

# 无线传感器网络多级融合的机械故障诊断方法<sup>\*</sup>

汤宝平<sup>1,2</sup>, 邓 兵<sup>2</sup>, 邓 蕾<sup>2</sup>, 颜丙生<sup>1</sup>

(1. 河南工业大学机电工程学院 郑州, 450007)

(2. 重庆大学机械传动国家重点实验室 重庆, 400030)

**摘要** 针对无线传感器网络(wireless sensor networks, 简称 WSNs)在机械故障诊断应用中大量振动信号不能实时传输的问题,提出基于无线传感器网络多级分层信息融合的机械故障诊断方法。采用簇树网络结构扩大网络监测覆盖范围,将 WSNs 信息融合分为数据级融合、特征级融合及决策级融合 3 个级别,终端节点对原始振动信息进行数据级融合以提取特征信息,簇头节点对特征信息进行特征级融合得到模式识别结果,网关节点对识别结果进行决策级融合以评估机械设备运行状态。实验表明,该方法能有效应用于机械故障诊断。

**关键词** 机械故障诊断; 无线传感器网络; 信息融合; 嵌入式信号处理

**中图分类号** TH17

## 引 言

无线传感器网络<sup>[1]</sup>具有自组织、可扩展和智能处理能力等特点<sup>[2]</sup>,适合用来构建无线、分布式机械设备状态监测与故障诊断系统<sup>[3-5]</sup>,通过在不同位置布置多个测振传感器进行振动信号监测可更好地反映设备整体运行状态。

机械故障诊断中振动信号采样频率高<sup>[6]</sup>,传感器节点获取的数据量大,若将原始振动信号直接由终端节点实时传输至网关节点,对于带宽资源有限的无线传感器网络仍是一个瓶颈<sup>[7]</sup>。Hou 等<sup>[8-9]</sup>采用星型无线传感器网络拓扑结构,基于 JN5139 传感器节点获取监测信号,在终端节点上进行信号特征提取和故障模式识别,只传输识别结果至网关节点,在网关节点上对识别结果进行融合,在一定程度上解决数据传输问题,但是星型拓扑结构覆盖范围有限,在终端节点上进行信号采集、特征提取和模式识别等任务会导致终端节点负载过重。为增加网络监测覆盖范围,均衡传感器节点负载,笔者采用簇树网络结构对 WSNs 中各级节点进行分层信息融合,通过传输少量特征信息来替代大量原始振动信号传输,以评估机械设备整体运行状态。

## 1 WSNs 多级分层信息融合的故障诊断架构

WSNs 多级分层信息融合的机械故障诊断架构如图 1 所示,由网关节点、多个簇头节点和终端节点组成簇树网络。WSN 信息融合分为数据级融合、特征级融合及决策级融合 3 个级别。终端节点负责采集振动信号并对振动信息进行数据级融合以提取特征信息。簇头节点负责对簇内终端节点特征信息进行特征级融合以得到模式识别结果。网关节点负责整个 WSNs 的建立、管理和维护并对识别结果进行决策级融合。D-S 证据理论在不确定性的表示、量测和组合方面具有优势<sup>[10-11]</sup>,而神经网络具有非线性处理能力,可以解决 D-S 证据理论中的基本概率赋值难的问题,同时在结构和功能上和 WSNs 有很多的相似之处<sup>[12]</sup>,能够很好地与 WSNs 相结合。因此,该架构中的簇头节点训练生成径向基函数(radical basis function, 简称 RBF)神经网络分类器并对终端节点混合域特征集进行特征级融合,得到描述机械设备运行状态的模式识别结果,网关节点针对簇头节点的独立诊断结果依托 D-S 证据理论进行融合决策,评估机械设备整体运行状态。

<sup>\*</sup> 国家自然科学基金资助项目(51375514, 51275546);国家重点基础研究发展计划(“九七三”计划)资助项目(2015CB057702)

收稿日期:2014-01-22;修回日期:2014-04-04

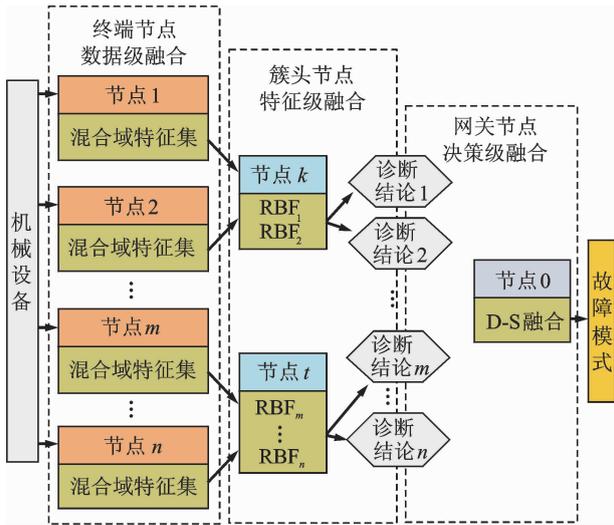


图 1 WSNs 多级分层信息融合的故障诊断架构

Fig. 1 Fault diagnosis architecture based on WSNs multilevel hierarchical information fusion

## 2 双核心 WSNs 节点设计

WSNs 多级分层信息融合要求各级融合中传感器节点均应具备较强的信号处理能力和足够大的样本存储空间。目前,国外针对工业振动监测应用的节点有 Wibeam<sup>[13]</sup>, WiVib<sup>[14]</sup>等,存在性能偏低、内存小的缺点。笔者设计基于双核心的传感器节点,利用两个独立的处理和控制中心分别控制信号处理单元与无线模块,并带有大容量 SD 卡作为主要存储介质以满足信息融合的需求。

双核心 WSNs 节点设计方案如图 2 所示。核心 1 是运行频率为 72 MHz 的基于 ARM Cortex-M3 内核的低功耗 STM32f103 微控制器,利用处理器出色的计算性能以及对事件的优异系统响应能力,能够执行包括硬件除法、单周期乘法和位字段操作在内的 Thumb-2 指令集以获取最佳性能和代码大小,具有 256 kB 的 Flash 空间和 64 kB 的内部 RAM,使得节点可轻松运行较为复杂的算法。移植  $\mu\text{C}/\text{OS-II}$  实时操作系统以提高处理器的利用率,设计实时任务动态优先级配置,保证对任务的实时响应和高效处理。核心 2 是无线射频芯片 TI CC2430 集成的增强型 8051 微处理器,支持 IEEE802.15.4 无线通讯协议,负责完成 WSNs 自组网、时间同步和数据收发等任务。

双核心设计将一个复杂的任务分解为多个子任务,映射到异构双核处理器上协调工作,既增强传感器节点的整体性能,又能减小软硬件模块间的耦合性,能够满足节点振动信号实时处理、网络通信等多任务调度而不会相互干扰。双核心之间采用命令包的形式进

行交互,在接收到命令包或者回应包时,先经过 8 阶的 CRC 校验,若校验无误则执行相应任务以增强系统稳定性。节点选用带有保护电路的大容量可充锂电池供电。

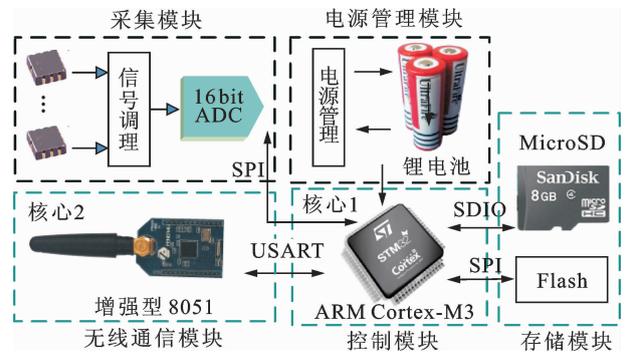


图 2 双核心 WSNs 节点

Fig. 2 WSNs node based on dual core

WSNs 节点存储模块以 8 GB Micro SD 存储卡为主要存储介质,在卡上建立 FAT32 文件系统,大量原始振动数据及重要计算参数均以文件的形式保存在卡上,方便数据的检索和管理。节点采用动态分配内存池的方式有效地分配节点内存池以高效运行较为复杂的算法。算法执行过程中较长的数组可以以文件形式暂时存储在 SD 卡上,内存中开辟的动态变量空间则可用于存储其他需要立即运算的数据,有效地缓解节点计算负载。采用 Cortex-M3 微处理器的 SDIO 接口以 4 bit 直接内存存取 (direct memory access, 简称 DMA) 模式读写 Micro SD 存储卡,速率最大可以达到 1.5 MB/s,完全满足信号实时处理时节点对存储系统读写速度要求。

在 WSNs 节点上设计独立信号处理单元,从而避免使用性能过高的微处理器造成成本大幅提高和节点能耗过高问题。设计开发适用于机械振动信号分析的实时预处理和常用分析函数并进行算法优化,形成一套较为完整的高效低复杂度嵌入式函数库。嵌入式函数库结构框图如图 3 所示,包括基本

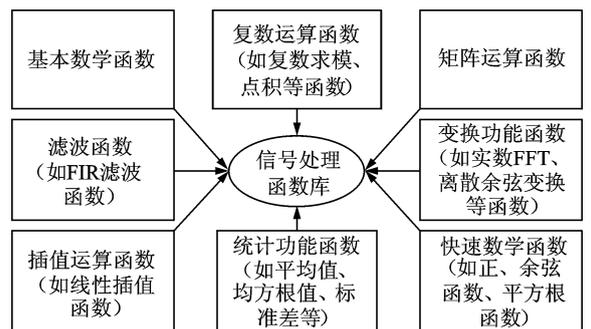


图 3 嵌入式函数库结构框图

Fig. 3 Block diagram of embedded function library

数学函数模块、统计功能函数模块、变换功能函数模块、插值运算函数模块和滤波函数模块等8个模块和各模块相应的功能函数。

### 3 WSNs 信息融合故障诊断方法实现

WSNs 节点的计算资源及能量有限,信息融合处理需要考虑算法的复杂度。时间复杂度和空间复杂度是算法复杂度的两个重要特征,也是衡量软件功耗的两个重要特征,因此笔者以这两个特征来度量节点各级融合算法的复杂度。时间复杂度主要以算法平均时间复杂度  $O_t$  来度量。空间复杂度  $S_s$  的度量主要包括3个方面:问题本身所用空间、程序本身所占空间和动态变量所占空间。问题本身所用空间与算法无关,程序代码所占空间对算法空间复杂度影响很小,这里均不进行讨论,而着重讨论度量算法动态变量所占内存空间。

#### 3.1 WSNs 终端节点数据级融合

机械设备出现故障时振动信号的幅值和概率分布将会发生变化,同时其对应的频谱成分,不同谱峰的幅值也将发生改变。通过构造一些定量的机械设备振动信号时域或频域特征统计指标量,可以表征机械设备的各类故障模式。WSNs 节点数据级融合中特征统计指标量最终按以下标准进行选取:计算需求,分类性能,特征域(时域、频域等)以及最优的特征个数。选取  $d$  个特征统计指标量组成特征集用于构造  $d$  维特征空间  $x \in R^d$ 。

以数据输入规模  $\text{len}$  为 2 048 点数据特征提取为例,节点提取各时域特征统计指标量时间复杂度为  $O(1)$ ,参与运算的数据所占的内存空间为  $4 \times \text{len}$  字节。在进行快速傅里叶变换时,为样本输入数组和变换输出数组动态开辟的内存空间大小为 24 kB。节点获取的原始振动信号及特征信息均以文件形式存储于 SD 卡以节省内存空间。

#### 3.2 WSNs 簇头节点特征级融合

簇头节点接受簇内终端节点发送的特征信息并作为样本进行特征级融合,算法流程如图4所示。

神经网络训练时随机选取  $h$  个训练样本作为聚类中心  $c_i (i=1, 2, \dots, h)$ ,按照输入的训练样本  $x_p$  与中心为  $c_i$  之间的欧氏距离,将  $x_p$  分配到输入样本的各个聚类集合  $\Omega_p (p=1, 2, \dots, P)$  中,计算各个聚类集合  $\Omega_p$  中训练样本的平均值,得到新的聚类中心  $c_i$ ,若新的聚类中心  $c_i$  不再变化,得到 RBF 神

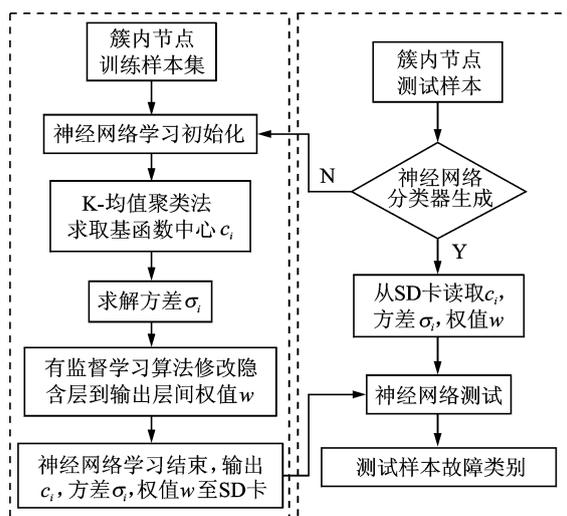


图4 簇头节点特征级融合算法流程

Fig. 4 Feature level fusion algorithm flow on cluster head node

经网络最终的基函数中心  $c_i$ , 否则重新按最近邻规则分组求取新的聚类中心  $c_i$ 。选择高斯函数作为基函数,求解方差  $\sigma_i$ ,计算公式如式(1)所示。隐含层到输出层间的权值  $w$  采用有监督的学习算法进行修改。输出训练好的神经网络聚类中心  $c_i$ , 方差  $\sigma_i$ , 权值  $w$  以文件形式保存在簇头节点 SD 卡上。

$$\sigma_i = \frac{c_{\max}}{\sqrt{2h}} \quad (i=1, 2, \dots, h) \quad (1)$$

其中:  $c_{\max}$  为所选取中心之间的最大距离。

簇头节点接受簇内终端节点测试样本,先判断神经网络分类器是否生成。若未生成则读取其 SD 卡中训练样本集进行训练以生成神经网络分类器,否则直接读取 SD 卡相应文件中的神经网络参数并对测试样本进行特征级融合,利用神经网络泛化能力得到各待识别模式的概率分配函数(basic probability assignment, 简称 BPA)。由于 D-S 理论要求各证据体的概率分配函数之和为 1, 概率分配函数由神经网络输出结果进行归一化后得到

$$m(B_i) = \frac{y(B_i)}{\sum_{i=1}^N y(B_i)} \quad (2)$$

其中:  $y(B_i)$  为神经网络分类器的输出结果;  $B_i (i=1, 2, \dots, N)$  表示第  $i$  类故障类型;  $N$  为待识别的故障类型个数; 概率分配函数  $m(B_i)$  用于进一步决策级融合。

簇头节点训练生成神经网络分类器过程中各函数时间复杂度为  $O(1)$ , 而为其动态分配的内存空间大小由网络分类器规模具体大小决定。节点获取的训练样本和测试样本均以文件形式保存在 SD 卡

中,通过文件系统管理神经网络学习、测试阶段的数据,并设计内存调用策略降低节点内存压力。在烧写节点应用程序时加载嵌入式函数库更好地实现神经网络学习和测试,使得簇头节点能实现特征级融合。

### 3.3 WSNs 网关节点决策级融合

簇头节点通过 RBF 神经网络分类器对簇内终端节点特征信息进行模式识别,得到对应各模式的概率分配函数并作为一个证据体。网关节点利用 D-S 理论合成规则将多个证据体的概率分配函数进行决策级融合,原理如下。设  $\Theta$  为识别框架,定义函数  $m:2^\Theta \rightarrow [0,1]$ ,称为 mass 函数,满足  $m(\varphi) = 0$  ( $\varphi$  为空集),  $\sum m(A) = 1 (A \in 2^\Theta)$ ,则称  $m(A)$  为  $2^\Theta$  上的概率分配函数, $m(A)$  为命题  $A$  的基本概率数,使得  $m(A) > 0$  的  $A$  称为焦元。识别框架  $\Theta$  上有限个  $m_1, m_2, \dots, m_n$  的 Dempster 合成规则为

$$(m_1 \oplus m_2 \oplus \dots \oplus m_n)(A) = \frac{\sum_{A_1 \cap A_2 \cap \dots \cap A_n = A} m_1(A_1) m_2(A_2) \dots m_n(A_n)}{(1 - k)} \quad (3)$$

其中:  $k$  为证据的不确定因子

$$k = \sum_{A_1 \cap A_2 \cap \dots \cap A_n = \varphi} m_1(A_1) m_2(A_2) \dots m_n(A_n) \quad (4)$$

网关节点融合多个证据体的概率分配函数结果为一组新的概率分配函数,以融合后的函数作为决策依据,得到机械设备整体运行状态。

## 4 实例分析

齿轮箱故障模拟实验台如图 5 所示。该实验台由单极减速器齿轮箱、调速电机、磁粉制动器、WSNs 节点和 MEMS 加速度传感器 ADXL001 等组成。电机驱动转速为 1.2 kr/min,采样频率为 10 kHz。模拟齿轮箱的 2 种故障类型:a. 驱动输入端齿轮齿根损伤;b. 驱动输入端轴承内圈损伤。其中:齿轮箱中齿轮齿数  $z_1 = 55, z_2 = 75$ ,模数  $m = 3$ ,轴承型号为 N205。

在驱动输入端轴承座和输出端轴承座附近布置 4 个终端节点(编号 1, 2, 3, 4)、2 个簇头节点(编号 5, 6)和 1 个网关节点,组建簇树网络。为降低节点计算复杂度,采用方差、方根幅值和均方根值等时域特征统计指标量和均值频率、标准偏差频率等频域特征统计指标量来表征齿轮箱运状态。终端节点对正常状态及两种故障状态的振动信号,依照时间

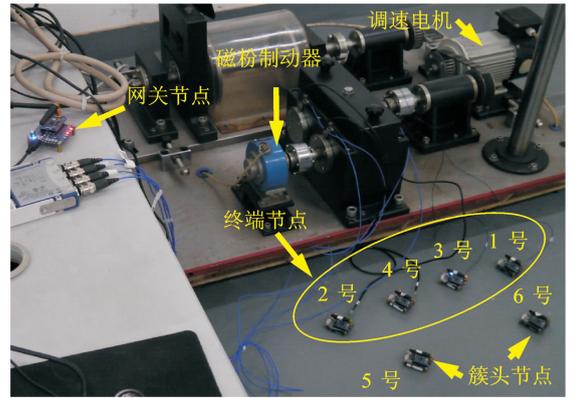


图 5 齿轮箱振动测试实验台

Fig. 5 The gearbox vibration measurement system

顺序以 2 048 个连续采样值为 1 个单位,分别构造 40 组特征信息样本,样本总数为 120 组。簇头节点接收终端节点 120 组样本并输入 RBF 神经网络进行网络学习以生成故障诊断分类器。为降低簇头节点网络学习压力,训练目标误差设置为 0.05。神经网络输入层神经元个数由特征维数决定为 5。设置隐含层神经元个数为 3 和 1 个偏置神经元。考虑齿轮箱的 3 种运行状态,设计输出层神经元个数为 3,即正常状态、齿根损伤和轴承内圈损伤,对应的输出分别记为  $[1,0,0], [0,1,0], [0,0,1]$ 。

选择驱动输入端轴承内圈损伤运行状态作为未知状态进行神经网络测试,簇内终端节点同时对齿轮箱运行状态构造 1 组特征信息样本,簇头节点从 SD 卡中读取相应神经网络分类器参数,将特征信息样本输入分类器得到对待识别模式的概率分配函数。网关节点利用 D-S 融合决策理论对各证据体进行融合决策,以融合后的函数作为决策依据识别出故障类型。分别进行 30 组测试,其中一组测试概率分配及融合决策结果如表 1 所示。 $A_1, A_2, A_3$  分别代表轴承的正常状态、齿根损伤和轴承内圈损伤; $m$  代表概率分配函数。

表 1 齿轮箱未知状态的概率分配及融合决策结果

Tab.1 The BPA and fusion diagnosis result of bearing unknown state

节点编号	$m(A_1)$	$m(A_2)$	$m(A_3)$	D-S 融合
1 号	0.117 5	0.004 3	0.878 2	$m(A_1) = 0.000 0$ $m(A_2) = 0.004 9$ $m(A_3) = 0.995 1$
2 号	0.000 1	0.367 9	0.632 0	
3 号	0.001 2	0.545 0	0.453 8	
4 号	0.001 3	0.587 3	0.411 4	

由表 1 可以看出,3 号、4 号节点对轴承内圈轻度损伤的支持程度并不明显,因而不能仅用 3 号节

点或4号节点对齿轮箱的运行状态进行辨识。由于轴承内圈轻度损伤的故障特征十分微弱,而3号、4号节点传感器测点远离故障源,受信号传播路径等原因,使得3号及4号节点没有完全触及到相应的故障特征信号。综合4组的概率分配函数进行决策级融合,准确诊断出了轴承内圈轻度损伤故障。对30组测试结果进行统计,故障识别率为83.3%。

## 5 结束语

提出无线传感器网络多级分层信息融合的机械故障诊断方法。相比星型网络结构,采用的簇树网络结构的网络监测覆盖范围更大。设计的双核心WSNs节点满足WSNs多级分层信息融合的故障诊断架构需求。利用多级分层信息融合将计算任务分配给各级节点,有效地均衡传感器节点计算负载,通过传输少量特征信息来替代大量原始振动信号传输,降低网络数据传输总量,节省网络带宽,降低网络能耗,为WSNs应用于机械设备故障诊断提出了新的思路。

### 参 考 文 献

- [1] Flammini A, Ferrari P, Marioli D, et al. Wired and wireless sensor networks for industrial applications [J]. *Microelectronics Journal*, 2009, 40(9): 1322-1336.
- [2] 汤宝平, 黄庆卿, 邓蕾, 等. 机械设备状态监测无线传感器网络研究进展[J]. *振动、测试与诊断*, 2014, 34(1): 1-7.  
Tang Baoping, Huang Qingqing, Deng Lei, et al. Research progress and challenges of wireless sensor networks for machinery equipment condition monitoring[J]. *Journal of Vibration, Measurement & Diagnosis*, 2014, 34(1): 1-7. (in Chinese)
- [3] Sung W T, Chen J H, Hsu C C. WSN system based on weight adjust for machinery manufacturing machine monitoring [J]. *Applied Mechanics and Materials*, 2013, 300: 124-127.
- [4] Chan J C, Tse P W. A novel, fast, reliable data transmission algorithm for wireless machine health monitoring [J]. *IEEE Transactions on Reliability*, 2009, 58(2): 295-304.
- [5] 汤宝平, 贺超, 曹小佳. 面向机械振动监测的无线传感器网络结构[J]. *振动、测试与诊断*, 2010, 30(4): 357-361.  
Tang Baoping, He Chao, Cao Xiaojia. Topology of wireless sensor networks for mechanical vibration monitoring[J]. *Journal of Vibration, Measurement & Diagnosis*, 2010, 30(4): 357-361. (in Chinese)
- [6] Vogl A, Wang D T, Storás P, et al. Design, process and characterisation of a high-performance vibration sensor for wireless condition monitoring [J]. *Sensors and Actuators A: Physical*, 2009, 153(2): 155-161.
- [7] Latré B, De Mil P, Moerman I, et al. Maximum throughput and minimum delay in IEEE[C]// *Mobile Ad-hoc and Sensor Networks*. Wuhan, China: Springer Berlin Heidelberg, 2005: 866-876.
- [8] Hou L, Bergmann N W. Novel industrial wireless sensor networks for machine condition monitoring and fault diagnosis[J]. *IEEE Transactions on Instrumentation and Measurement*, 2012, 61(10): 2787-2798.
- [9] Hou L, Bergmann N W. Induction motor fault diagnosis using industrial wireless sensor networks and Dempster-Shafer classifier fusion [C]// *IECON 2011-37th Annual Conference on IEEE Industrial Electronics Society*. Melbourne: [s. n.], 2011: 2992-2997.
- [10] Dempster A P. Upper and lower probabilities induced by a multivalued mapping [J]. *The Annals of Mathematical Statistics*, 1967, 38(2): 325-339.
- [11] Shafer G. A mathematical theory of evidence [M]. Princeton: Princeton University Press, 1976: 173-207.
- [12] Soares S G, da Rocha A F, de A Barbosa T M G, et al. Embedding a neural network into WSN furniture [C]// *2010 10th International Conference on Hybrid Intelligent Systems (HIS)*. Atlanta: [s. n.], 2010: 219-222.
- [13] Jagannath V M D, Raman B. WiBeaM: wireless bearing monitoring system [C]// *2007 2nd International Conference on Communication Systems Software and Middleware*. Bangalore: [s. n.], 2007: 1-8.
- [14] Neander J, Nolin M, Bjorkman M, et al. Wireless vibration monitoring (WiVib)-an industrial case study [C]// *2007 IEEE Conference on Emerging Technologies and Factory Automation (ETFA)*. Patras: [s. n.], 2007: 920-923.



**第一作者简介:** 汤宝平,男,1971年9月生,教授、博士生导师。主要研究方向为无线传感器网络、机电装备安全服役与寿命预测、测试计量技术及仪器。曾发表《Fault diagnosis for wind turbine transmission system based on manifold learning and Shannon wavelet support vector machine》(《Renewable Energy》2014, Vol. 62, No. 9)等论文。  
E-mail: bptang@cqu.edu.cn

