以强有力的学习并行处理能力为故障诊断提供了一种全新的实现手段。BP神经网络利用已有的特征数据和已知的故障结果对神经网络进行训练和网络学习,使BP神经网络的权值、阈值、与已知故障结果之间存在对应关系,达到期望的故障结果^[3]。目前很多学者对传统BP网络进行了改进,例如遗传算法的引入。遗传算法^[4]的基本思想是随机产生若干解,每一个解称为个体或者染色体,每一个染色体携带的数字编码称为基因,将这些解的集合称为种群,通过对染色体适应度的评价,淘汰适应度低的个体,选择适应度高的个体交叉和变异,形成新一代种群,如此不断进化,经过若干迭代代数或者平均适应度已收敛,输出最优的个体,该个体就是问题的最优解^[5]。在选择算子过程中,2个参数交叉概率 p_c 和变异概率 p_m 的选择是影响GA行为和性能的关键所在。目前很多学者对遗传算法进行了改进,以提高神经网络检测的有效性。例如Srinivas等提出一种自适应遗传算法,曲婧华提出的对自适应BP的改进^[6], p_c 和 p_m 能够随适应度自动改变。当种群中每个个体适应度趋于局部最优时, p_c 和 p_m 增加,而当群体适应度趋于局部分散时, p_c 和 p_m 减少。这样对于适应值高于群体平均适应值的个体,对应着较低的 p_c 和 p_m ,使该解得以保护进入下一代;而低于平均适应值的个体对应着较高的 p_c 和 p_m ,使该解被淘汰掉^[7]。这种自适应调整的思想实质上是一种比较性选择:通过比较要交叉的2个个体中较大的适应度值与群体中最大的适应度值的大小来选择交叉概率参数。同理,通过比较要变异个体的适应度值和种群中最大适应度值的大小来选择变异概率,以此达到自适应的目的。

1 人工神经网络

1.1 集成神经网络

神经网络模型^[8]由结构上相同的计算机节点排列而成,从而一层中的每个神经元的输出送到下一层的每个神经元的输入,通过使激励函数最小化过程完成输入到输出的映射^[9]。它具有超强的非线性映射能力和容错性,被广泛应用于电路故障诊断,形成了基于神经网络的智能诊断^[10-12]。然而神经网络的智能诊断目前存在两大问题:一方面对于信号提取得到的大量特征信息如何选取最有价值、分类能力最强的特征信息以提高自动化程度;另一方面是应该如何优化神经网络,方可保证其最大的泛化能力,提高神经网络的自适应能力。

针对于这些问题,很多学者进行了探讨。其中陈果^[13]提出集成分类器思想,并且采用粗糙集和遗传算法进行优化。对于一般集成神经网络,具有网络结构简单、诊断精度高等特点。但是也有缺点:当诊断一组数据时需要进入每一个子网络中进行判断。如果设备的故障分类多时进入每一个子网进行故障判断会加大运算量,使得诊断效率下降。

1.2 选择性集成神经网络

由于电路板故障的多样性、复杂性以及故障参数多变性,传统BP神经网络识别能力比较低,有时甚至检测不出一些隐含故障。本文结合集成神经网络和遗传神经网络比较性选择思想,对传统BP神经网络加以改进,提出选择性集成神经网络方法。

1.2.1 方法改进

第一,将多分类问题转化为两分类,各子网分别负责诊断一种故障(如图1中故障检测模块)。当输入要判断的一组数据时,根据这组数据特征,与设定的阈值进行门限判决从而进入相应子网中诊断,最后输出该子网判决结果。这种选择性的进入子网诊断方法避免了不必要的故障诊断,减少了后台运作时间、使设计的网络结构更加清晰、明了。

第二,为了提高诊断的精度,本文对故障进行了范围化训练。在每一子网中设计针对该故障的多种样本进行训练,这样使训练样本的数据范围更加广泛。图1为选择性集成神经网络的流程图。

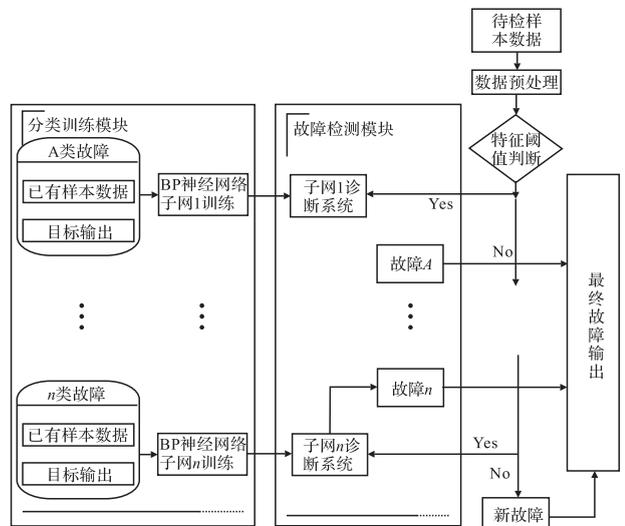


图1 电路板故障诊断的选择性集成神经网络模型

Fig.1 Selective integrated-neural-network model of circuit board fault diagnosis

1.2.2 改进的诊断和训练算法

对于训练数据组,设共有 c 类故障样本,记为 p_1, p_2, \dots, p_c ;对每类故障进行数据范围化由一维向量扩充成 q 维矩阵;记 Q_{pq} 为第 p 类故障第 q 个向量。这样每类故障自成一个子网进行训练。设网络有 m 层, y_j^m 表示第 m 层中第 j 个结点输出, y_j^0 (零

层输出)等于 x_j , 即第 j 个输入。 w_{ij}^m 表示从 y_i^{m-1} 到 y_j^m 的连接加权。

1) 输入待测样本 $\mathbf{C} = [c_1 c_2 \cdots c_N]$, 经过下式阈值判断: $c_i > r_i$ (r_i 为各类元件敏感阈值, 本文根据电路故障数据特点设 $r_i = 0.5$) 跳至步骤 2 进行子网 p_i 的训练和诊断; 否则 i 加 1, 重复步骤 1 直到 $i = N$ 诊断结束。

2) 子网 p_i 训练, 当加入第 Q_{pq} 个输入向量时, 从训练数据组选一数据对 (x^k, T^k) , 将输入向量加到输入层 ($m=0$), 使得对所有端点 i 有 $y_i^0 = x_i^k$, k 表示向量类号。信号通过网络向前传播, 即利用关系式: $y_j^m = F(s_j^m) = F(\sum_i w_{ij}^m y_i^{m-1})$, 计算从第一层开始的各层内每个结点 i 的输出 y_j^m 直到输出层的每个结点的输出计算完为止。

3) 计算输出层各结点的误差: $\delta_j^m = F'(s_j^m)(T_j^k - y_j^m) = y_j^m(1 - y_j^m)(T_j^k - y_j^m)$, 计算前面各层各结点的误差值, 利用公式: $\delta_h^k = F'(s_h^k) \sum_i w_{hi} \delta_j^k = F'(s_h^k) \Delta_h^k$, $\Delta_h^k = \sum_j w_{hi} \delta_j^k$, 得 $\delta_j^{m-1} = F'(s_j^m) \sum_i w_{ji} \delta_i^m$ 。逐层计算反传误差, 直到将每层内每个结点的误差计算出来为止。

4) 利用加权修正公式 $\Delta w_{ij}^m = \eta \delta_j^m y_i^{m-1}$ 和关系 $w_{ij}^{new} = w_{ij}^{old} + \Delta w_{ij}$, 修正所有连接权, 一般训练速率系数 $\eta = 0.01 \sim 1$ 。

5) q 加 1, 若 q 不大于 6, 跳至步骤 2; 否则 $q > 6$, 则对第 p 类故障训练完毕, 对待测样本诊断, 利用误差函数 $e = \sqrt{\sum_{i=1}^N (T_i - Y_i)^2}$ 作为性能指标函数, (其中 Y_i 、 T_i 分别为预测值和期望值), 计算预测误差 e , 并输出诊断结果。

2 基于改进算法的电路板故障智能诊断实例

2.1 确定电路板温度异常元件并编号

造成电路板局部过热的原因有很多, 导体连接不良、材料欠佳、接触面积不足、绝缘子受潮、过负荷运行等等。本例中所使用电路板设计了 5 种常见故障分别记为故障 y_1, y_2, y_3, y_4, y_5 ; 5 个常见异常元件 c_1, c_2, c_3, c_4, c_5 ; 利用基于差分检测法的红外热像技术确定电路板温度异常元件, 经过大量的对现场设备进行红外扫描检测, 掌握各元件间的相互作用关系和热图像规律, 进而形成故障元件的热图像参考图谱和判断标准^[14]。

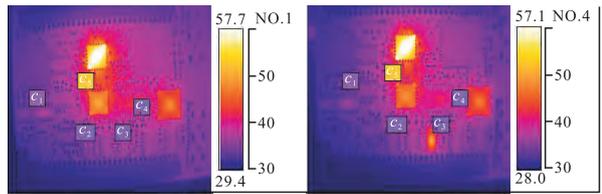


图 2 红外热图像

Fig.2 Infrared thermal image

2.2 建立范围化故障征兆表并数据处理

在电子电路中, 元件异常工作时温度高于或低于正常温度, 但是异常温度并不是一个固定值, 而是在一个范围内波动。如果仅用一组数据对它进行网络训练, 会使得训练结果仅收敛于该组数据。当输入新的一组测试数据时, 得到的诊断结果误差会很大。考虑到这一点本文提出数据范围化网络训练。

采用多次测量求平均值法得到电路在正常工作的一组温度值, 记为 y_0 。对于发生故障 y_1 时, 采集 6 组数据组成一个矩阵, 这 6 组数据都是针对故障 y_1 时的特征数据。记为矩阵 \mathbf{Y}_1 。将 \mathbf{Y}_1 的每一组数据减去 y_0 由此得到发生故障 y_1 时的相对温差数据组矩阵记为 \mathbf{Y}'_1 。同理得到 $\mathbf{Y}'_2, \mathbf{Y}'_3, \mathbf{Y}'_4, \mathbf{Y}'_5$ 。

经过实验, 建立电路板故障原因与征兆对应表, 见表 1。将故障发生时所对应的元件 $c_1 \sim c_5$ 的 5 组相对温差作为网络的输入, 因此每个子网输入层节点设置为 5。

表 1 范围化故障征兆表

Tab.1 Scope of fault symptom table

故障类型	网络输入					目标输出				
	c_1	c_2	c_3	c_4	c_5	c_1	c_2	c_3	c_4	c_5
y_1	28.9	0.6	2.7	0.2	0.6	1	0	0	0	0
y_1	32.6	1.1	0.2	0.8	0.3	1	0	0	0	0
y_1	36.7	2.3	0.6	0.4	2.1	1	0	0	0	0
y_1	40.5	1.4	2.3	1.4	1.3	1	0	0	0	0
y_1	46.4	0.8	1.3	1.3	2.0	1	0	0	0	0
y_1	50.3	1.5	0.5	0.7	0.4	1	0	0	0	0
y_2	0.6	29.9	0.3	48.6	1.2	0	1	0	1	0
y_2	1.1	34.5	1.3	50.3	0.3	0	1	0	1	0
y_2	2.1	38.7	0.8	36.4	1.4	0	1	0	1	0
y_2	0.3	42.3	3.0	43.5	0.9	0	1	0	1	0
y_2	1.8	48.6	1.3	37.6	0.7	0	1	0	1	0
y_2	0.9	50.7	0.7	36.5	1.1	0	1	0	1	0
y_3	1.2	0.8	28.9	0.8	0.3	0	0	1	0	0
y_3	0.3	0.4	34.9	0.7	1.8	0	0	1	0	0
y_3	0.9	1.0	38.2	2.1	0.3	0	0	1	0	0
y_3	2.0	2.1	43.7	1.4	0.7	0	0	1	0	0
y_3	1.3	0.3	46.8	1.3	1.1	0	0	1	0	0
y_3	0.5	0.8	51.3	0.4	0.9	0	0	1	0	0
y_4	29.6	0.7	0.3	1.5	48.9	1	0	0	1	0
y_4	32.8	1.9	1.3	0.9	46.7	1	0	0	1	0
y_4	37.8	0.4	0.7	0.4	27.4	1	0	0	1	0
y_4	41.3	0.5	0.8	1.3	36.2	1	0	0	1	0
y_4	46.7	1.7	2.0	0.4	30.5	1	0	0	1	0
y_4	49.3	0.8	1.1	0.7	33.5	1	0	0	1	0
y_5	2.3	1.4	31.2	3.1	33.4	0	0	1	0	1
y_5	1.5	0.5	40.9	2.4	50.6	0	0	1	0	1
y_5	0.6	0.7	43.8	5.7	42.4	0	0	1	0	1
y_5	1.7	2.5	34.5	3.3	41.2	0	0	1	0	1
y_5	1.4	1.1	36.7	1.2	53.8	0	0	1	0	1
y_5	0.6	2.1	47.3	4.3	37.5	0	0	1	0	1

表中“网络输入”栏各个数据代表元件故障温度与标准温度的相对温差。“目标输出”栏“1”代表元

件发生故障,“0”代表元件没有发生故障。

2.3 仿真与结果分析

试验平台为 XP 系统,CPU 为 Intel Core i3-2120 3.30 GHz,内存 2 G,编程环境为 Matlab R2010a。

2.3.1 网络训练的误差收敛性比较

以故障 y_3 为例,选择性集成网络与传统 BP 神经网络对比。该故障的温度异常元件是 c_3 ,从训练样本中选择 1 组待测样本分别采用传统 BP 神经网络和本文提出的选择性集成 BP 神经网络进行仿真。经 125 次迭代后,该网络性能达到规定误差要求,可进行故障诊断。诊断结果对比见表 2。

表 2 发生故障 y_3 两种神经网络输出结果

Tab.2 Output Results of Two Kinds of Neural Network When y_3 Fault Occurs

输出	c_1	c_2	c_3	c_4	c_5
理想输出	0	0	1	0	0
传统 BP 输出	0.009 1	0.006 8	0.920 9	0.000 5	0.058 0
选择性集成 BP 输出	0.050 8	0.064 6	0.969 0	0.046 1	0.039 7

从表 2 可以看出,发生故障 y_3 时集成神经网络诊断的故障结果($c_3=0.969 0$)与传统神经网络诊断结果($c_3=0.920 9$)相当。从图 3 可以看出:2 条曲线最终都收敛到所设定的误差值 0.001,集成神经网络仅用 125 次迭代;对比图 4 神经网络经过 188 次迭代才收敛到 0.001 误差值。

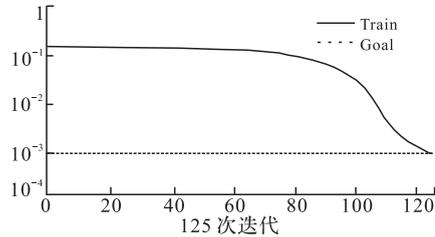


图 3 选择性集成 BP 结果

Fig.3 Results of selective integrated BP

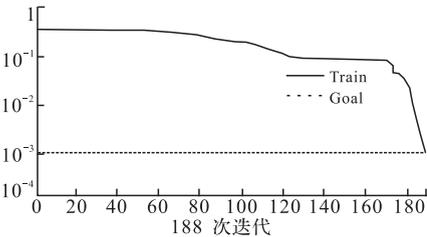


图 4 传统 BP 结果

Fig.4 Results of traditional BP

2.3.2 诊断敏感性比较

以发生故障 y_4 为例进行比较。本文故障 y_4 是指当电路元件 c_1 、 c_5 出现异常,而真正发生故障的元件是 c_1 、 c_4 。利用两种神经网络来检测故障 y_4 的真正故障元件,诊断结果本文给出了仿真比对。从

表 3 可以看出选择性集成神经网络,诊断出 c_1 实际输出值 0.911 1, c_4 为 0.978 3,都非常接近“1”,所以很容易判定 c_1 、 c_4 同时出现故障。传统神经网络只能诊断出 c_1 (实际输出值 0.7638 接近“1”),对于 c_4 的实际输出值 0.357 1,很难判断是否出现故障,敏感性提高了 1.74 倍。经过大量实验证明,样本数据进行范围化之后,神经网络可以更加准确的判断出故障源。

表 3 故障 y_4 仿真结果

Tab.3 Simulation Results When y_4 Fault Occurs

输出	c_1	c_2	c_3	c_4	c_5
理想输出	1	0	0	1	0
选择性集成 BP 输出	0.911 1	0.088 2	0.018 5	0.978 3	0.000 2
传统 BP 输出	0.763 8	0.033 5	0.225 4	0.357 1	0.002 9

预测误差比较:BP 预测误差输出 $e =$

$$\sqrt{\sum_{i=1}^N (T_i - Y_i)^2} = 0.721; \text{选择性集成 BP 的预测}$$

误差输出 $e = \sqrt{\sum_{i=1}^N (T_i - Y_i)^2} = 0.127$,是传统 BP 误差的 17.6%。对于多个元件导致的故障,用 BP 神经网络算法进行诊断的敏感性要差于选择性集成神经网络。这是因为在每个子网只负责一种故障诊断,范围化训练样本之后使得敏感性更强。

2.3.3 诊断效率比较

以发生故障 y_5 为例进行仿真。选择一个待测样本, $P=[1.2 \ 0.7 \ 30.5 \ 0.2 \ 50.6]$,故障 y_5 的异常元件是 c_3 和 c_5 。仿真结果见表 4~表 6。

目标输出 $T=[0 \ 0 \ 1 \ 0 \ 1]$,即 $c_3=1, c_5=1$,出现故障。

表 4 传统 BP 诊断结果

Tab.4 Diagnosis results of traditional BP

诊断值	$c_1=0.007 7, c_2=0.054 3, c_3=0.924 0,$ $c_4=0.021 0, c_5=0.895 7$
最终诊断结果	c_3, c_5 为故障元件
诊断时间	1.70 s

表 5 一般集成神经网络

Tab.5 Diagnosis Results of Integrated BP

子网 1 诊断值	$c_1=0.089 2$
子网 2 诊断值	$c_2=0.099 5$
子网 3 诊断值	$c_3=0.992 8$
子网 4 诊断值	$c_1=0.002 3 \ c_5=0.021 5$
子网 5 诊断值	$c_3=0.988 5 \ c_5=0.989 4$
最终诊断结果	c_3, c_5 为故障元件
诊断时间	6.49 s

表6 选择性集成BP诊断结果

Tab.6 Diagnosis Results of Selective Integrated BP

子网3诊断值	$c_3=0.9829$
子网5诊断值	$c_3=0.9954, c_5=0.9848$
最终诊断结果	c_3, c_5 为故障元件
诊断时间	2.80 s

由表6知,选择性集成神经网络并不是进入所有子网进行诊断,而是通过特征阈值判断进入相应几个子网进行诊断。本例中分别进入子网3和子网5进行诊断,并且得到各自的诊断结果。对比表5可以看到该网络节约了大量时间;对比表4,选择性集成神经网络诊断时间虽然加长了,却提高了诊断精度。

3 结语

本文对红外热图像电路板故障自动诊断进行了研究和实现,采用多分类向两分类转化思想设计多个针对不同故障的子网络,最后形成集成网络。基于集成神经网络,本文提出特征阈值比较的选择性集成神经网络,减少了不必要的运算量;并且根据故障电路板红外热图像数据的分布特点,提出样本数据范围内训练。经过实验验证,取得较为满意的结果,提高了神经网络诊断的敏感性。限于篇幅,本文采用的样本集数据较少,如果想提高网络识别的准确率,需要大容量的训练样本。

参考文献(References):

- [1] 马丁·P L.电子故障分析手册[M].北京:科学出版社,2005.
Martin P L. Electronic Failure Analysis Handbook[M]. Beijing: Science Press, 2005. (in Chinese)
- [2] 韩力群.人工神经网络教程[M].北京:北京邮电大学出版社,2006.
HAN Liqun. Artificial Neural Network Tutorial[M]. Beijing: Beijing university Posts and Telecommunications Press, 2006. (in Chinese)
- [3] 魏江涛,陈方涛,姜美雷.BP神经网络在设备故障诊断方面的应用[J].现代电子技术,2010,35(19):132-133.
WEI Jiangtao, CHEN Fangtao, JIANG Meilei. Application of BP neural network in fault diagnosis of radar device[J]. Modern Electronics Technique, 2010, 35(19): 132-133. (in Chinese)
- [4] Adami C. Introduction to Artificial Life[M]. California: TELOS, 1998: 1-15.
- [5] 任勋益,王汝传,周何骏.遗传BP神经网络及其在异常检测中的应用[J].计算机工程与科学,2008,30(11):19-20.

- REN Xunyi, WANG Ruchuan, ZHOU Hejun. The genetic BP neural network and its application in anomaly detection[J]. Computer engineering & science, 2008, 30(11): 19-20. (in Chinese)
- [6] 曲婧华.基于自适应神经网络的电路系统故障诊断研究[J].空军工程大学学报:自然科学版,2006,07(04):82-83
QU Jinghua. Research on Fault Diagnosis of circuit system based on adaptive neural network[J]. Journal of air force engineering university: natural science edition, 2006, 07(04): 82-83. (in Chinese)
- [7] 李享梅,赵天峻.改善遗传神经网络收敛性的研究[J].计算机应用,2005,25(12):2790-2791.
LI Xiangmei, ZHAO Tianyun. Study on improving the convergence of genetic neural network[J]. Computer application, 2005, 25(12): 2790-2791. (in Chinese)
- [8] Di Zeno S. A note on the gradient of a multi-image. Comput. Vis. Graph[J]. Image Processing, 1986, 33(1): 116-125.
- [9] 张红辉,罗海波,余新荣,等.改进的神经网络红外图像非均匀性校正方法[J].红外技术,2013,35(04):233-234.
ZHANG Honghui, LUO Haibo, YU Xinrong, et al. Improved algorithm of neural network used in IR image non-uniformity correction[J]. Infrared technology, 2013, 35(04): 233-234. (in Chinese)
- [10] Kalkat M, Yildirim S, Uzmay I. Design of artificial neural networks for rotor dynamics analysis of rotating machine systems[J]. Mechatronics, 2005, 15(05): 573-588.
- [11] Nalinaksh S, Vyas D. Satishkumar. Artificial neural network design for fault identification in a rotor-bearing system[J]. Mechanism and machine theory, 2001, 36(03): 157-175.
- [12] 虞和济,陈长征,张省,等.基于神经网络的智能诊断[M].北京:冶金工业出版社,2000.
YU Heji, CHEN Changzheng, Zhang Sheng, et al. Intelligent diagnosis based on neural network[M]. Beijing: Metallurgical industry press, 2000. (in Chinese)
- [13] 陈果.粗糙集-遗传算法-神经网络集成分类器及其在转子故障诊断中的应用研究[J].中国机械工程,2008,19(01):85-89.
Chen Guo. Rough set-genetic algorithm-neural network composite classifier and its application in rotor faults diagnosis[J]. Chinese mechanical engineering, 2008, 19(01): 85-89. (in Chinese)
- [14] 梁旗.基于红外热图像电力设备热故障的自动诊断[J].人工智能及识别技术,2008,06(03):1107-1108.
LIANG Qi. Automatic diagnosis of electric power appliances thermal failure based on infrared thermal image[J]. Artificial intelligence and recognition technology, 2008, 06(03): 1107-1108. (in Chinese)

(编辑:姚树峰)