



(12) 发明专利

(10) 授权公告号 CN 111814108 B

(45) 授权公告日 2024. 04. 12

(21) 申请号 202010025573.5

(22) 申请日 2020.01.10

(65) 同一申请的已公布的文献号

申请公布号 CN 111814108 A

(43) 申请公布日 2020.10.23

(73) 专利权人 北京航天测控技术有限公司

地址 100041 北京市石景山区实兴东街3号

(72) 发明人 毛鹏飞 解梦迪 贾凡

(74) 专利代理机构 北京理工大学专利中心

11120

专利代理人 李爱英 付雷杰

(51) Int. Cl.

G06F 17/18 (2006.01)

G06N 3/047 (2023.01)

G06N 3/08 (2023.01)

(56) 对比文件

CN 102073318 A, 2011.05.25

CN 108520301 A, 2018.09.11

CN 109765054 A, 2019.05.17

CN 109871862 A, 2019.06.11

EP 2472440 A1, 2012.07.04

US 2019243735 A1, 2019.08.08

WO 2015158198 A1, 2015.10.22

吕建丰. 基于SOM神经网络的柴油机故障诊断. 科学技术创新. 2019, (35), 全文.

邓冠前; 邱静; 李智; 颜宁. 间歇故障诊断技术研究综述. 兵工自动化. 2015, (01), 全文.

审查员 刘天晓


权利要求书1页 说明书4页 附图2页

(54) 发明名称

一种基于自组织神经网络的连接型间歇故障诊断方法

(57) 摘要

本发明公开了一种基于自组织神经网络的连接型间歇故障诊断方法, 该方法包括: 步骤1、提取全要素特征参数; 所述的全要素特征参数包括测试信号特征参数和外部环境特征参数; 步骤2、模型学习训练; 所述的学习训练过程为: 初始化、归一化处理、计算欧式距离、确定最小距离、调整连接权和更新学习速率和邻域; 步骤3、故障诊断; 通过对正常态、间歇态、故障态的样本进行学习训练, 得到多种分类结果的神经网络权重矢量; 通过对标准样本的状态的严重程度的计算, 对分类后的结果进行状态标记; 将测试的样本输入到模型中, 通过SOFM神经网络诊断的类别, 得到测试样本的状态, 从而得到测试样本的间歇故障诊断结果。



1. 一种基于自组织神经网络的连接型间歇故障诊断方法,其特征在于,所述方法包括以下步骤:

步骤1、提取全要素特征参数;所述的全要素特征参数包括测试信号特征参数和外部环境特征参数;

步骤2、模型学习训练;所述的学习训练过程为:初始化、归一化处理、计算欧式距离、确定最小距离、调整连接权和更新学习速率和邻域;

步骤3、故障诊断;通过对正常态、间歇态、故障态的样本进行学习训练,得到多种分类结果的神经网络权重矢量;通过对标准样本的状态的严重程度的计算,对分类后的结果进行状态标记;将测试的样本输入到模型中,通过SOFM神经网络诊断的类别,得到测试样本的状态,从而得到测试样本的间歇故障诊断结果;

所述测试信号特征参数包括:信号中断总时间 T 、信号中断最大幅度 F 、信号中断幅度0-20%的时间 T_1 、信号中断幅度20%-40%的时间 T_2 、信号中断幅度40%-60%的时间 T_3 、信号中断幅度60%-80%的时间 T_4 和信号中断幅度80%-100%的时间 T_5 ;所述的外部环境特征参数包括:温度条件 W 、振动条件 Z 和应力作用时间 T_y 。

一种基于自组织神经网络的连接型间歇故障诊断方法

技术领域

[0001] 本发明属于故障诊断技术领域,具体涉及一种基于自组织神经网络的连接型间歇故障诊断方法。

背景技术

[0002] 一般将间歇故障细分为三种类型,工程型(engineering)、测试无效型(test void)和连接型(connection),在设备寿命的晚期(交付使用的后期),连接型间歇故障开始大量涌现,主要原因是设备在使用中,受到的外部温度和振动应力的影响随时间推移越来越大,导致设备中连接型部分更容易出现接触不良或者焊点破裂的情况。间歇故障在设备使用中出现后,做地面检测时不一定能复现,主要的原因有两个,第一个是此种间歇性故障通常需要施加一定应力条件才能检测到;第二个是即使施加一定的应力条件,间歇性故障仍然是一个随机出现的故障。电子设备连接型间歇故障主要包括接触不良和焊点破裂等2类,现有技术中对间歇故障的测试还缺乏有效手段,主要的研究方法是采用隐马尔科夫(HMM)模型建模方法,存在以下缺点:

[0003] 1、隐马尔科夫(HMM)模型主要基于统计和概率转移矩阵的方式,是对随机过程的发生的统计描述,无法体现间歇故障特征,不具备适应能力;

[0004] 2、间歇故障的产生与外界环境有明显的关系,隐马尔科夫(HMM)模型无法反应外界环境,如应力条件、温度等,因而模型不能够广泛使用。

发明内容

[0005] 为解决上述问题,本发明提出了一种基于自组织SOFM(self-organizing Feature Map)神经网络的连接型间歇故障诊断方法,该方法包括以下步骤:

[0006] 步骤1、提取全要素特征参数;所述的全要素特征参数包括测试信号特征参数和外部环境特征参数;

[0007] 步骤2、模型学习训练;所述的学习训练过程为:初始化、归一化处理、计算欧式距离、确定最小距离、调整连接权和更新学习速率和邻域;

[0008] 步骤3、故障诊断;通过对正常态、间歇态、故障态的样本进行学习训练,得到多种分类结果的神经网络权重矢量;通过对标准样本的状态的严重程度的计算,对分类后的结果进行状态标记;将测试的样本输入到模型中,通过SOFM神经网络诊断的类别,得到测试样本的状态,从而得到测试样本的间歇故障诊断结果。

[0009] 所述测试信号特征参数包括:信号中断总时间T、信号中断最大幅度F、信号中断幅度0-20%的时间T1、信号中断幅度20%-40%的时间T2、信号中断幅度40%-60%的时间T3、信号中断幅度60%-80%的时间T4和信号中断幅度80%-100%的时间T5;所述的外部环境特征参数包括:温度条件W、振动条件Z和应力作用时间Ty。

[0010] 本发明有益效果如下:

[0011] 本发明可以更加准确的反应间歇故障与外界应力的关系,提升间歇故障诊断的准

确性和适应性,提高间歇故障的故障检测能力。

附图说明

- [0012] 图1是本发明实施例中一种全要素特征的神经网络诊断架构图;
 [0013] 图2是本发明实施例中一种自组织神经网络的权重向量图;
 [0014] 图3是本发明实施例中一种自组织神经网络2×3类输出图;
 [0015] 图4是本发明实施例中一种自组织神经网络3×4类输出图。

具体实施方式

[0016] 下面结合附图并举实施例,对本发明进行详细描述。

[0017] 如图1所示,全要素特征参数提取,包括测试信号特征参数和外部环境特征参数;所述的测试信号特征参数包括:信号中断总时间T、信号中断最大幅度F、信号中断幅度0-20%的时间T1、信号中断幅度20%-40%的时间T2、信号中断幅度40%-60%的时间T3、信号中断幅度60%-80%的时间T4和信号中断幅度80%-100%的时间T5;所述的外界环境特征参数包括:温度条件W、振动条件Z和应力作用时间Ty。

[0018] 所述的要素提取的具体过程为:对于输入模式X,首先确定中心神经元MC,满足 $\|X-MC\| = \min\{\|x_i - M_i\|\}$,然后对以MC为中心的周围的神元元的权向量按下式进行调整,

$$[0019] \quad M_i(k+1) = \begin{cases} M_i(k) + a(k)[X - M_i(k)], & i \in N_g(k) \\ M_i(k), & i \notin N_g(k) \end{cases} \quad (3-4)$$

[0020] 其中Ng表示由以MC为中心的周围神经元组成的领域,在学习中,Ng(k)的初始值可选大一些,然后逐步收缩,通常学习系数a(k)在初始时可取接近于1.0的常数,然后逐渐变小。

[0021] 设网络的输入模式为 $P_k = (P_1^k, P_2^k, \dots, P_N^k)$, $k = 1, 2, \dots, q$ 。竞争层神经元矢量为 $A_j = (a_{j1}, a_{j2}, \dots, a_{jm})$, $j = 1, 2, \dots, m$, 其中, P_k 为连接值, A_j 为数字量,竞争层神经元j与输入层神经元之间的连接权矢量为

$$[0022] \quad W_j = (w_{j1}, w_{j2}, \dots, w_{jn}), i = 1, 2, \dots, N; j = 1, 2, \dots, M;$$

[0023] 所述的学习训练过程为:

[0024] (1) 初始化;将网络的连接权 $\{w_{ij}\}$ 赋予 $[0, 1]$ 区间内的随机值, $i = 1, 2, \dots, N; j = 1, 2, \dots, M$;确定学习速率 $\eta(0)$ 的初始值 $\eta(0)$, $(0 < \eta(0) < 1)$;确定邻域Ng(t)的初始值Ng(0);邻域Ng(t)是指步骤(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;Ng(t)的值表示在第t次学习过程中邻域中所包含的神经元的个数;确定总的学习次数T;

[0025] (2) 任选q个学习模式中的一个模式 P_k 提供网络的输入层,并进行归一化处理;

$$[0026] \quad \bar{P}_k = \frac{P_k}{\|P_k\|} = \frac{(P_1^k, P_2^k, \dots, P_N^k)}{[(P_1^k)^2 + (P_2^k)^2 + \dots + (P_N^k)^2]^{1/2}} \quad (3-5)$$

[0027] (3) 对连接权矢量 $W_j = (w_{j1}, w_{j2}, \dots, w_{jn})$ 进行归一化处理,计算 \bar{W}_j 与 \bar{P}_k 之间的欧氏

$$\text{距离: } \bar{W}_j = \frac{w_j}{\|w_j\|} = \frac{(w_{j1}, w_{j2}, \dots, w_{jn})}{[(w_{j1})^2 + (w_{j2})^2 + \dots + (w_{jn})^2]^{1/2}} \quad (3-6)$$

$$[0028] \quad d_j = [\sum_{i=1}^N (\overline{p_i^k} - \overline{w_{j\mu}})^2]^{1/2}, j = 1, 2, \dots, M \quad (3-7)$$

[0029] (4) 找出最小距离 d_g , 确定获胜神经元 g ;

[0030] (5) 进行连接权的调整; 对竞争层邻域 $N_g(t)$ 内的所有神经元与输入层神经元之间的连接权进行修正;

$$[0031] \quad \overline{w_{j\mu}}(t+1) = \overline{w_{j\mu}}(t) + \eta(t) \cdot [\overline{p_i^k} - \overline{w_{j\mu}}(t)] \quad (3-8)$$

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

[0032] 其中 $\eta(t)$ 为 t 时刻的学习速率;

[0033] (6) 选取另一个学习模式提供给网络的输入层, 返回步骤(3), 直至 q 个学习模式全部提供给网络;

[0034] (7) 更新学习速率 $\eta(t)$ 及邻域 $N_g(t)$;

$$[0035] \quad \eta(t) = \eta(0)(1 - \frac{t}{T}) \quad (3-9)$$

[0036] 其中 $\eta(0)$ 为初始速率, t 为学习次数, T 为总的学习次数;

[0037] 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 $(x_g - N_g(t), y_g - N_g(t))$ 为右三角和左下角的正方形, 其修正公式为:

$$[0038] \quad N_g(t) = \text{INT} \left[N_g(0) \left(1 - \frac{t}{T} \right) \right] \quad (3-10)$$

[0039] 式中 $\text{INT}[x]$ 为取整数符号, $N_g(0)$ 为 $N_g(t)$ 的初始值;

[0040] (8) 令 $t=t+1$, 返回步骤(2), 直至 $t=T$ 为止。

[0041] 所述的故障诊断, 为SOFM通过对正常态、间歇态、故障态的样本进行学习训练, 得到多种分类结果的神经网络权重矢量, 这些权重矢量和分类的数据反映出样本的统计特性; 通过对标准样本的状态的严重程度的计算, 对分类后的结果进行状态标记。将测试的样本输入到模型中, 通过SOFM神经网络诊断的类别, 得到测试样本的状态, 从而得到测试样本的间歇故障诊断结果。

[0042] 按照SOFM网络的学习规则, 将训练样本故障集中的每条记录作为一个输入模式, 分别映射到一维处理单元上, 然后定义一维网络邻域矩阵和初始权值矩阵, 最后开始训练网络。经网络训练后, 以输出为 2×3 类为例, 其训练后的特征矢量图如图2所示。

[0043] 在完成样本训练后, 输入待诊断的试验样本, 通过SOFM网络进行诊断, 6类输出和12类输出的结果分别如图3所示。图3中, 输入的试验样本同神经网络诊断为 2×3 类, 按照ZB的状态将其分为了3类, 包括正常状态、间歇状态和永久故障状态。

[0044] 图4中, 输入的试验样本同神经网络诊断为 3×4 类, 按照ZB的状态将其分为了5类, 包括正常状态、正常向间歇渐变状态、间歇状态、间歇向永久故障渐变状态和永久故障状态。

[0045] 通过比较这两种分类输出, 可以看出分类数量的增加可以一定程度上反映出ZB的间歇状态的严重程度, 很好的模拟了间歇故障的渐变特性, 通过对其的深入研究, 能够对间歇故障的状态评估和预测提供支撑。

[0046] 上述实施例仅是本发明的典型应用方式, 并非用于局限本发明的保护范围。凡在本发明的精神和原则之内, 所作的任何修改、等同替换、改进等, 均应包含在本发明的保护

范围之内。




图1




图2




图3




图4