

基于 FPGA 及 RBF 神经网络的电磁无损检测技术

王丽霞, 杨惠春

(北京信息科技大学 自动化学院, 北京 100192)

摘要: 电磁无损检测技术是无损检测领域的一个研究重点, 针对电磁无损检测技术中的超声波处理, 提出了一种基于 FPFA 的参数优化的 RBF 神经网络; 首先, 通过 FPGA 编程实现对电磁超声波信号的采集, 设计了放大电路将原始的电磁超声波进行放大处理已满足 RBF 神经网络的需求; 提出一种采用 K-means 聚类算法来计算 RBF 中径向基函数的中心和宽度的参数优化 RBF 算法, K-means 聚类算法的初始聚类中心难以确定会导致 RBF 算法的参数无法优化, 提出 KL 散度, 采用数据密度分析法来计算 K-means 算法的聚类中心; 试验表明, 改进后的 K-means 算法的聚类误差的数量级为 10^{-12} , 传统 K-means 算法的聚类误差为 10^{-13} , 改进后的 K-means 算法的聚类结果更准; 参数优化后的 RBF 神经网络对具有 1.02 mm 缺陷长度的发动机涡轮叶片的缺陷长度预测结果为 0.9~1.1 mm, 传统的 RBF 神经网络的预测结果为 0.7~1.2 mm, 参数优化后的 RBF 神经网络的预测结果更准确。

关键词: 电磁无损检测技术; FPGA; 放大电路; RBF 神经网络; K-means 聚类算法

Electromagnetic Nondestructive Testing Technology Based on FPGA and RBF Neural Network

WANG Lixia, YANG Huichun

(School of Automation, Beijing Information Science and Technology University, Beijing 100192, China)

Abstract: Electromagnetic non-destructive testing technology is a research focus in the field of non-destructive testing. Aiming at ultrasonic processing in electromagnetic non-destructive testing technology, a RBF neural network based on FPFA parameter optimization is proposed. First of all, the acquisition of electromagnetic ultrasonic signals was realized through FPGA programming, and the amplification circuit was designed to amplify the original electromagnetic ultrasonic waves. It has met the needs of RBF neural network; a K-means clustering algorithm was proposed to calculate the radial basis in RBF. The parameters of the center and width of the function optimize the RBF algorithm. The initial clustering center of the K-means clustering algorithm was difficult to determine, which will cause the parameters of the RBF algorithm to be unable to optimize. The KL divergence was proposed and the data density analysis method was used to calculate Cluster center of the K-means algorithm. Experiments show that the magnitude of the clustering error of the improved K-means algorithm is 10^{-12} , and the clustering error of the traditional K-means algorithm is 10^{-13} , and the improved K-means algorithm has more accurate clustering results; After parameter optimization, the RBF neural network predicts the defect length of engine turbine blades with a defect length of 1.02 mm, which is 0.9~1.1 mm, and the traditional RBF neural network predicts a good result of 0.7~1.2 mm. With optimized parameters the prediction result of RBF neural network is more accurate.

Keywords: electromagnetic nondestructive testing technology; FPGA; amplifying circuit; RBF neural network; K-means clustering algorithm

0 引言

无损检测技术是指在不破坏物体表面或者内部的情况下, 检测物体的性能、材料组织状态的一种技术, 被广泛应用到航天、铁路、机械制造、石油化工等领域。无损检测技术通过不断的发展, 也逐渐的出现很多检测技术, 比如 X 射线、磁粉、超声、电磁超声等, 其中电磁超声无损检测技术是近年来无损检测技术领域的研究重点, 无损检测技术的重点在于对采集数据的处理和分析, 得到检测结果。对于电磁超声波信号的处理与分析, 本文采用 RBF 神经网络对电磁超声波信号进行分析, 但是需要对其参数进

行进一步的优化。

在现有的 RBF 神经网络参数优化研究中, 文献 [1] 提出一种采用自适应混沌果蝇算法来优化 RBF 神经网络, 首先采用自适应混沌来优化果蝇算法, 然后将其用来改善 RBF 神经网络的结构参数, 能够减少较大预测误差出现的概率, 但是需要进行迭代运算, 计算量较大; 文献 [2] 针对 RBF 神经网络对 DNA 序列的分类问题, 提出一种改进粒子群算法来优化 RBF 神经网络参数, 虽然也能够提高 RBF 的收敛速度和泛化能力, 但是也需要进行迭代运算。

基于以上内容, 本文采用 K-means 算法对 RBF 神经网络

收稿日期: 2020-11-20; 修回日期: 2021-01-11。

作者简介: 王丽霞(1977-), 女, 内蒙古人, 硕士, 讲师, 主要从事检测与自动化, 电子技术等方向的研究。

引用格式: 王丽霞, 杨惠春. 基于 FPGA 及 RBF 神经网络的电磁无损检测技术[J]. 计算机测量与控制, 2021, 29(7): 31-35.

络的参数进行优化,引入 KL 散度对传统 K-means 算法进行改进以提高其分类准确度,根据 K-means 算法的聚类结果,计算 RBF 神经网络中的径向基函数的中心和宽度两个参数,最后,以发动机涡轮叶片为例来验证算法的可行性。

1 电磁无损检测技术及原理

电磁无损检测技术是利用电磁感应原理产生的超声波对材料内部进行检测的一种技术^[3],其主要原理如图 1 所示。

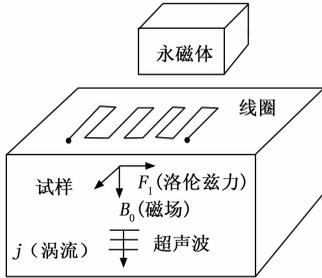


图 1 电磁检测原理

首先在被检测金属零件表面的线圈中通入高频电流,根据电磁感应被检测金属零件的内部会产生一个形同频率的感应电流,感应电流在永磁体的磁场下会产生相同频率的洛伦兹力,此时金属的结晶点阵会受到该洛伦兹力的作用,晶体会产生周期性的振动,进而产生超声波^[4]。当被检测零件的材料是铁磁性材料时,该零件内部晶体不仅会受到洛伦兹力的作用,还会受到磁致伸缩力的作用,为了减少该力对检测结果的影响,需要采用电磁超声换能器 (EMAT, electromagnetic acoustic transducer),其主要由高频线圈、外界线圈、被测导致三部分组成^[5]。在实际的检测过程中,通过设计线圈的结构和改进线圈的摆放位置,或者改变线圈的物理参数,不仅可以减少磁致收缩力对检测结果的影响,还能改变被检测零件的受力方向,产生不同的超声波用来检测^[6]。

电磁无损检测主要应用于金属探伤,高温、高压管道状态下的管道测量、无缝钢管检测等领域^[7]。其主要的优势在于可以检测任意的金属材料,并且不需要耦合剂,对金属表面的光洁度和检测环境也没有太高的要求,并且很容易产生水平剪切波和兰姆波。其主要的缺陷是只能检测导电介质,检测时会受到被检测零件的尺寸和外观的影响,并且检测的精度较低^[8]。

总之,随着电磁无损检测技术的不断发展,结合人工智能技术,能够在工业生产过程中对产品的质量进行把关,通过检测结果,能够优化生产工艺,提高产品质量和效率,会大幅度提高生产力,节省人力物力和成本^[9]。

2 基于 FPGA 的超声波信号采集与处理

电磁无损检测技术是一个“硬件+软件”结合的综合技术^[10]。为了实现多维度电磁超声波的信号采集和快速处理,本文采用大规模可编程逻辑器件 (FPGA) 来实现对电磁超声波信号进行采集和处理^[11],基本架构如图 2 所示。

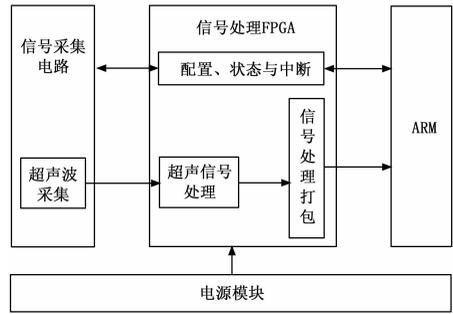


图 2 超声波信号采集与处理架构

该系统主要分为 3 个子模块,信息采集模块、信息处理模块模块和电源模块。信号采集模块主要通过信号采集电路实现超声波信号的采集;信号处理模块包括配置、状态与中断模块、信号处理和信号处理打包 3 个子模块,配置、状态与中断模块与信号采集与 ARM 处理器相连,对信号采集和 ARM 的工作状态进行控制;电源模块则负责给整个信号采集和处理的过程进行供电^[12]。

但是采集到的超声波的信号较小,需要进行放大达到一定的功率范围后才能被 A/D 采样器转化^[13],因此本研究设计出一个放大电路来实现超声波信号的放大,放大电路如图 3 所示。

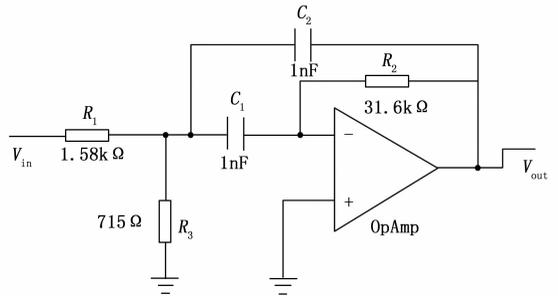


图 3 放大电路

在放大电路的输入端接入一个 715 Ω 的电阻,不仅增加了整个放大电路的阻抗,还提高了电路的耦合性^[14]。采用 LC 回路作为反馈支路,提高了整个放大电路的稳定性^[15]。FPGA 的软件部分则为超声波信号的处理算法,下文进行详细的描述。

3 参数优化 RBF 神经网络

3.1 聚类 RBF 神经网络

本研究采用的信号分析算法为 RBF 神经网络,RBF 神经网络是一种多层前向型神经网络,其建立的基础为函数逼近理论,能够逼近任意的非线性函数,具有快速的收敛能力和泛化能力,已被广泛的应用到故障诊断、时间序列分析、系统建模等领域^[16],其结构如图 4 所示。

RBF 神经网络由输入层、隐含层、输出层三层的前馈神经网络构成。假设输入层的节点数为 n ,隐含层的节点数为 m ,输出层的节点数为 p ,输入层的向量用 x 表示, $x = (x_1, x_2, \dots, x_n)^T$,根据 RBF 结构和原理,则隐含层的第 j 个节点的输出为:

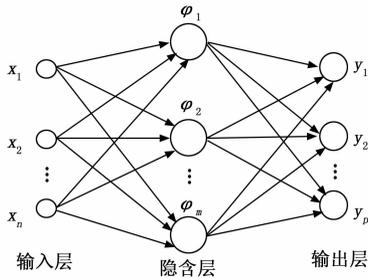


图 4 RBF 神经网络

$$h_j(x) = \exp\left(-\frac{\|x - \varphi_j\|^2}{2\sigma_j^2}\right) \quad (1)$$

式 (1) 中, $h_j(x)$ 为径向基函数; $\|\cdot\|$ 为欧式范数; φ_j 为径向基函数的中心向量, $\varphi_j = (\varphi_{j1}, \varphi_{j2}, \dots, \varphi_{jm})^T$; σ_j 为第 j 个基函数的扩展宽度。

输出层的第 k 个节点的输出为:

$$y_k(x) = \sum_{i=1}^m \omega_{ki} h_i(x) + \omega_{k0} \quad (2)$$

式 (2) 中, ω_{ki} 为隐含层中第 i 个节点到输出层的第 k 个节点的连接权重; ω_{k0} 为输出层第 k 个节点的偏差项。

输出层的第 k 个节点的误差函数为:

$$E_k = \frac{1}{2} (y_k(x) - y_{d,k})^2 \quad (3)$$

式 (3) 中, $y_{d,k}$ 为节点 k 的期望输出。

RBF 神经网络的总误差函数为:

$$E = \sum_{k=1}^m E_k \quad (4)$$

在 RBF 神经网络中, 基函数的宽度初始值和隐含层中心节点两个参数对网络的收敛速度具有较大的影响^[17], 为了提高 RBF 神经网络的收敛速度, 采用聚类算法来确定这两个参数, 将聚类算法得到的聚类中心 $\mu_j (j = 1, 2, \dots, m)$ 作为径向基函数的中心 μ ^[18], 则径向基宽度的计算公式为:

$$\sigma_1 = \sigma_2 = \dots = \sigma_m = \frac{d_{\max}}{\sqrt{2m}} \quad (5)$$

式 (5) 中, d_{\max} 为所有中心的最大距离。

本文计算 RBF 神经网络的权重参数的方法为最小二乘法^[19], 将式 (2) 转换成矩阵形式:

$$Y = HW \quad (6)$$

$$H = \begin{bmatrix} 1 & h_{11} & h_{12} & \dots & h_{1m} \\ 1 & h_{21} & h_{22} & \dots & h_{2m} \\ \vdots & \vdots & \vdots & & \vdots \\ 1 & h_{p1} & h_{p2} & \dots & h_{pm} \end{bmatrix} \quad (7)$$

$$w = (\omega_1, \omega_2, \dots, \omega_m)^T \quad (8)$$

采用矩阵 H 的伪逆 $H^* = (H^T H)^{-1} H^T$ 可以求得:

$$w = H^* Y \quad (9)$$

采用聚类算法计算 RBF 神经网络中的径向基函数的中心和宽度的最大优势在于可以提前求出, 不必在 RBF 训练完成后再进行求解, 训练时只需求出隐含层输出矩阵的伪逆 φ' , 然后根据式 (9) 计算出输出层和隐含层的权重即可^[20]。

本研究采用的聚类算法为 K-means 算法, 由于 K-means 算法的聚类中心难以确定, 导致参数的计算不准确, 同时宽度的计算为考虑数据的分布, 因此提出基于 KL 散度的 K-means 算法来计算径向基函数的中心和宽度^[21]。

3.2 基于 KL 散度的 K-means 算法

假设数据的真实概率分布为 X , 理论分布为 Y , 根据 KL 散度, 则有^[22]:

$$D(X \| Y) = \sum X \ln(X/Y) \quad (10)$$

$$\begin{cases} X = 0, Y = 0 \text{ 时, } \ln(X/Y) = 0 \\ X = 0, Y \neq 0 \text{ 时, } \ln(X/Y) = 1 \end{cases}$$

聚类个数 k 和初始聚类中心的确定是 K-means 算法中最核心的部分^[23], 初始聚类中心的位置会影响到同一支数据点的平均距离 d , k 与 d 的关系如图 5 所示。

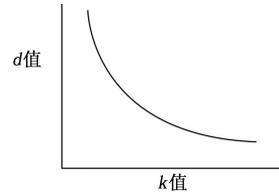


图 5 k 值与 d 值关系图

从图中可以看出, 当 k 值较小的时候, 数据的平均距离 d 会非常大, 而随着 k 值的不断增大, d 值会随之减小, 最后趋于平稳。

基于上述描述, 对如何利用 KL 散度来确定聚类个数加以说明, 主要步骤为:

1) 在无法确定聚类个数 k 时, 可以随机取值 1, 2, 4, 5, 7, …, 然后通过 K-means 计算每个 k 值对应的 d 值。

2) d 值的变化趋势计算:

$$\Delta_m = (d_{m-1} - d_m) / 2^{m-1} \quad (11)$$

3) 根据步骤的 (2) 的结果, 可以确定 d 值变化率变化最快的区间, 就可以确定 k 值的范围^[12]:

$$k \in [2^{m-2}, 2^m] \quad (12)$$

4) 根据 2 分法可以缩小区间, 最终可以求得 K 值^[13]。

数据密度分析法是确定初始聚类中心问题上最常用的方法^[24], 本研究采用 KL 散度来进行数据密度分析。

当某一数据同时满足数据密度较大、与其他数据较小两个条件, 就可以将其作为初始聚类中心。

基于 KL 散度和数据密度分析的初始聚类中心确定步骤:

1) 设 $x_1, x_2 \dots x_n$ 为对象集合 M 里的元素, 根据式 (10) 可以得出第 i 个对象对第 j 个对象的 KL 散度:

$$d_{ij} = d_{kl}(x_i \| x_j) = \sum x_i \ln(x_i/x_j) \quad (13)$$

式中, d_{ij} 为差异值矩阵 D 中的元素。

2) 将差异值矩阵 D 中的元素按从小到大排序, 然后分别计算每个行元素到其他行元素之间的平均距离:

$$\bar{d}_i = \sum_{j=1}^n d_{ij} / n \quad (14)$$

3) 将矩阵 D 第 i 行中与 x_i 距离大于 $\bar{d}_i/2$ 的元素剔除, 然后根据式 (9) 计算其他元素到 x_i 的平均距离 \tilde{d}_i , 根据

计算结果统计距离小于 \tilde{d}_i 的元素个数 n_i ，求得密度：

$$den_i = n_i/d_i^2 \quad (15)$$

4) 将所有的元素密度值 den_i 进行比较比较，其中最大的为第一个中心点。

5) 根据 den_i 的大小将 x_i 按从大到小排序，然后按照排序结果依次处理其他元素，直到选取了 k 个中心点。

6) 如果最后选取的中心点数量过少，是因为密度选取的较大，可以适当的减小密度，重新进行选取，直至选取到合适数量的初始聚类中心。

3.3 RBF 径向基函数宽度的计算

径向基函数宽度的选择应该考虑到每个聚类中心的距离以及样本数据的分布密度^[25]，基于此，引入距离基数概念，距离基数为每个聚类中心与其他聚类中心距离的平均值，用 $meanD$ 来表示距离基数，则距离基数的计算公式为：

$$meanD(\mu_i) = \frac{\sum_{j \neq i} dist(\mu_i, \mu_j)}{k-1} \quad (16)$$

样本数据的分布密度可以用方差来表示，根据聚类结果，可以计算每个聚类的方差：

$$S_i = \frac{1}{size(C_i)} \sum_{x \in C_i} dist(x, \mu_i)^2 \quad (17)$$

式 (17) 中， S_i 为聚类方差； $size(C_i)$ 为聚类中心 μ_i 的样本数； $dist(x, \mu_i)$ 为欧式距离。

根据式 (17)，可以求得该中心宽度的缩放因子 ϵ_i ：

$$\epsilon_i = \frac{S_i}{\frac{1}{k} \sum_{i=1}^k S_i} \quad (18)$$

可以得到每个中心的宽度：

$$\sigma_i = \epsilon_i \cdot meanD(\mu_i) \quad (19)$$

3.4 参数优化的 RBF 神经网络算法

基于上述描述，得到的参数优化 RBF 神经网络算法的步骤为：

1) 采用基于 KL 散度的 K-means 算法求得 RBF 神经网络隐含层节点的 k 个聚类中心。

2) 根据式 (16) 求得每个聚类的距离基数。

3) 根据式 (17) 求得每个聚类的方差。

4) 根据式 (18) 求得该中心宽度的缩放因子。

5) 根据式 (19) 计算该核函数的宽度，进而求得 RBF 神经网络中对应中心的宽度。

6) 根据求得的中心和宽度，采用最小二乘法计算隐含层与输出层之间的连接权重，然后进行模型训练。

4 仿真分析

采用 Matlab 软件对上述的改进 K-means 算法和优化后的 RBF 算法进行仿真以验证其性能，使用的计算系统为 Windows10 64 位，计算机 CPU 为 Inter Corei7-9700f，硬盘大小为 500 G，运行内存为 DDR4 3200 MHz 16 G。

4.1 基于 KL 散度的 K-means 算法仿真

采用经典 K-means 算法与基于 KL 散度的 K-means 算法 (KL-K-means) 进行对比试验来验证基于 KL 散度

的 K-means 算法的性能，用平方误差 (E) 来评价分类的准确度，平方误差的计算公式为：

$$E = \sum_{i=1}^k \sum_{p \in C_i} dist(p, \mu_i)^2 \quad (20)$$

式 (20) 中， μ_i 为聚类中心； p 为进行试验的数据对象。

选取 UCI 开源的数据集作为试验样本数据，采用上述两种聚类算法分别进行 10 次聚类，根据式 (20) 计算两种算法的平方误差，为了直观的表现两种算法的平方误差差距，采用直方图的形式表现，如图 6 所示。

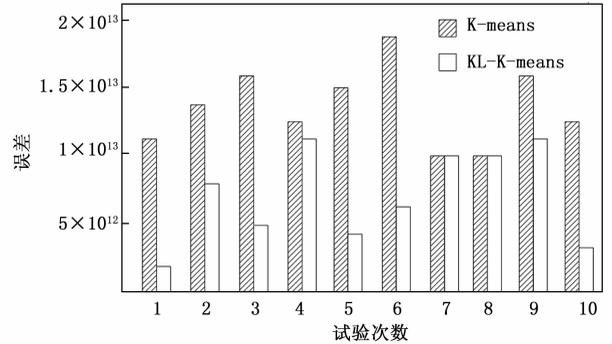


图 6 两种算法的误差对比

根据图 6 可以看出，经典 K-means 算法的平方误差的数量级大多为 10^{-13} ，KL-K-means 算法的平方误差的数量级大多为 10^{-12} ，可以得到 KL-K-means 算法的聚类误差小于传统的 K-means 算法，即分类的准确率高于传统的 K-means 算法。

4.2 参数优化的 RBF 算法仿真

选取发动机涡轮叶片作为电磁无损检测技术的检测对象，将 FPGA 中信号采集到的模拟信号转化成数字信号，采用传统的 RBF 算法和参数优化后的 RBF 算法进行对比试验来验证参数优化后的 RBF 算法的性能，依旧在上述计算机中进行仿真。

选取两个性能不同的发动机涡轮叶片作为检测对象，它们的性能数据如表 1 所示。

表 1 3 种涡轮叶片的性能数据

项目	表面硬度/HB	表面光洁度	缺陷长度/mm
涡轮叶片 1	80	Ra3.2	1.02
涡轮叶片 2	82	Ra3.2	0.68
涡轮叶片 3	85	Ra3.2	0.95

采用上述两种算法对表 1 中的 3 种涡轮叶片的缺陷长度进行预测，记录预测的数据，可以得到表 2 的预测对比数据。

表 2 两种算法的缺陷预测对比

项目	缺陷长度真实值/mm	RBF 预测值/mm	参数优化后的 RBF 预测值/mm
涡轮叶片 1	1.02	1.35	1.13
涡轮叶片 2	0.68	0.85	0.72
涡轮叶片 3	0.95	0.71	0.83

从表 2 中可以看出, 参数优化后的 RBF 算法的预测结果更接近真实值, 但是由于试验的样本数据较少, 说服力不足, 采用上述两种算法对涡轮叶片 1 进行 100 次预测, 记录数据, 可以得到图 7 的预测结果变化图。

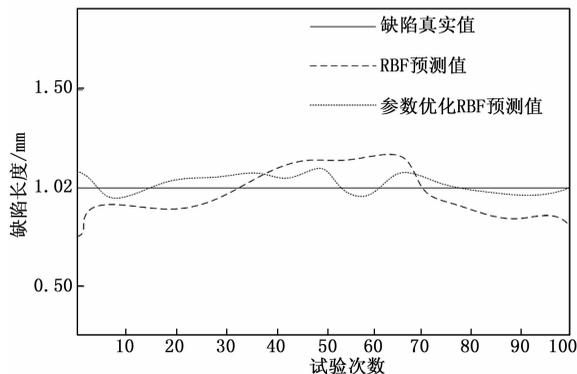


图 7 两种算法的 100 次缺陷预测值

从图中可以看出, 虽然两者的预测结果都会有起伏, 但是与缺陷真实值相比, 参数优化后的 RBF 算法的预测结果相比传统的 RBF 算法差距更小, 即更接近真实值, 说明预测的结果更准确。

5 结束语

本文针对电磁超声波的处理分析问题, 提出了一种参数优化的 RBF 神经网络, 并在 FPGA 上通过编程实现, 并得出以下结论:

(1) FPGA 是一种用途广泛的大规模可编程器件, 能够实现电磁超声波的采集、放大与分析。

(2) 径向基函数的中心和宽度两个参数对 RBF 神经网络的影响较大, 采用聚类算法来计算这两个参数的效果较好。

(3) K-means 算法的聚类中心难以确定, 引入 KL 散度, 采用数据密度分析法能够解决问题。

通过试验和仿真验证了上述算法的可行性, 在电磁无损检测领域具有一定的应用前景, 但是由于试验的不足, 在后续的研究中需要进一步的改进和完善。

参考文献:

[1] 崔 闪, 彭道刚, 钱玉良. 基于 ACFOA 优化 RBF 的短期风电功率预测 [J]. 可再生能源, 2017, 35 (1): 80-85.

[2] 孙 倩, 赵 昕. 粒子群优化 RBF 神经网络的 DNA 序列分类 [J]. 现代电子技术, 2020, 43 (9): 87-91.

[3] 范 伟, 李 兵, 陈冰华, 等. 钢丝绳应力集中和疲劳损伤的电磁无损检测技术分析 [J]. 机电信息, 2020 (12): 144-147.

[4] 常 琳. 基于电磁法的无损检测技术在矿用钢丝绳检测中的应用 [J]. 煤矿机械, 2020, 41 (1): 154-156.

[5] 何鑫业, 胡龙年, 张中利. 基于 GMR 的电磁无损检测探究 [J]. 低碳世界, 2019, 9 (5): 103-104.

[6] 赵金浩, 赵 倩, 徐寒扬, 等. 基于电磁检测技术的 CFRP 无损探伤系统 [J]. 电子技术, 2018, 47 (11): 98-101.

[7] 陈金忠, 沈功田, 郑 阳, 等. 材料损伤电磁无损检测与评估新技术研究 [J]. 中国特种设备安全, 2018, 34 (2): 1-4.

[8] 刘丽辉, 谢瑞芳, 陈棣湘, 等. 基于 ARM 和 FPGA 的双核电磁无损检测系统 [J]. 中国测试, 2016, 42 (1): 65-68.

[9] 信鹏皓, 杨连雯, 白庭宇. 基于电磁超声的核电厂在役检测技术的分析与展望 [J]. 设备管理与维修, 2015 (11): 94-96.

[10] 师俊杰, 邵季飞, 石家铭. 电磁无损检测技术在电力生产中的应用 [J]. 科技资讯, 2015, 13 (20): 63.

[11] 张泽芳, 任勇峰, 何常德. 基于 CMUT 的超声波信号检测及放大电路设计 [J]. 仪表技术与传感器, 2020 (2): 37-40.

[12] 周 杨, 陆云峰, 李会银. 基于 FPGA 的超声波成像测井分析系统研究 [J]. 电子测量技术, 2015, 38 (3): 65-71.

[13] 徐方明, 夏 洲, 朱 浩, 等. 基于 FPGA 的多声路超声波流量计设计与实现 [J]. 水电自动化与大坝监测, 2014, 38 (2): 25-27.

[14] 刘晓宇, 杨 江. 时间比例放大技术在超声波流量计中的应用 [J]. 传感技术学报, 2007 (2): 454-457.

[15] 石志超. 超声波探伤仪中放大电路的设计 [J]. 电子制作, 2016 (13): 19.

[16] 王 婷, 李国勇, 吕世轩. 基于 HPSO-RBF 神经网络的瓦斯传感器故障诊断 [J]. 仪表技术与传感器, 2015 (3): 78-81.

[17] 黄 波, 丁 浩, 张孝芳, 等. 基于 RBF 神经网络的某复杂装备故障预测方法 [J]. 计算机仿真, 2014, 31 (1): 14-17.

[18] 潘海洋, 杨 宇, 郑近德, 等. 基于径向基函数的变量预测模型模式识别方法 [J]. 航空动力学报, 2017, 32 (2): 500-506.

[19] 彭彬彬, 闫献国, 杜 娟. 基于 BP 和 RBF 神经网络的质量预测研究 [J]. 表面技术, 2020, 49 (10): 324-328.

[20] 邵庆祝, 谢 民, 王同文, 等. 基于 CPSO 优化的 RBF 神经网络的电网故障诊断 [J]. 电气自动化, 2020, 42 (5): 48-50.

[21] 杨建华, 肖达强, 张 伟, 等. 基于改进 PSO 优化的 RBF 神经网络的特高压线损预测 [J]. 广东电力, 2020, 33 (9): 85-91.

[22] LIAO W, WEI X H, LAI J Z, et al. Formation control for multi-UAVs systems based on Kullback-Leibler divergence [J]. Transactions of the Institute of Measurement and Control, 2020, 42 (3): 598-603.

[23] MENG X Y, LIU M Y, QIAO A L, et al. Fuzzy Interval Number K-Means Clustering for Region Division of Pork Market [J]. International Journal of Decision Support System Tehnology, 2020, 12 (3): 43-61.

[24] 高 西, 胡子牧. 基于改进 k-means 算法的数字图像聚类 [J]. 液晶与显示, 2020, 35 (2): 173-179.

[25] 黄 昊, 胡永峰. 基于采样点局部密度的径向基函数核宽度确定方法及其在装备设计中的应用范例 [J]. 军事运筹与系统工程, 2016, 30 (4): 58-64.