

# 基于 WVPMCD 和层次模糊熵的液压泵故障诊断方法研究

舒思材, 韩 东

(机械工程学院, 石家庄 050003)

**摘要:** 为了更准确地对液压泵进行故障诊断, 提出了基于 WVPMCD (WLS-Variable predictive mode based class discriminate, WVPMCD) 和层次模糊熵 (hierarchical fuzzy entropy, HFE) 的故障诊断方法; 由于液压泵振动信号比较复杂, 基于变量预测模型的模式识别 (variable predictive mode based class discriminate, VPMCD) 方法在对模型参数进行估计时会出现异方差的现象, 从而导致参数估计出现病态, 估计所得参数不稳定, 从而降低预测精度; WVPMCD 作为 VPMCD 的改进, 采用更先进的加权最小二乘参数估计法代替最小二乘参数估计法, 消除异方差的影响, 提高参数估计的精度, 进而提高液压泵故障诊断准确率; 此外, 在层次熵 (Hierarchical Entropy, HE) 的基础上提出了层次模糊熵的概念, 模糊熵作为样本熵的改进, 在衡量时间序列复杂度上并比样本熵更优越; 运用 WVPMCD 和层次模糊熵对液压泵进行故障诊断, 实验结果验证了该方法的有效性。

**关键词:** WVPMCD; 层次模糊熵; 液压泵; 故障诊断

## Method of Fault Diagnosis of Hydraulic Pump Based on WVPMCD and Hierarchical Fuzzy Entropy

Shu Sicai, Han Dong

(Ordnance Engineering College, Shijiazhuang 050003, China)

**Abstract:** In order to diagnose hydraulic pump more accurately, a new approach based on WVPMCD and HFE is proposed. Because hydraulic pump's vibration signal is complex, VPMCD's parameter estimation will be heteroscedastic. And then, it will result in morbidity and the gained parameter will be instability. Thus, the prediction accuracy will decrease. As improvement of VPMCD, WVPMCD uses the advanced weighted least square parameter estimation method to replace ordinary least square parameter estimation method, which remove the affect of heteroscedasticity and improve accuracy of parameter estimation. Thus, accuracy of pattern recognition will be also increase. Furthermore, HFE is proposed on the base of HE. As improvement of SE, FE have advantage in measurement of time series' complexity. The proposed algorithm is verified by experimental data analysis.

**Keywords:** WVPMCD; hierarchical fuzzy entropy; hydraulic pump; fault diagnosis

## 0 引言

液压泵的故障诊断从本质上讲其实是模式识别的过程。目前常见的机械故障模式识别方法主要有神经网络与支持向量机等。但这些方法其实都忽略了特征值之间的联系。Raghuraj 等<sup>[1]</sup>提出了一种基于变量预测模型的模式识别方法, 并将该方法与其他模式识别方法进行了对比, 验证了该方法的优越性。程军圣等<sup>[2]</sup>运用 VPMCD 提出了基于 VPMCD 和 EMD 的齿轮故障诊断方法, 结果表明该方法能有效提高故障诊断的精度。罗颂荣等<sup>[3]</sup>在 VPMCD 的基础上进行改进, 提出了 GA-VPMCD 的方法, 并应用于机械故障智能诊断, 有效提高了故障诊断的精度和诊断系统的鲁棒性。杨宇等<sup>[4]</sup>提出了 VPMCD 的另一个改进版—WVPMCD 方法, 即在原方法中用加权最小二乘法代替最小二乘法进行参数估计, 克服了回归模型出现异方差的情况, 提高了预测精度。

故障诊断的另一关键是特征提取, 近年来, 基于样本熵<sup>[5]</sup>

的特征提取方法已经被广泛应用于故障诊断。Jiang 等<sup>[6]</sup>提出一种层次熵的方法, 通过层次分解和样本熵进行分析, 并且已经将这种方法应用于心脏间隔时间序列, 对不同的心脏疾病进行识别。Zhu 等<sup>[7]</sup>将层次熵与支持向量机结合应用于滚动轴承的故障诊断, 取得了良好的效果。但样本熵的定义必须包含一个模版匹配, 否则无意义, 且无法解释白噪声熵值过大的问题。陈伟婷<sup>[8]</sup>对样本熵进行改进, 提出了模糊熵的概念, 它具有样本熵的优点, 并比之更优越。

考虑到 WVPMCD 和模糊熵的优点, 结合基于层次熵的特征提取方法, 本文提出一种基于 WVPMCD 和层次模糊熵的液压泵故障诊断方法, 实验数据分析与比较结果验证了该方法的有效性。

## 1 WVPMCD

对于 WVPMCD 方法, 特征值  $X_i$  对应的既可能是线性变量预测模型, 也可能是非线性变量预测模型, 为满足要求, 定义了 4 种模型以供选择:

(1) 线性模型 (L):

$$X_i = b_0 + \sum_{j=1}^r b_j X_j \quad (1)$$

(2) 线性交互模型 (LI):

收稿日期: 2015-07-23; 修回日期: 2015-08-27。

基金项目: 国家自然科学基金(51275524)。

作者简介: 舒思材(1990-), 男, 湖北黄石人, 硕士, 主要从事状态监测与故障预测方面的研究工作。

$$X_i = b_0 + \sum_{j=1}^r b_j X_j + \sum_{j=1}^r \sum_{k=j+1}^r b_{jk} X_j X_k \quad (2)$$

(3) 二次模型 (Q):

$$X_i = b_0 + \sum_{j=1}^r b_j X_j + \sum_{j=1}^r b_{jj} X_j^2 \quad (3)$$

(4) 二次交互模型 (QD):

$$X_i = b_0 + \sum_{j=1}^r b_j X_j + \sum_{j=1}^r b_{jj} X_j^2 + \sum_{j=1}^r \sum_{k=j+1}^r b_{jk} X_j X_k \quad (4)$$

在式 (1-4) 中:  $X_i$  代表待预测变量,  $X_j, X_k$  代表预测变量。R 代表模型阶数, 但应小于等于  $p-1$ 。假设特征值个数是  $p$ , 从 4 个模型中选取任意一个模型, 得到下式

$$X_i = f(X_j, b_0, b_j, b_{jj}, b_{jk}) + e \quad (5)$$

变量  $X_i$  的变量预测模型 WVPM<sub>i</sub> 即式 (5),  $e$  代表的是预测中存在的误差;  $b_0, b_j, b_{jj}, b_{jk}$  代表的是变量预测模型的参数。WVPMCD 方法的具体流程如下。

1) 训练的过程:

(1) 针对系统出现的  $g$  类故障, 首先收集足够多的  $N$  个训练样本, 其中, 训练样本中每一类故障对应的样本数目分别为  $n_1, n_2, \dots, n_g$ 。

(2) 选择一种合适且有效的特征提方法, 提取所有训练样本的特征值, 得到  $X = [X_1, X_2, \dots, X_p]$ 。

(3) 对于特征向量中的任意一个被预测变量  $X_i$ , 根据特征值之间的相互关联, 选择合适的模型类型、预测变量与模型阶数。

(4) 为了更好的进行预测, 首先假设  $k=1$ , 对于第  $k$  类故障模式下的任一个训练样本, 分别建立预测模型, 则利用每个特征值都能够建立  $n_k$  个方程。然后借用加权最小二乘参数估计法对  $n_k$  个方程的回归参数  $b_0, b_j, b_{jj}, b_{jk}$  进行估计。经过加权最小二乘处理, 将模型参数再代回原始特征方程中, 以变量预测模型的预测误差平方和的值最小作为评判标准, 最终完成建立  $k=1$  时的所有特征值的预测模型。

(5) 令  $k=k+1$ , 继续步骤 4), 直到  $k=g$  时循环结束。

(6) 完成以上步骤后, 所有故障类别下的所有特征值均已建立了预测模型 WVPM<sub>i</sub><sup>k</sup>,  $k=1, 2, \dots, g$  代表不同的类别,  $i=1, 2, \dots, p$  代表不同的特征值, 下面需要展开的是分类工作。

2) 分类过程:

(1) 输入不同故障模式的测试样本, 采用相同的特征提取方法, 得到特征值  $X = [X_1, X_2, \dots, X_p]$ 。

(2) 利用训练过程中得到的 WVPM<sub>i</sub><sup>k</sup>, 对测试样本所有的特征值进行预测, 得到预测值  $\tilde{X}_i^k$ 。

(3) 对经过预测得到的  $\tilde{X}_i^k$  进行整理, 计算并比较相同类别的全部的特征值的预测误差平方和  $\sum_{i=1}^p (X_i - \tilde{X}_i^k)^2$ , 将

$\sum_{i=1}^p (X_i - \tilde{X}_i^k)^2$  最小作为分类准则。

## 2 层次模糊熵

### 2.1 模糊熵

对于近似熵和样本熵, 两个向量相似性的度量都是通过阶跃函数定义的。模糊熵的定义则引入了模糊函数的概念, 并选择指数函数  $e^{-(d/r)^n}$  作为模糊函数来衡量两个向量的相似性。指数函数具有以下特征: (1) 连续性保证其值不会突变; (2)

凸性保证向量自身的自相似性值最大。事实上, 其他函数只要满足条件 (1), (2) 也可以作为模糊函数。

模糊熵的定义如下<sup>[8]</sup>:

(1) 对  $N$  点时间序列  $\{u(i); 1 \leq i \leq N\}$  按顺序支起  $m$  维向量:

$$X_i^m = \{u(i), u(i+1), \dots, u(i+m-1)\} - u_0(i), \quad i = 1, 2, \dots, N-M+1 \quad (6)$$

式中,  $X_i^m$  代表从第  $i$  个点开始的连续  $m$  个  $u$  的值去掉均值  $u_0(i)$ , 其中

$$u_0(i) = \frac{1}{m} \sum_{j=0}^{m-1} u(i+j) \quad (7)$$

(2) 定义  $X_i^m$  和  $X_j^m$  间的距离  $d[X_i^m, X_j^m]$  为两者对应元素差值的最大值, 即

$$d_{ij}^m = d[X_i^m, X_j^m] = \max_{k \in (0, m-1)} \{|(u(i+k) - u_0(i)) - (u(j+k) - u_0(j))|\} \quad (8)$$

(3) 通过模糊函数  $\mu(d_{ij}^m, n, r)$  定义矢量  $X_i^m$  和  $X_j^m$  的相似度  $D_{ij}^m$ , 即

$$D_{ij}^m = \mu(d_{ij}^m, n, r) = e^{-(d_{ij}^m/r)^n} \quad (9)$$

式中, 模糊函数  $\mu(d_{ij}^m, n, r)$  为指数函数,  $n$  和  $r$  分别为其边界的梯度和宽度。

(4) 定义函数:

$$\varphi^m(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left( \frac{1}{N-m-1} \sum_{\substack{j=1 \\ j \neq i}}^{N-m} D_{ij}^m \right) \quad (10)$$

(5) 类似地, 再对维数  $m+1$ , 重复上述 (1)~(4), 得

$$\varphi^{m+1}(n, r) = \frac{1}{N-m} \sum_{i=1}^{N-m} \left( \frac{1}{N-m-1} \sum_{\substack{j=1 \\ j \neq i}}^{N-m} D_{ij}^{m+1} \right) \quad (11)$$

(6) 定义模糊熵为:

$$FuzzyEn(m, n, r) = \lim_{N \rightarrow \infty} [\ln \varphi^m(n, r) - \ln \varphi^{m+1}(n, r)] \quad (12)$$

当  $N$  为有限数时, 上式表示成:

$$FuzzyEn(m, n, r, N) = \ln \varphi^m(n, r) - \ln \varphi^{m+1}(n, r) \quad (13)$$

模糊熵和样本熵的物理意义相近, 都是时间序列复杂性的度量, 熵值越大, 复杂度越大。模糊熵具有样本熵的优点: 所需数据量小, 并保持一致性; 同时, 比样本熵更优越: 首先, 模糊熵采用的是指数函数模糊化相似性度量公式, 指数函数的连续性保证了模糊熵值随参数连续平滑变化; 其次, 模糊熵通过均值运算, 去除了基线漂移的影响, 且向量的相似性不再由绝对幅值差确定, 从而使相似性度量模糊化。

### 2.2 层次模糊熵

给定一个时间序列  $X = \{x_1, x_2, \dots, x_N\}$ , 其中  $N = 2^n$ , 其层次模糊熵定义如下。

(1) 定义一个均值算子  $Q_0$ :

$$(Q_0(X))_j = \frac{x(2j-1) + x(2j)}{2}, j = 1, 2, \dots, 2^{n-1} \quad (14)$$

长度为  $2^{n-1}$  的时间序列  $Q_0(X)$  表示原时间序列  $X$  经过一次层次分解后的均值成分。

(2) 定义一个差值算子  $Q_1$ :

$$(Q_1(X))_j = \frac{x(2j-1) - x(2j)}{2}, j = 1, 2, \dots, 2^{n-1} \quad (15)$$

长度为  $2^{n-1}$  的时间序列  $Q_1(X)$  表示原时间序列  $X$  经过一次层次分解后的差值成分。原时间序列  $X$  也可由  $Q_0(X)$  和

$Q_1(X)$  表示

$$x_{2j-1} = (Q_0(X))_j + (Q_1(X))_j, x_{2j} = (Q_0(X))_j - (Q_1(X))_j, \\ j = 1, 2, \dots, 2^{n-1} \quad (16)$$

由此可知, 时间序列  $Q_0(X)$  和  $Q_1(X)$  构成了对时间序列  $X$  进行多层次分析的第二层。算子  $Q_j$  ( $j$  等于 0 或 1) 可表示为一个矩阵

$$Q_j = \begin{bmatrix} \frac{1}{2} & \frac{(-1)^j}{2} & 0 & 0 & \dots & 0 & 0 \\ 0 & 0 & \frac{1}{2} & \frac{(-1)^j}{2} & \dots & 0 & 0 \\ 0 & 0 & 0 & 0 & \dots & \frac{1}{2} & \frac{(-1)^j}{2} \end{bmatrix}_{2^{n-1} \times 2^n} \quad (17)$$

算子  $Q_j$  的矩阵形状取决于它们所作用的时间序列长度。为了描述  $X$  的多层次分析, 这些算子将会被反复使用。

(3) 令  $e$  为整数, 且  $0 \leq e \leq 2^n - 1$ 。令  $L_i$  ( $i = 1, 2, \dots, n$ ) 等于 0 或 1。对给定的  $e$ , 有唯一一组向量  $[L_1, L_2, \dots, L_n]$ , 使得

$$e = \sum_{i=1}^n L_i 2^{n-i} \quad (18)$$

(4) 序列  $X$  第  $n+1$  层的第  $e+1$  个节点定义为

$$X_{n,e} = Q_{L_n} \cdot Q_{L_{n-1}} \cdot \dots \cdot Q_{L_1}(X) \quad (19)$$

式 (19) 中,  $Q_{L_i}$  代表  $X_{0,0}$  到  $X_{n,e}$  的第  $i$  次层次分解。若第  $i$  次层次分解为均值运算, 则  $Q_{L_i} = Q_0$ , 即  $L_i = 0$ ; 若第  $i$  次层次分解为差值运算, 则  $Q_{L_i} = Q_1$ , 即  $L_i = 1$ 。

最后, 计算节点  $X_{n,e}$  的模糊熵, 这个过程叫做层次模糊熵分析。

在层次模糊熵中, 第 1 层只有一个节点  $X_{0,0}$ , 代表原时间序列  $X$ ,  $X_{n,0}$  代表原时间序列  $X$  在第  $n+1$  层的均值成分, 其他节点代表非均值成分。对于不同的  $n$  和  $e$ ,  $X_{n,e}$  构成了  $X$  在不同层次上的分解信号, 图 1 展示了  $X$  的两次层次分解图。




图 1 两次层次分解图

### 2.3 参数选取

根据模糊熵的定义, 模糊熵值的计算与嵌入维数  $m$ 、相似容限  $r$ 、模糊函数的梯度  $n$  和数据长度  $N$  均有关系。(1)  $m$  越大, 在序列的联合概率进行动态重构时, 会有越多的详细信息, 但  $m$  越大计算所需数据长度也越大, 综合考虑本文取  $m = 2$ 。(2)  $r$  过大将丢失很多统计信息, 过小估计出的统计特性效果不理想, 而且会增加对结果噪声的敏感性。一般  $r$  取  $0.1 \sim 0.25SD$  ( $SD$  是原始时间序列标准差), 本文取  $r = 0.15SD$ 。(3)  $n$  决定了相似容限边界的梯度,  $n$  越大则梯度越大,  $n$  在模糊熵向量间相似性的计算过程中起着权重的作用。 $n > 1$  时, 更多地计入较远的向量的相似度贡献, 而更少地计入较远的向量的相似度贡献。 $n$  过大将导致细节信息丧失, 为捕

获更多的细节信息, 文献 [8] 建议计算时取较小的整数值。综合考虑, 本文选取  $n = 2$ 。

## 3 应用

### 3.1 实验准备

本实验采用的液压泵类型为斜盘式轴向柱塞泵, 型号为: L10VS028DR/31R-PPA12N00; 液压泵柱塞数为 9, 理论排量为 28 ml/r, 额定转速为 2 200 rpm。驱动电机型号为: YE2-225M-4; 电机额定转速为 1 480 rpm。设置液压泵的工作压力为 20 MPa, 采样频率为 2 KHz, 采用 DH-5920 动态信号测试分析系统采集并存储数据。首先用正常状态的液压泵进行实验, 采集端盖处的振动加速度信号。然后将正常部件替换成故障部件, 人为模拟液压泵松靴故障、配流盘磨损和滑靴磨损 3 种故障模式。

从采集的 4 种状态的信号中分别随机取一个样本, 如图 2 所示。




图 2 不同状态的时域波形图

### 3.2 基于层次模糊熵的特征提取

根据模糊熵的定义, 模糊熵值的计算与嵌入维数  $m$ 、相似容限  $r$ 、模糊函数的梯度  $n$  和数据长度  $N$  均有关系。综合考虑, 本文取  $m = 2, r = 0.15SD$  ( $SD$  是原始时间序列标准差),  $n = 2$ 。

用层次模糊熵分别对图 1 中 4 种信号进行处理, 层次分解的次数取 2, 结果如图 3。横坐标 1~4 代表层次分解节点  $X_{3,0} \sim X_{3,3}$ 。

### 3.3 基于 WVPMCD 的模式识别

从采集的液压泵 4 种状态的数据中分别随机抽取 10 组数据, 共 40 组数据作为训练样本; 另外分别随机抽取 10 组数据, 共 40 组数据作为测试样本。

首先计算 40 组训练样本的特征向量  $[M_1, M_2, M_3, M_4]$ , 分别采用 VPMCD 方法与 WVPMCD 方法进行训练, 分别得到的最佳模型、最佳阶数如表 1、2 所示。

从表 1 和表 2 可以看出, 经过原始 VPMCD 训练得到的均




图 3 不同状态的层次模糊图

表 1 VPMCD 训练得到的最佳模型和最佳模型阶数

被预测变量	液压泵状态							
	正常状态		松靴		配流盘磨损		滑靴磨损	
	模型类型	模型阶数	模型类型	模型阶数	模型类型	模型阶数	模型类型	模型阶数
$M_1$	QI	3	QI	3	QI	3	QI	3
$M_2$	QI	3	QI	3	QI	3	QI	3
$M_3$	QI	3	QI	3	QI	3	QI	3
$M_4$	QI	3	QI	3	QI	3	QI	3

表 2 WVPMCD 训练得到的最佳模型和最佳模型阶数

被预测变量	液压泵状态							
	正常状态		松靴		配流盘磨损		滑靴磨损	
	模型类型	模型阶数	模型类型	模型阶数	模型类型	模型阶数	模型类型	模型阶数
$M_1$	QI	3	QI	3	QI	3	QI	3
$M_2$	QI	3	QI	3	QI	3	QI	3
$M_3$	QI	3	QI	3	QI	3	QI	3
$M_4$	QI	3	Q	3	Q	3	QI	3

为 3 阶二次交互模型，经过 WVPMCD 训练得到的预测模型类型则部分出现了变化。这是由于 VPMCD 认为模型越复杂，模型拟合性也应该更好。但这样一来，模型的异方差性也增加了，这样反而会降低参数估计的精度。

将采用加权最小二乘法估计得到的参数代回原方程，得到最佳  $WVPM_i^t$  如表 3 所示。

从表 3 可以看出，最终得到的最佳的  $4 \times 4$  个  $WVPM_i^t$  误差都非常小，说明模型拟合程度与可信度均较高。

最后利用 40 组测试样本来验证本文所提故障诊断方法的

表 3 训练得到的  $WVPM_i^t$  及误差分析

		$WVPM_1^t$	误差
正常状态	$WVPM_1$	$M_1 = -101.6448 + 126.7602M_2 + 307.6253M_3 - 322.2951M_4 - 4.9905M_2^2 - 84.3546M_3^2 + 41.0775M_4^2 - 91.7524M_2M_3 + 26.9537M_2M_4 + 82.9827M_3M_4$	$1.2203 \times 10^{-13}$
	$WVPM_2$	$M_2 = -38.1344 + 212.7626M_1 - 20.1281M_3 - 169.6177M_4 - 57.2587M_1^2 - 14.6243M_3^2 + 30.4745M_4^2 - 0.1719M_1M_3 - 1.0225M_1M_4 + 42.5182M_3M_4$	$6.9632 \times 10^{-12}$
	$WVPM_3$	$M_3 = 972.8038 - 327.2831M_1 - 280.6272M_2 - 504.6728M_4 + 64.6056M_1^2 + 142.4368M_2^2 + 49.7101M_4^2 - 121.0920M_1M_2 + 176.9152M_1M_4 + 5.9887M_2M_4$	$2.7993 \times 10^{-11}$
	$WVPM_4$	$M_4 = -296.9475 - 104.8177M_1 + 53.47979M_2 + 413.0625M_3 + 48.9973M_1^2 + 30.0770M_2^2 - 67.9799M_3^2 - 16.2879M_1M_2 - 28.6280M_1M_3 - 75.2638M_2M_3$	$9.1657 \times 10^{-10}$
		$WVPM_2^t$	误差
松靴	$WVPM_1$	$M_1 = -123.3014 + 1.3161 \times 10^3M_2 - 1.5059 \times 10^3M_3 + 314.7641M_4 - 277.0984M_2^2 + 839.6775M_3^2 + 294.0403M_4^2 - 108.1446M_2M_3 - 103.3138M_2M_4 - 675.5086M_3M_4$	$7.0411 \times 10^{-11}$
	$WVPM_2$	$M_2 = 169.6730 + 29.8225M_1 - 202.6850M_3 - 24.9201M_4 + 13.8352M_1^2 + 226.5320M_3^2 + 147.5101M_4^2 - 45.7760M_1M_3 + 0.4293M_1M_4 - 284.3254M_3M_4$	$1.5417 \times 10^{-12}$
	$WVPM_3$	$M_3 = 31.7712 - 245.6945M_1 + 46.2533M_2 + 164.2282M_4 + 1.7494M_1^2 + 18.9289M_2^2 - 3.1123M_4^2 + 83.3830M_1M_2 + 56.4894M_1M_4 - 147.1315M_2M_4$	$1.3054 \times 10^{-14}$
	$WVPM_4$	$M_4 = -27.3804 - 10.5837M_1 - 135.2405M_2 + 181.9187M_3 + 3.1891M_1^2 + 39.1139M_2^2 - 53.4583M_3^2$	$8.6391 \times 10^{-6}$
		$WVPM_3^t$	误差
配流盘磨损	$WVPM_1$	$M_1 = 138.2304 + 353.1403M_2 - 1.4848 \times 10^3M_3 + 970.3966M_4 - 53.3168M_2^2 + 382.0087M_3^2 - 183.1422M_4^2 + 91.7458M_2M_3 - 187.3431M_2M_4 - 2.3700M_3M_4$	$1.0277 \times 10^{-5}$
	$WVPM_2$	$M_2 = 5.3421 \times 10^3 - 1.9259 \times 10^3M_1 - 4.1437 \times 10^3M_3 - 63.0927M_4 + 202.1484M_1^2 + 511.1540M_3^2 - 433.4977M_4^2 + 571.7799M_1M_3 + 129.5107M_1M_4 + 779.5238M_3M_4$	$4.7843 \times 10^{-6}$
	$WVPM_3$	$M_3 = 866.9498 - 315.3294M_1 - 169.9799M_2 - 507.5123M_4 + 21.8031M_1^2 - 2.8102M_2^2 + 75.1444M_4^2 + 49.7945M_1M_2 + 87.7945M_1M_4 + 53.0849M_2M_4$	$2.5204 \times 10^{-7}$
	$WVPM_4$	$M_4 = -77.1234 - 83.4002M_1 - 29.3088M_2 + 143.6821M_3 + 24.2911M_1^2 - 8.6108M_2^2 - 41.1135M_3^2$	$4.0423 \times 10^{-4}$
		$WVPM_4^t$	误差
滑靴磨损	$WVPM_1$	$M_1 = -266.0826 + 6.0843M_2 - 751.5171M_3 - 1.0552 \times 10^3M_4 + 47.9053M_2^2 + 47.9053M_3^2 - 105.8440M_4^2 + 257.8741M_2M_3 - 355.9802M_2M_4 - 49.4533M_3M_4$	$1.6299 \times 10^{-11}$
	$WVPM_2$	$M_2 = 145.2786 - 31.3163M_1 - 398.4784M_3 + 261.3386M_4 - 6.1187M_1^2 - 72.7216M_3^2 - 181.5884M_4^2 + 97.1826M_1M_3 - 65.8785M_1M_4 + 278.5355M_3M_4$	$2.1543 \times 10^{-10}$
	$WVPM_3$	$M_3 = 2.8366 \times 10^3 - 654.1847M_1 - 575.4193M_2 - 2.0931 \times 10^3M_4 + 78.2089M_1^2 - 119.7442M_2^2 + 312.7917M_4^2 + 101.5630M_1M_2 + 122.8645M_1M_4 + 477.9291M_2M_4$	$3.8041 \times 10^{-8}$
	$WVPM_4$	$M_4 = -9.1258 \times 10^3 + 934.0193M_1 + 5.4333 \times 10^3M_2 + 4.2940 \times 10^3M_3 + 136.6644M_1^2 - 783.8334M_2^2 - 631.9824M_3^2 - 586.3267M_1M_2 - 240.4261M_1M_3 - 1.0071 \times 10^3M_2M_3$	$1.3944 \times 10^{-7}$

统测量的数据与传统测量的结果基本上一致,说明系统对相关参数的测量有较高的准确性,温度平均误差 0.41%,心率平均误差 1.17%,收缩压平均误差 0.4%,舒张压平均误差 0.9%,这些误差范围不会影响医护人员正确决策,符合实

表 1 体温与脉搏测量数据与传统测量值的对比

时间	体温(单位:摄氏度)		心率脉搏(单位:次每分)	
	DS18B20 传感器	体温计	Pulse sensor 传感器	传统计数
8:00	36.1	36	89	90
10:00	36.4	36.2	92	91
14:00	36.4	36.2	90	88
16:00	36.7	36.8	79	79
20:00	36.9	36.8	88	88
22:00	36.5	36.7	77	79

表 2 血压测量数据与传统测量值的对比

		XGZP6847 血压传感器测量值 (单位:mmHg)		传统血压计测量值 (单位:mmHg)	
状态	时间	收缩压	舒张压	收缩压	舒张压
测试者 1	8:00	109.5	80.25	110	80
	12:00	109.5	88.275	110	75
	17:00	117.75	78	120	80
测试者 2	8:00	102	68.25	100	65
	12:00	90	60	90	60
	17:00	98.25	66	95	65
测试者 2	8:00	125.25	95.25	130	95
	12:00	128.25	98.25	130	100
	17:00	128.25	96	130	95

~~~~~

(上接第 88 页)  
有效性。实验结果表明,该方法的故障诊断准确率达 97.5%。在相同条件下,采用 VPMCD 方法进行模式识别用以对比,准确率为 87.5%。

4 结论

将 WVPMCD 和层次模糊熵应用于液压泵的故障诊断,实验数据分析与比较结果表明,WVPMCD 方法由于在训练时运用加权最小二乘参数估计法代替最小二乘参数估计法,克服了模型可能出现的异方差,提高了预测精度,有效实现了对液压泵的故障诊断。

参考文献:

[1] Raghuraj R, Lakshminaryanan S. Variable Predictive Models—A New Multivariate Classification Approach for Pattern Recognition Applications [J]. Pattern Recognition, 2009, 42 (1): 7-16.  
[2] 程军圣, 马兴伟, 杨 宇. 基于 VPMCD 和 EMD 的齿轮故障诊断方法 [J]. 振动与冲击, 2013, 32 (20): 9-13.

际要求。

5 结论

本系统通过设计基于 ZigBee 的养老院健康监护系统,可有效地对老人的身体指标进行监护,避免老人出现健康状况时无人知晓。本文以 CC2530 为硬件核心构建一个 ZigBee 无线传感网络,详细阐述了协调器节点、终端节点的硬件设计方法和软件设计流程。经实验表明,系统可靠性高、功耗低,能够满足实际应用的要求,使老人能够了解自身的身体情况并且及时休息或者去医院治疗,从而避免耽误救治,为养老院老人健康监护提出了一种新的方法。

参考文献:

[1] 赵锦萌, 吴效明, 张莉莉. 面向家庭的 ZigBee 医疗监护网络研究 [J]. 计算机测量与控制, 2012, 20 (3): 780-783.  
[2] 朱 亮, 王绪国, 庾嘉平, 等. 基于 ZigBee 的医疗监护系统的设计与研究 [J]. 微型机与应用, 2013, 32 (19): 66-68.  
[3] 衣翠平, 柏逢明. 基于 ZigBee 技术的 CC2530 粮库温湿度检测系统研究 [J]. 长春光学精密机械学院学报, 2011, 34 (4): 53-57.  
[4] 吴 响, 张 立, 赵 强, 等. 基于体域网的远程健康监护系统设计 [J]. 电子技术应用, 2014 (3): 19-21.  
[5] 孟仁俊, 丁 辛. 可嵌入服装的 PVDF 压电传感器的研制与应用 [J]. 产业用纺织品, 2010, 28 (2): 26-30.  
[6] 秦 芹. 一种基于 DS18B20 的温度采集新方案 [J]. 电子技术, 2010, 37 (10): 62-64.  
[7] 刘恩华, 徐科明. 基于 ISD1700 SPI 协议模式的语音报警系统 [J]. 电子测试, 2009, (10): 69-72.

[3] 罗颂荣, 程军圣, 郑近德等. GA-VPMCD 方法及其在机械故障智能诊断中的应用 [J]. 振动工程学报, 2014, 27 (2): 289-295.  
[4] 杨 宇, 李永国, 程军圣. WVPMCD 及其在滚动轴承故障诊断中的应用 [J]. 湖南大学学报 (自然科学版), 2014, 41 (2): 52-57.  
[5] Richmann J S, Moorman J R. Physiological Time Series Analysis Using Approximate Entropy and Sample Entropy [J]. American Journal of Physiology—Heart and Circulatory Physiology, 2000, 278: 2039-2049.  
[6] Jiang Ying, Peng C K, Xu Yuesheng. Hierarchical Entropy Analysis for Biological Signals [J]. Journal of Computational and Applied Mathematics, 2011, (236): 728-742.  
[7] Zhu Keheng, Song Xigeng, Xue Dongxin. A Roller Bearing Fault Diagnosis Method Based on Hierarchical Entropy and Support Vector Machine with Particle Swarm Optimization Algorithm [J]. Measurement, 2014 (47): 669-675.  
[8] 陈伟婷. 基于熵的表面肌电信号特征提取研究 [D]. 上海: 上海交通大学, 2008.