

基于 Kohonen 网络对万向接轴裂纹的诊断

姚志宏<sup>1</sup>, 戴琳<sup>2</sup>

(1. 南京师范大学 电气与电子工程学院, 江苏 南京 210042; 2. 南京师范大学 物理科学与技术学院, 江苏 南京 210097)

[摘要] 利用神经网络中的 Kohonen 网络聚类的特点,把轧钢机万向接轴裂纹故障不同的关联度作为 Kohonen 网络的训练样本输入到 Kohonen 网络,并由网络进行学习和聚类. 由于裂纹深度不同,裂纹故障的关联度不同,于是网络便产生不同的聚类中心点. 根据不同的聚类中心,可以很明确地诊断万向接轴裂纹的故障程度.

[关键词] Kohonen 网络,裂纹故障,训练样本,聚类中心,关联度,万向接轴

[中图分类号] TP183, [文献标识码] B, [文章编号] 1672-1292-(2004) 03-0073-03

1 原理

轧钢机万向接轴裂纹故障用时序法诊断的实验数据如表 1 所示.

表 1 万向接轴裂纹时序法诊断数据

裂纹故障	$\frac{2}{a}$	$\mu$
$X_{t1}$ (完好轴)	0.708 02	1.483 89
$X_{t1}$ (d/9 深裂纹)	0.007 051 6	0.086 712 6
$X_{t2}$ (d/5 深裂纹)	0.017 94	0.087 491 5
$X_{t3}$ (2d/5 深裂纹)	0.012 663	0.052 9
$X_{t4}$ (d/2 深裂纹)	0.013 977	0.115 947
$X_{t5}$ (3d/5 深裂纹)	0.017 245	0.109 061

注:  $d$  为轴直径;  $\frac{2}{a}$  为模型的残差方差;  $\mu$  为时序数据的均值.

在灰色关联度分析中,残差模型即第  $l$  时刻预测值与原始累加值之差称为  $l$  时刻的残差. 另外关联度是事物之间、因素之关联度的“量度”,其基本思路是从随机性的时间序列找到关联性和关联性的量度,以便为因素分析、预测的精度分析提供依据,因而关联度分析可以用来进行故障诊断. 关联度是由关联系数演变而来的,记  $X_i$  对  $X_j$  的关联系数为  $ij(tl)$ ,表示  $X_i$  与  $X_j$  比较关联性的采样点,记:

$$ij(tl) = |X_j(tl) - X_i(tl)| \quad tl \in \{1, 2, \dots, N\}$$
 (1)

$$\min = \min_j \min_{tl} ij(tl) \quad \max = \max_j \max_{tl} ij(tl)$$

在定义  $ij(tl)$  为:

$$ij(tl) = \frac{\min + \max * k}{ij(tl) + \max * k} \quad tl \in \{1, 2, \dots, N\}$$
 (2)

其中  $k$  为取定的常数,  $k \in \{0, 1\}$ .

$X_i$  与  $X_j$  的关联度  $ij$  为:

$$ij = \frac{1}{N-1} * \frac{1}{2} \left[ \sum_{tl=1}^N ij(tl) + \sum_{tl=2}^{N-2} ij(tl) \right]$$
 (3)

关联度  $ij$  的大小反映  $X_i$  与  $X_j$  的关联程度. 利用  $ij$  的大小,可以对系统故障模式进行识别.

对 5 种故障状态计算出的关联度如下(其中  $\min = 0$ ):

$$\begin{aligned} i1r1 &= 0.546\ 4 & i1r2 &= 0.734 \\ i2r1 &= 0.550\ 5 & i2r2 &= 0.866 \\ i3r1 &= 0.550\ 8 & i3r2 &= 0.666 \\ i4r1 &= 0.551\ 8 & i4r2 &= 0.786 \\ i5r1 &= 0.554\ 1 & i5r2 &= 0.696 \end{aligned}$$

显然,单凭这些关联度来确切诊断裂纹故障和故障程度不十分理想. 为了达到确切诊断万向接轴裂纹故障的目的,可把这些关联度作为 Kohonen 网络的样本输入并由网络进行学习和聚类,产生 Kohonen 网络的聚类中心点. 根据这些聚类中心来确认和诊断万向接轴裂纹的严重程度.

2 Kohonen 网络的结构以及自组织学习过程

Kohonen 网络的结构如图 1 所示.




图 1 Kohonen 网络的结构

网络的学习及工作规则:

收稿日期: 2004-03-10.  
作者简介: 姚志宏(1946 - ), 副教授, 主要从事电工电子学及人工神经网络的教学与研究. E-mail: yaozhihong4607@njnu.edu.cn

(1) 初始化将网络的连接权  $\{w_{ij}\}$  赋予  $[0,1]$  区间的随机值,  $i = 1, 2, \dots, N; j = 1, 2, \dots, M$ . 确定学习率  $(t)$  的初始值  $(0)$  ( $0 < (0) < 1$ ); 确定邻域  $N_g(t)$  的初始值  $N_g(0)$ , 邻域  $N_g(t)$  是指以步骤(4) 确定的获胜神经元  $g$  为中心, 且包含若干神经元的区域范围. 这个区域一般是均匀对称的, 最典型的是正方形或圆形区域, 如图 2 所示.  $N_g(t)$  的值表示在第  $t$  次学习过程中邻域中所包含的神经元个数; 确定总的学习次数  $T$ .




图 2 Kohonen 网络神经元

(2) 任选  $q$  个学习模式中的一个模式  $p_k$  提供给网络的输入层, 并进行归一化处理.

$$\bar{P}_k = \frac{P_k}{P_k} = \frac{(p_1^k, p_2^k, \dots, p_n^k)}{[(p_1^k)^2 + (p_2^k)^2 + \dots + (p_n^k)^2]^{\frac{1}{2}}} \quad (4)$$

(3) 对连接权  $w_j = (w_{j1}, w_{j2}, \dots, w_{jn})$  进行归一化处理, 计算  $\bar{w}_j$  与  $\bar{P}_k$  之间的欧氏距离:

$$\bar{w}_j = \frac{w_j}{w_j} = \frac{(w_{j1}, w_{j2}, \dots, w_{jn})}{[(w_{j1})^2 + (w_{j2})^2 + \dots + (w_{jn})^2]^{\frac{1}{2}}}$$
$$d_j = \left[ \sum_{i=1}^N (\bar{p}_i^k - \bar{w}_{ji})^2 \right]^{\frac{1}{2}} \quad j = 1, 2, \dots, M$$

(4) 找出最小距离  $d_g$ , 确定获胜神经元  $g$ :

$$d_g = \min[d_j] \quad j = 1, 2, \dots, M$$

(5) 进行连接权的调整, 对竞争层邻域  $N_g(t)$  内所有神经元与输入层神经元之间的神经元进行修正:

$$w_{ji}(t+1) = \bar{w}_{ji}(t) + (t) \cdot [\bar{p}_i^k - \bar{w}_{ji}(t)]$$

$j \in N_g(t), j = 1, 2, \dots, M$  ( $0 < (t) < 1$ ) (6)

其中  $(t)$  为  $t$  时刻的学习率.

(6) 选取另一学习模式提供给网络的输入层, 返回步骤(3), 直至  $g$  个学习模式全部提供给网络.

(7) 更新学习率  $(t)$  及邻域  $N_g(t)$ :

$$(t) = (0) \left( 1 - \frac{t}{T} \right) \quad (7)$$

其中  $(0)$  为初始学习率,  $t$  为学习次数,  $T$  为总的

学习次数.

设竞争层某神经元  $g$  在二维阵列中的坐标值为  $(x_g, y_g)$ , 则邻域的范围是以点  $((x_g + N_g(t), y_g + N_g(t))$  和点  $((x_g - N_g(t), y_g - N_g(t))$  为右上角和左下角的正方形, 其修正公式为;

$$N_g(t) = \text{INT} \left[ N_g(0) \left( 1 - \frac{t}{T} \right) \right] \quad (8)$$

式中  $\text{INT}[x]$  为取整符号,  $N_g(0)$  为  $N_g(t)$  的初始值.

(8) 令  $t = t + 1$  返回步骤(2) 直至  $t = T$  为止.

Kohonen 网络的自组织学习过程是对于每一个网络的输入, 只调整一部分权值, 使权向量更接近或更偏离输入矢量, 这一调整过程就是竞争学习的过程. 随着不断学习, 所有权矢量都在输入矢量空间相互分离, 形成了各自代表输入空间的一类模式. 这就是 Kohonen 网络的特征自动识别的聚类功能.

3 Kohonen 网络诊断的流程

Kohonen 网络流程如图 3 所示. 把原始样本扩大 100 倍, 网络的样本输入为: [54.64 55.05 55.08 55.18 55.41; 73.4 86.6 66.6 78.6 69.6].

Kohonen 网络定义聚类中心的范围:  $X = [54.5 \ 55.5; 68.0 \ 86.0]$ ; 聚类中心的个数: clusters = 8; 每个聚类的数据点个数: points = 20; 每个聚类的标准偏差: std. dev = 0.02.

网络的初始化用 MATLAB 神经网络工具箱中的 init 函数. 网络竞争层用 newc 函数, 网络的训练用 train 函数, 网络仿真用 simuc 函数, 网络的聚类中心用符号“o”表示, 聚类的输入样本用符号“+”表示. 网络的最大训练步数为 100, 流程如图 3 所示.

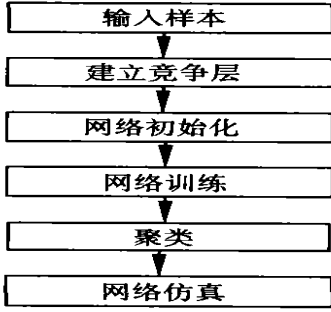


图 3 kohonen 网络诊断流程图

4 Kohonen 网络聚类和仿真诊断

经过 Kohonen 网络聚类后, 聚类中心点不在一

处,由网络仿真可以知道各种裂纹故障的聚类中心是完全不同的.例如  $X_{i3}$  (2 d/ 5 深裂纹) 的聚类中心是 1,其它的聚类中心分别是 3,2,4,8. 这样可以根据不同的聚类中心来诊断各种裂纹故障. Kohonen 网络聚类如图 4 所示.




图 4 Kohonen 网络聚类

仿真诊断的结果如表 2 所示.

表 2 诊断结果

裂纹故障	仿真诊断的结果
$X_{i1}$ ( d/ 9 深裂纹)	(3,1) 1
$X_{i2}$ ( d/ 5 深裂纹)	(2,1) 1
$X_{i3}$ (2 d/ 5 深裂纹)	(1,1) 1
$X_{i4}$ ( d/ 2 深裂纹)	(4,1) 1
$X_{i5}$ (3 d/ 5 深裂纹)	(8,1) 1

只要输入相应的关联度,通过神经网络的仿真便可以知道样本的 Kohonen 网络聚类中心,即可以知道裂纹故障的程度. 这种办法比较可靠和准确,也比较直观.

[参考文献]

[1] 虞和济,陈长征. 基于神经网络的智能诊断[M]. 北京:冶金工业出版社,2000. 57 ~ 66.  
[2] 闻新. MATLAB 神经网络应用设计[M]. 北京:科学出版社,2000. 165 ~ 182.

Crack Diagnosis of Universal Coupling Based on Kohonen Network

YAO Zhihong<sup>1</sup>, DAI Lin<sup>2</sup>

(1. School of Electrical and Electronic Engineering, Nanjing Normal University, Nanjing 210042, China;  
2. School of Physical Science and Technology, Nanjing Normal University, Nanjing 210097, China)

**Abstract:** With the Kohonen network clustering in neural network employed, the degree of relationship of the universal joint axle of the rolling mill was input to Kohonen network as the training sample, studied and clustered by the network to generate different clustering centers according to the different depth and different degree of relationship among the cracks. Based on the clustering centers and simulating, the cracks in the universal joint axle can be diagnosed.

**Key words:** Kohonen network, crack, training sample, clustering center, degree of relationship, universal joint axle

[责任编辑:刘健]