

doi:10.11835/j.issn.1000-582X.2018.01.010

# 改进测度下的模糊 C 均值三元催化器故障诊断方法

李鹏华<sup>a,b</sup>, 刘晶晶<sup>a,b</sup>, 冯辉宗<sup>a,b</sup>, 米 怡<sup>a,b</sup>

(重庆邮电大学 a. 自动化学院; b. 汽车电子与嵌入式工程研究中心, 重庆 40000)

**摘要:**针对采用物理建模刻画三元催化器故障演化精确性不足问题,提出一种基于尾气大数据的改进测度模糊 C 均值(FCM, fuzzy c-means),故障诊断方法。该方法包括分数阶傅里叶变换(FRFT, fractional fourier transform)下的故障特征提取与优化、核熵成分分析(KECA, kernel entropy component analysis)下的分形故障特征降维以及改进相似测度下的 FCM 故障特征聚类。首先,对不同工况的尾气数据进行 FRFT 处理,获取三元催化器从时域到频域的精细故障信息,同时利用粒子群算法(PSO, particle swarm optimization)选取最优的 FRFT 特征,并由分形算子给出相应精细特征的分形维数;其次,借助 KECA 对候选的高维分形特征进行维数约简;最后,将获得的故障特征提交给改进测度的 FCM 故障分类器完成故障诊断。数值实验结果表明,较之采用欧式距离或余弦距离的 FCM 方法,研究方法的故障诊断精确度更高。

**关键词:**三元催化器;故障诊断;尾气排放;模糊聚类

**中图分类号:**TP277

**文献标志码:**A

**文章编号:**1000-582X(2018)01-088-11

## Fault diagnosis of three-way catalytic converter using improved fuzzy C-means clustering

LI Penghua<sup>a,b</sup>, LIU Jingjing<sup>a,b</sup>, FENG Huizong<sup>a,b</sup>, MI Yi<sup>a,b</sup>

(a. College of Automation; b. Automotive Electronics Engineering Research Center, Chongqing University of Posts and Telecommunications, Chongqing 400000, P.R.China)

**Abstract:** The model precision of three-way catalytic converter is restricted by its complex physical and chemical reaction, which limits the accuracy of fault diagnosis based on its reaction model. To solve this problem, we propose a fault diagnosis method using improved fuzzy C-means (FCM) clustering. The method includes fault feature extraction and optimization using fractional Fourier transform (FRFT), dimensionality reduction of fractal feature using kernel entropy component analysis (KECA) and FCM fault feature clustering based on improved similarity measure. Firstly, we obtain the detailed features of different fault conditions from time domain to frequency domain using FRFT, then select the optimal FRFT order by particle swarm optimization (PSO) algorithm and these high-dimensional FRFT features with optimal order are transformed into fractal feature vectors through the fractal operator. Next, these fractal feature

**收稿日期:**2017-06-20

**基金项目:**国家自然科学基金资助项目(61403053);重庆高校优秀成果转化项目(KJZH14207)。

Supported by National Natural Science Foundation of China(61403053) and Achievement Transfer Program of Institutions of Higher Education in Chongqing(KJZH14207).

**作者简介:**李鹏华(1984—),男,重庆邮电大学副教授,主要从事故障诊断、深度神经网络方向研究,(E-mail)lipnghua88@163.com。

vectors dimensionality is reduced with KECA. At last, the reduced feature vectors are submitted to the improved FCM for fault clustering analysis. Numerical experiment results show that compared with the FCM method of Euclidean distance or cosine distance, the proposed method could obtain better fault identification result.

**Keywords:** three-way catalytic converter; fault diagnosis; exhaust emission; fuzzy clustering

作为一种有效的汽车排气处理手段,三元催化净化技术被广泛地应用于汽车排放系统,在实现汽车低污染排放方面发挥着重要作用<sup>[1-3]</sup>。但在实际车辆行驶中,三元催化器易出现化学中毒、过热老化、机械损坏和结焦积碳等故障,致使排放水平急剧恶化,造成严重的环境污染。因此,针对三元催化转化器的故障诊断一直是汽车领域重点关注的问题<sup>[4]</sup>。

近几十年来,众多学者对三元催化器做出了大量富有成效的研究<sup>[5-9]</sup>,构建出三元催化器化学反应动力学模型<sup>[5-6]</sup>、传热和流体数值分析模型<sup>[7]</sup>、储放氧模型<sup>[8-9]</sup>等诸多模型来监测分析三元催化器的性能。在模型构建过程中出现的模型复杂度和鲁棒性之间的矛盾长期困扰着研究者,即引入较多反应参数可以提高模型精确性,但会增加计算复杂度,并降低模型的鲁棒性。通过简化模型来降低复杂度提高模型的鲁棒性,却又无法详尽刻画潜在反应过程,使精确度降低,增加故障诊断的难度<sup>[10]</sup>。当前,高速发展的现代传感技术已能实现对汽车尾气成分的准确检测<sup>[3]</sup>,由此产生了海量的排放数据。这些海量的排放数据携带着三元催化器绝大部分物化反应信息,给基于尾气数据的三元催化器故障诊断奠定了基础。虽然当前利用 SVM、神经网络、统计模式识别等智能方法对三元催化器的研究获得一定进展<sup>[11-14]</sup>,但大多关注于对故障模型参数的辨识以及对三元催化器中部分废气的预测,未直接对尾气数据中蕴含的故障信息进行分析<sup>[15-18]</sup>。

事实上,三元催化器的工作过程是一个涉及物化反应、传热、流体流动的复杂过程,加之车辆驾驶方式因人而异,车辆行驶环境复杂多变,所以尾气信号属于一种典型的非线性、随机性和耦合性的非平稳信号。考虑到尾气信号的复杂性且数据驱动的三元催化器故障诊断本质属于模式识别问题,选择合适的故障特征提取方法与分类(聚类)方法对提高三元催化器故障诊断准确性至关重要。分数阶傅里叶变换(FRFT, fractional fourier transform)是一种高精度的时频分析方法,可将原始数据空间中可分性差的信号映射到特定分数阶域来实现耦合信号的分离<sup>[19]</sup>,这给尾气信号的特征提取提供一条有效途径。然而,在 FRFT 结果所构成的高维特征空间中,并不是任意阶次的 FRFT 都能最佳地刻画三元催化器故障特征。为此,引入粒子群优化算法(PSO),借助其建模简单、收敛快速等优点,在构建合理的适应度函数基础上,定位所需的最优 FRFT 阶次。为进一步降低故障聚类的计算开销,采用分形计算<sup>[20]</sup>和核熵成分分析<sup>[21]</sup>(KECA, kernel entropy component analysis),在确保信息损失最小的前提下,将高维故障特征映射到较低维度<sup>[22-23]</sup>。在诸多聚类分析方法中,模糊 C 均值聚类(FCM)<sup>[24]</sup>在故障诊断领域应用最为广泛,但经典的 FCM 仅单一使用欧氏距离或角度作为测度来反映各特征向量之间的距离关系,使分类精度的提高受限。综合考虑这两种测度,通过构造含有欧式距离和角度距离测度来优化迭代目标函数,提高故障分类的精确性。

## 1 改进测度下的模糊 C 均值三元催化器故障诊断方法

基于改进测度的 FCM 三元催化器故障诊断方法流程如图 1 所示。诊断过程主要包括原始信号获取,故障特征提取与故障聚类分析 3 个部分。在获得不同故障工况下的尾气信号之后,通过 FRFT 给出尾气信号从时域逐步变化到频域的所有特征,并采用 PSO 算法选择最优的 FRFT 阶次。这些最优阶次的 FRFT 特征经过分形算子转换成分形特征向量之后,通过 KECA 对候选故障特征实现维数约简。经过降维处理的故障特征向量被提交给改进测度的 FCM 进行故障聚类分析。

### 1.1 分数阶傅里叶变换下的故障特征提取与优化

对携带故障信息的尾气时域信号  $x(t)$  的  $p$  阶分数阶傅里叶变换(FRFT)可定义为

$$X_p(u) = \int_{-\infty}^{+\infty} x(t) K_p(t, u) dt, \quad (1)$$

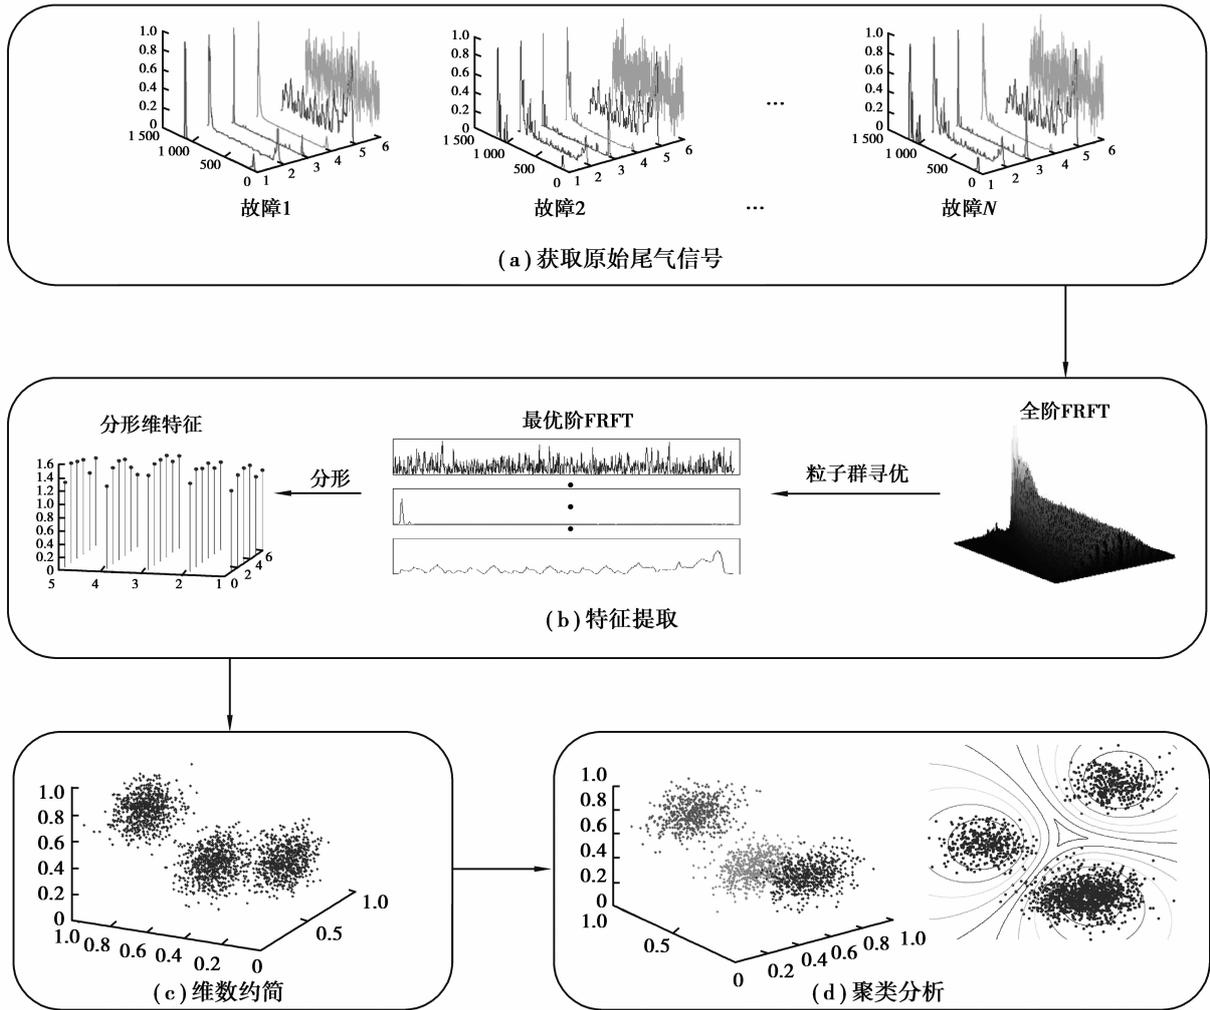


图 1 三元催化器故障诊断流程

Fig.1 Fault diagnostic process of three-way catalytic converter

式中  $K_p(t, u)$  为 FRFT 的核函数, 可表示为

$$K_p(t, u) = \begin{cases} \sqrt{\frac{1 - j \cot \alpha}{2\pi}} e^{\frac{j\pi}{2}[(t^2+u^2)\cot \alpha - 2tucsc \alpha]}, & \alpha \neq n\pi, \\ \delta(t - u), & \alpha = 2n\pi, \\ \delta(t + u), & \alpha = (2n - 1)\pi, \end{cases} \quad (2)$$

其中:  $p$  为变换的阶次, 取值范围一般为  $0 \sim 1$ ;  $p$  阶 FRFT 是在  $(t, \omega)$  平面上旋转  $\alpha$  角度所产生的坐标空间,  $\alpha = \pi p/2$  为变换的旋转角度, 一般取  $0 \sim \pi/2$  的逆时针方向进行分析。由 FRFT 的对称性和周期性可知, 其它角度的信号分析结果与  $0 \sim \pi/2$  旋转角度相一致。随着  $p$  从 0 变到 1, FRFT 平滑地从原函数变化到傅里叶变换。因此, FRFT 能给出信号从时域逐步变化到频域的所有特性。由于在不同 FRFT 变换域上的信号分布呈现不同的特性, 当旋转到一定的分数阶, 原本在时频平面上交错的信号将会分离。为实现故障尾气信号在 FRFT 时频平面上的最优分离, 利用 PSO 算法对 FRFT 变换结果进行搜索。

PSO 算法具体描述为: 在  $p \in [0, 1]$  范围内, 随机产生均匀分布、群体规模为  $N$  的粒子群, 每个粒子代表一个 FRFT 变换结果。其中第  $i$  个粒子位置是  $x_i$ , 飞行速度是  $v_i$ 。根据粒子的适应度值, 第  $k$  次迭代使粒子的自身历史最优位置为  $p_{best}$ , 全局粒子最优位置为  $g_{best}$ , 粒子通过这 2 个不断更新的极值来更新自己的速

度和位置。迭代公式如下

$$v_i^{k+1} = \omega v_i^k + \eta_1 \text{rand}() \cdot (p_{\text{best}} - x_i^k) + \eta_2 \text{rand}() \cdot (g_{\text{best}} - x_i^k), \quad (3)$$

$$x_i^{k+1} = x_i^k + v_i^{k+1}, \quad (4)$$

其中: $k$  为当前进化代数; $\eta_1$ 、 $\eta_2$  为学习因子,一般取  $\eta_1 = \eta_2 = 2$ ,  $\text{rand}()$  为介于 0 到 1 的随机数; $\omega$  为惯性权重。当达到最大迭代次数或适应度函数达到预设值时,停止迭代。此时的全局最优位置  $g_{\text{best}}$  即为所求的最优解。

采用散布矩阵来构建适应度函数  $J$

$$J = \frac{\text{tr}\{S_b\}}{\text{tr}\{S_w\}}, \quad (5)$$

其中  $S_w$  和  $S_b$  分别为类内散布矩阵和类间散布矩阵。

$$S_w = \sum_{i=1}^c P_i E[(x_j^i - \mu_i)(x_j^i - \mu_i)^T], \quad (6)$$

$$S_b = \sum_{i=1}^c P_i [(\mu_i - \mu_0)(\mu_i - \mu_0)^T], \quad (7)$$

其中: $c$  为故障类别数; $P_i$  为第  $i$  类的先验概率; $x_j^i$  表示第  $i$  类样本集中的第  $j$  个样本向量; $E(*)$  为期望值函数; $\mu_i$  表示第  $i$  类样本集的均值向量; $\mu_0$  表示全部样本的均值向量。适应度函数  $J$  代表内离散度与间离散度的差别, $J$  越大表明不同类别间的差别越大,相同类别的相似性越强。

## 1.2 核熵成分分析下的分形故障特征降维

由于 FRFT 给出的故障特征以长度较长的波形表示,不利于后续的故障聚类。因此,引入分形计算对 FRFT 表示的故障特征加以离散化,同时也降低特征向量的长度。分形盒维数的定义由下式给出

$$d_v = \lim_{\epsilon \rightarrow 0} \frac{\ln N_V(\epsilon)}{\ln(1/\epsilon)}, \quad (8)$$

式中: $V$  是  $R^n$  的非空有界子集,由对应的最优 FRFT 特征幅值构成; $N_V(\epsilon)$  表示最大直径为  $\epsilon$  且能覆盖  $V$  集合的最少个数。实际计算中取有限的  $\epsilon$  (介于 1 和 2 之间的一个分数),通过求取一系列  $\epsilon$  和  $N_V(\epsilon)$ ,然后在双对数坐标中用最小二乘法拟合直线,所得直线的斜率即所求分形维数。

考虑到同一类型的三元催化器故障尾气数据包含 CO、HC、NO<sub>x</sub>、CO<sub>2</sub>、H<sub>2</sub>O、N<sub>2</sub> 等多种成分,这些气体成分数据所表征的故障特征向量够成一个高维故障特征空间。为降低故障聚类的计算开销,研究采用核熵成分分析(KECA)对用分形维表示的高维故障特征向量组进行维数约简。KECA 以瑞利熵和 Parzen 窗密度估计为基础,其中二次瑞利熵定义为

$$H(p) = -\log \int p^2(x) dx, \quad (9)$$

KECA 的目标是利用最少的特征最大地呈现式(9)中输入数据的熵值。已知对数函数是单调函数,只需考虑  $V(p) = \int p^2(x) dx$  值的大小。为了估计  $V(p)$ ,引入 Parzen 窗密度估计,即

$$\hat{p}(x) = \frac{1}{N} \sum_{x_i \in \mathbf{D}} k_\sigma(x, x_i), \quad (10)$$

进一步有

$$\hat{V}(p) = \frac{1}{N} \sum_{x_i \in \mathbf{D}} \hat{p}(x_i) = \frac{1}{N} \sum_{x_i \in \mathbf{D}} \frac{1}{N} \sum_{x_i' \in \mathbf{D}} k_\sigma(x_i, x_i') = \frac{1}{N^2} \mathbf{l}^T \mathbf{K} \mathbf{l}, \quad (11)$$

其中: $\mathbf{K}$  为由  $k(x_i, x_i')$  组成的  $N \times N$  核矩阵; $\mathbf{l}$  为元素均为 1 的  $N \times 1$  向量。将核矩阵特征分解,可得  $\mathbf{K} = \mathbf{E} \mathbf{D} \mathbf{E}^T$ ,其中  $\mathbf{D}$  为以特征值  $\lambda_1, \dots, \lambda_N$  为元素的对角矩阵, $\mathbf{E}$  为相应的特征向量  $\mathbf{e}_1, \dots, \mathbf{e}_N$  构成的矩阵。将  $\mathbf{D}$  和  $\mathbf{E}$  矩阵代入式(11),得到

$$\hat{V}(p) = \frac{1}{N} \sum_{x_i \in \mathbf{D}} \hat{p}(x_i) = \frac{1}{N^2} \sum_{i=1}^N (\sqrt{\lambda_i} \mathbf{e}_i^T \mathbf{l})^2. \quad (12)$$

由此可知,上式中核矩阵的特征值、特征向量均对  $\hat{V}(p)$  有贡献。设  $\mathbf{U}_k$  为高维故障特征数据通过非线性

映射  $\Phi$  得到的子空间,  $U_k$  由对  $\hat{V}(p)$  贡献最大的前  $k$  个特征值及特征向量组成, 核熵成分分析的特征映射记为

$$\Phi_{\text{ECA}} = U_k^T \Phi = \sqrt{D_k} E_k^T, \quad (13)$$

对式(13)的求解即可实现对高维故障特征向量组的降维操作, 该求解过程转化为求解最小化问题

$$\Phi_{\text{ECA}} = \sqrt{D_k} E_k^T: \min_{\lambda_1, \epsilon_1, \dots, \lambda_N, \epsilon_N} \hat{V}(p) - \hat{V}_k(p) = \min_{\lambda_1, \epsilon_1, \dots, \lambda_N, \epsilon_N} \frac{1}{N} I^T (K - K_{\text{ECA}}) I, \quad (14)$$

其中,  $K_{\text{ECA}} = \Phi_{\text{ECA}}^T \Phi_{\text{ECA}} = E_k D_k E_k^T$ 。

### 1.3 改进相似测度下的模糊 C 均值故障特征聚类

假设维数约简之后的三元催化剂故障特征样本集合为  $X = \{x_1, \dots, x_k, \dots, x_N\}$ , 相应的模糊分类矩阵  $U = [\mu_{ik}]_{c \times N}$ , 聚类中心向量  $C = [c_1, \dots, c_i, \dots, c_c]$ , 其中  $c$  为聚类中心个数,  $\mu_{ik} \in [0, 1]$  为任意故障特征点  $x_k$  相对于聚类中心  $c_i$  的隶属度,  $d_{ik}$  为故障特征点  $x_k$  到聚类中心  $c_i$  的距离测度。现有的 FCM 单一使用欧氏距离或余弦距离作为测度, 在刻画各特征向量之间距离方面受到限制, 进而影响聚类精确度。为提高聚类精确度, 综合欧氏距离和余弦距离, 提出一种新的测度  $G$

$$G_{ik} = \sqrt{D_{ik}(1 - S_{ik})} \cdot \left[ \frac{D_{ik}(\max D_{ik} - \min D_{ik})}{N} \right], \quad (15)$$

式中,  $S_{ik}$  为故障特征点  $x_k$  到聚类中心  $c_i$  的余弦距离测度, 表示为

$$S_{ik} = \cos \angle(x_k, c_i). \quad (16)$$

$D_{ik}$  为数据点  $x_k$  到聚类中心  $c_i$  的欧式距离, 表示为

$$D_{ik} = \|x_k - c_i\|. \quad (17)$$

综合考虑式(15)、(16)、(17)可得

$$J(C, U) = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m G_{ik} = \sum_{i=1}^c \sum_{k=1}^N (\mu_{ik})^m \sqrt{D_{ik}(1 - S_{ik})} \cdot \left[ \frac{D_{ik}(\max D_{ik} - \min D_{ik})}{N} \right], \quad (18)$$

其中,  $m$  为模糊加权参数、控制数据划分过程中的模糊程度, 通常取 2。对于给定的精度  $\epsilon$ , 改进的 FCM 聚类可按如下步骤实现

1) 计算故障特征的聚类中心

$$c_i = \frac{\sum_{k=1}^N (\mu_{ik}^{t-1})^m x_k}{\sum_{k=1}^N (\mu_{ik}^{t-1})^m}, 0 \leq i \leq c. \quad (19)$$

2) 更新划分矩阵

$$\mu_{ik}^{(t)} = \frac{1}{\sum_{j=1}^c \left( \frac{G_{ik}}{G_{jk}} \right)^{\frac{2}{m-1}}}. \quad (20)$$

3) 迭代计算

$$\|U^{(t)} - U^{(t-1)}\| < \epsilon. \quad (21)$$

## 2 仿真实验

数值实验按国家标准 GB 18352.5: 轻型汽车污染物排放限值及测量方法(中国第五阶段)进行尾气排放数据采集, 采集过程分为 4 个低速运转循环和 1 个高速运转循环。其中, 每个低速循环均采集 195 个数据样本, 高速运转循环采集 400 个数据样本, 每个数据样本长度为  $N=1180$ 。实际尾气数据采集, 考虑工作正常、化学中毒、过热老化、机械损坏、结焦积炭 5 种状态, 每种状态下采集 COH、THC、COL、NO<sub>x</sub>、HC 和 CO<sub>2</sub> 6 种气体数据。在相同工况及约束条件下, 对上述 5 种状态分别进行 20 次独立实验, 共得到 100 组排放数据。图 2 给出了其中一组数据, 该组数据包含了化学中毒、过热老化、机械损坏和结焦积炭 4 种故障状态下的三元催化剂原始尾气信号。

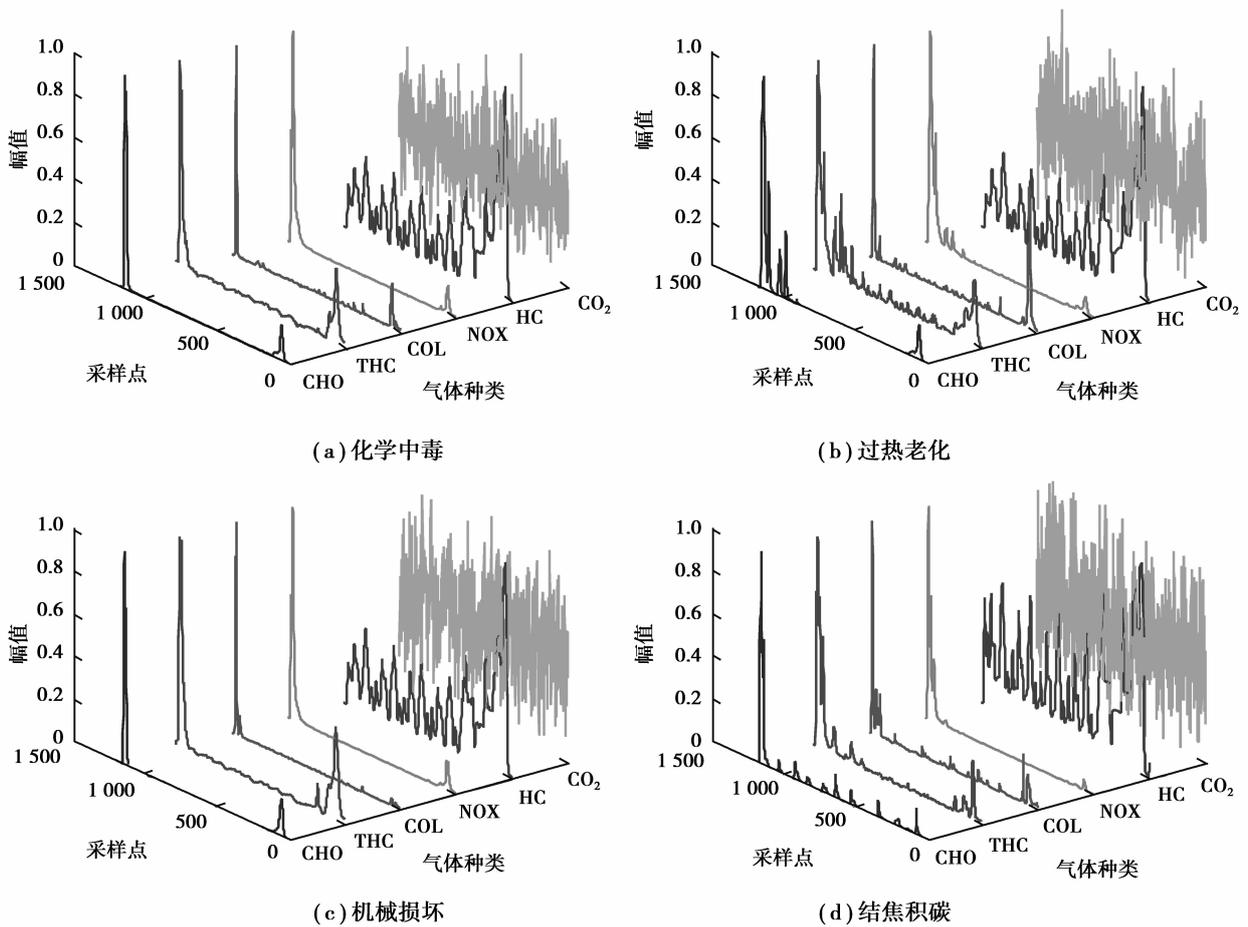


图 2 三元催化器 4 种故障状态下的原始尾气数据  
 Fig.2 Original exhaust data extracting from 4 fault states of three-way catalytic converter

为了清楚地说明三元催化器故障特征的提取与选择过程,以机械损坏故障数据集中的 THC 信号  $x_{THC}(t)$  为例。通过对信号  $x_{THC}(t)$  进行 FRFT,得到该信号的时频域全局特征,如图 3 所示。图 3 中给出在机械损坏情况下,当分数阶次  $p$  从 0 变化到 1 时,  $x_{THC}(t)$  相应从时域到频域的一个连续平滑变化的过程。

为获得最优 FRFT 阶次,使用 PSO 算法对信号  $x_{THC}(t)$  的 FRFT 结果进行寻优搜索。在区间  $[0,1]$  内随机产生均匀分布的 30 个阶次,以这 30 个阶次对应的 FRFT 变换结果初始化粒子群,由此,确定了 30 个粒子的初始位置。设置学习因子  $\eta=2$ ,权重  $\omega=0.75$ ,迭代次数为 100,分数阶次  $p$  的步长为 0.002。寻优得到最佳 FRFT 的阶次  $p$  值为 0.932,对应的 FRFT 特征由图 4(b) 给出。图 4(a)、4(c) 分别给出  $p=0$  (原始信号) 和  $p=1$  (傅里叶变换) 时的变换结果。从图 4 中,可明显看出当  $p=0.932$  时,  $x_{THC}(t)$  信号能量最为集中,这种能量分布的可分性较强,特征更为突出。

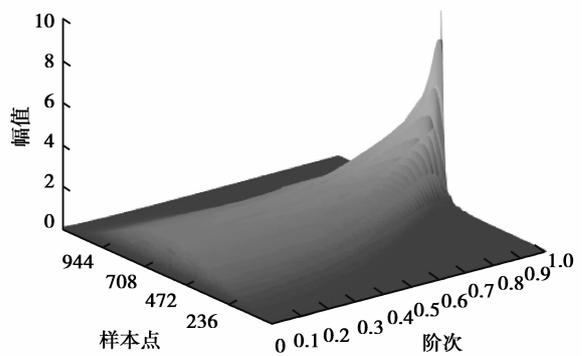


图 3 THC 信号的 FRFT 特征  
 Fig.3 FRFT feature of THC signal

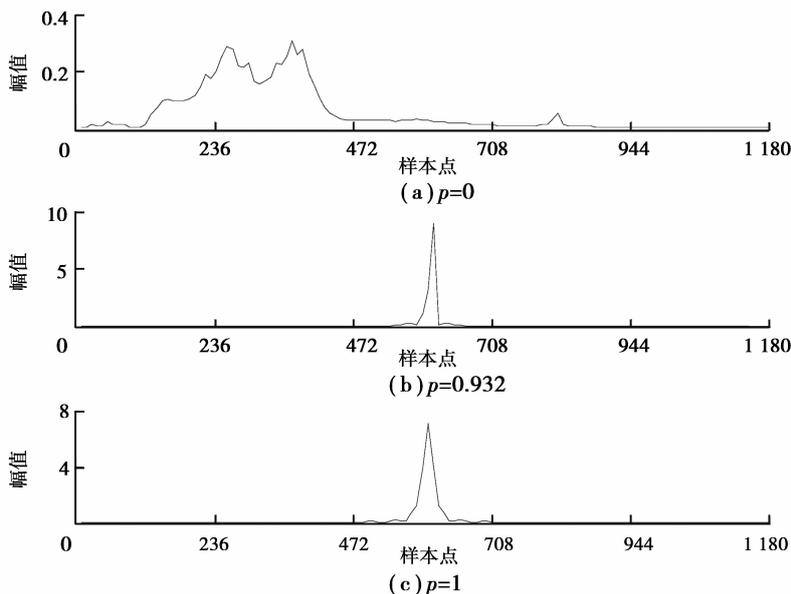


图 4 THC 信号在  $p=0, p=0.932, p=1$  时的变换结果

Fig.4 The FRFT result of THC signal, when  $p=0, p=0.932, p=1$

对 5 种状态下的各气体信号分别进行 FRFT, 并采用 PSO 搜索最优阶次, 构成 5 个故障特征数据集, 每个故障特征数据集都采用三维数组表示, 其维度为  $1180 \times 6 \times 20$ 。此处, 1180 代表各类气体 FRFT 之后的长度, 6 代表气体种类, 20 代表独立实验次数。对上述 5 个故障特征数据集进行分形分析, 得到 5 组  $6 \times 20$  的分形故障特征, 其均值如表 1 所示。

表 1 分形故障特征均值

Table 1 Average of the fractal fault features

数据类型	分形维均值					
	COH	THC	COL	NO <sub>x</sub>	HC	CO <sub>2</sub>
正常	1.232 0	1.401 3	1.442 1	1.420 2	1.182 0	1.218 4
化学中毒	1.320 1	1.471 4	1.418 1	1.431 2	1.290 1	1.316 5
过热老化	1.421 1	1.525 7	1.525 7	1.523 6	1.370 4	1.386 8
机械损坏	1.238 4	1.451 0	1.486 5	1.444 7	1.260 3	1.086 7
结焦积碳	1.274 3	1.493 5	1.458 1	1.418 5	1.154 3	1.316 2

从表 1 可以看出 5 种模式下不同尾气排放数据的分形故障特征, 在气体种类的横向(表 1 的行方向)差异较为明显, 在故障种类的纵向(表 1 的列方向)除“机械损坏”与“正常”在“COH 列”相近, 以及“过热老化”与“结焦积碳”在“CO<sub>2</sub> 列”相近之外, 其他各列差异明显。因此, 采用分形来刻画 5 种状态的特征信息是可行的。

为降低后续故障聚类的计算复杂度, 对以上 6 维候选故障特征运用 KECA 进行特征降维, 核函数宽度取值为  $\sigma=5$ 。得到 5 组  $3 \times 20$  的降维故障特征。为评估 KECA 的有效性, 将新的 5 组  $3 \times 20$  故障特征的行向量进行任意抽取, 构成一个  $3 \times 100$  的数据矩阵。该数据矩阵的三维散点分布如图 5 所示。从图 5

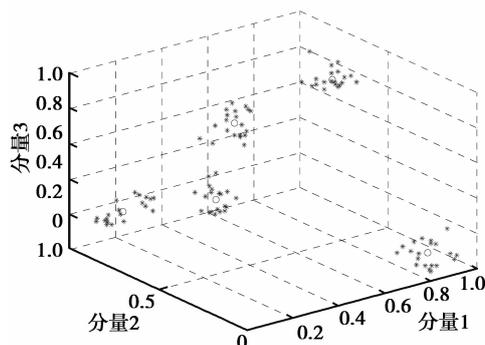


图 5 分形故障特征的三维散点分布

Fig.5 Three-dimensional scatter distribution of the fractal fault feature

中,可以明显看出分形故障特征经 KECA 提取之后,具有明显的聚类倾向。

对 KECA 降维后的 5 组  $3 \times 20$  分形故障特征数据进行改进相似性测度下的 FCM 故障聚类。根据 5 种不同故障模式状态,聚类中心个数定为  $c=5$ ,加权指数  $m=2$ ,迭代终止容差  $\epsilon=0.000 1$ 。迭代计算至收敛得到聚类中心  $C=\{c_1, c_2, c_3, c_4, c_5\}$ ,分别对应正常、化学中毒、过热老化、机械损坏和结焦积炭 5 种状态

$$C = \begin{bmatrix} 0.576 9 & 0.297 7 & 0.460 3 \\ 0.180 7 & 0.231 4 & 0.334 8 \\ 0.163 3 & 0.387 6 & 0.248 7 \\ 0.495 1 & 0.437 1 & 0.328 5 \\ 0.621 4 & 0.130 7 & 0.179 4 \end{bmatrix} \quad (22)$$

故障聚类结果如图 6 所示。其中:图 6(a)为改进测度 FCM 故障聚类的 3 维空间分布;图 6(b)为图 6(a)的二维投影等高线分布。为验证研究方法的有效性,在相同条件下,分别采用欧式距离和余弦距离的 FCM 聚类,其故障聚类结果由图 6(c)和图 6(d)分别给出。从图 6 可清楚看到,采用改进测度、欧式距离、余弦距离的 FCM 方法进行故障聚类,100 组分形故障特征都围绕在 5 个聚类中心周围,正常模式和 4 种故障模式呈明显分离状态,且 4 种故障之间间距较大没有出现混叠现象。相比之下,选用改进测度与余弦距离测度的等高线比欧式距离测度更加符合特征点分布的走势。特别地,在故障特征点偏离聚类中心程度上,采用改进测度的 FCM 较之采用欧式距离和余弦距离的 FCM 要小。

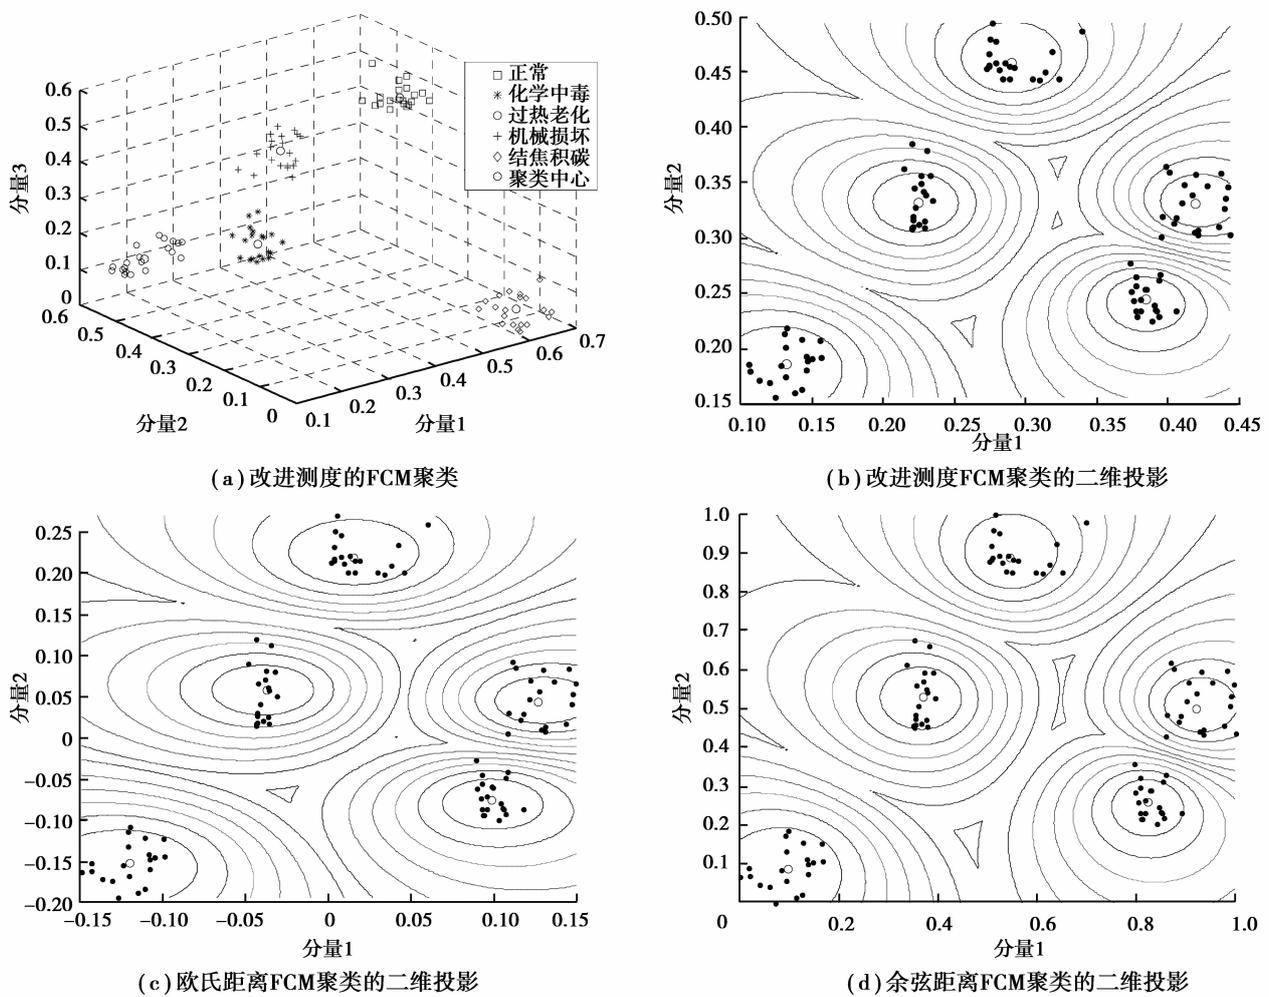


图 6 FCM 故障聚类

Fig.6 The FCM clustering result of fault data

为定量体现改进相似测度 FCM 聚类方法的优点,采用分区索引(SC)和 Xie-Beni 指标(XB)作为评价模糊聚类有效性指标标准。XB 定义为

$$XB = \frac{\sum_{i=1}^c \sum_{k=1}^N (u_{ik})^m d_{ik}}{N \cdot \min_{i \neq k} d_{ik}}, \quad (23)$$

SC 定义为

$$SC = \frac{\sum_{i=1}^c \sum_{k=1}^N (u_{ik})^m d_{ik}}{\sum_{k=1}^N u_{ik} \sum_{j=1}^c d_{ij}}, \quad (24)$$

式中:XB 指标以最小的类与类中心距离平方来衡量类间分离度,是类内紧密度与类间分离度的比值,其值越小表示聚类效果越好。SC 表示聚类紧凑性与分离程度之和的占比,SC 值越低表明划分效果越好。3 种 FCM 故障聚类的定量评价指标由表 2 给出。

表 2 聚类评价指标

Table 2 Evaluation index of clustering

聚类方法 (不同测度)	评价指标	
	SC	XB
欧式距离	0.849 9	4.114 5
余弦距离	0.284 0	3.599 4
改进测度	0.136 9	2.506 0

为进一步验证方法的有效性,另采集 5 种模式下各 60 组数据作为测试样本,重复上述方法对测试样本进行特征提取,再利用最大贴适度原则进行故障识别。测试样本识别结果如表 3 所示

表 3 测试样本识别结果

Table 3 Identification results of test sample

故障种类	改进测度的 FCM		欧式距离的 FCM		余弦距离的 FCM	
	识别样本	准确率/%	识别样本	准确率/%	识别样本	准确率/%
正常	58	96.67	51	85.00	54	90.00
化学中毒	58	96.67	52	86.67	55	91.67
机械失活	57	95.00	55	91.67	56	93.33
过热老化	57	95.00	53	88.33	58	96.67
结焦积碳	58	96.67	56	93.33	54	90.00
平均准确率		96.00		89.00		92.33

从表 3 可以得出,改进测度的 FCM 故障聚类准确率较之采用欧式距离和余弦距离的 FCM 聚类,其故障诊断准确率整体水平最高,平均故障诊断准确率分别为 96%、89%和 92.33%。

### 3 结 论

研究针对三元催化器的故障诊断问题,提出一种利用汽车尾气排放数据对三元催化器进行故障诊断的方法。考虑到尾气信号的复杂性和数据驱动的三元催化器故障诊断本质属于模式识别问题,该方法主要包

括原始信号获取、故障特征提取与故障聚类分析 3 个部分。在获得不同故障工况下的尾气信号之后,通过 FRFT 给出尾气信号从时域逐步变化到频域的所有特征,并采用 PSO 算法选择最优的 FRFT 阶次。这些最优阶次的 FRFT 特征经过分形算子转换成分形特征向量之后,通过 KECA 对候选故障特征实现维数约简。经过降维处理的故障特征向量被提交给改进测度的 FCM 进行故障聚类分析。数值实验结果表明,研究方法能有效对三元催化器的正常、化学中毒、过热老化、机械损坏和结焦积炭 5 种状态进行识别,较之采用欧式距离和余弦距离的 FCM 故障聚类方法,故障诊断准确率更高。

#### 参考文献:

- [ 1 ] Twigg M V. Catalytic control of emissions from cars[J]. *Catalysis Today*, 2011, 163(1):33-41.
- [ 2 ] Granger P, Parvulescu V I. Catalytic NO(x) abatement systems for mobile sources: from three-way to lean burn after-treatment technologies[J]. *Chemical Reviews*, 2011, 111(5):3155-207.
- [ 3 ] 中国环境保护产业协会机动车污染防治技术专业委员会.机动车污染防治行业 2014 年发展综述[J].*中国环保产业*, 2015(10):10-23.  
China Environmental Protection Industry Association Motor Vehicle Pollution Control Technology Specialized Committee. Development report on motor vehicle pollution control industry in 2014 [J]. *China Environmental Protection Industry*, 2015(10): 10-23. (in Chinese)
- [ 4 ] Alkemade U G, Schumann B. Engines and exhaust after treatment systems for future automotive applications[J]. *Solid State Ionics*, 2006, 177(26): 2291-2296.
- [ 5 ] Siemund S, Leclerc J P, Schweich D, et al. Three-way monolithic converter: simulations versus experiments[J]. *Chemical Engineering Science*, 1996, 51(15): 3709-3720.
- [ 6 ] 龚金科,蔡皓,耿玉鹤,等.改进型汽油机三元催化转化器反应模型及试验研究[J].*内燃机学报*,2009,27(5):430-434.  
GONG Jinke, CAI Hao, GENG Yuhe, et al. Improved reaction model and experimental study of gasoline engine three-way catalytic converter [J]. *Transactions of CSICE*, 2009, 27(5): 430-434. (in Chinese)
- [ 7 ] Kumar P, Makki I, Kerns J, et al. A low-dimensional model for describing the oxygen storage capacity and transient behavior of a three-way catalytic converter[J]. *Chemical Engineering Science*, 2012, 73: 373-387.
- [ 8 ] Kwon H J, Hyun Baik J, Tak Kwon Y, et al. Detailed reaction kinetics over commercial three-way catalysts[J]. *Chemical Engineering Science*, 2007, 62(18): 5042-5047.
- [ 9 ] Ma L P, Bart H J, Ning P, et al. Kinetic study of three-way catalyst of automotive exhaust gas: modeling and application[J]. *Chemical Engineering Journal*, 2009, 155(1): 241-247.
- [10] 李晗,萧德云.基于数据驱动的故障诊断方法综述[J].*控制与决策*,2011,01:1-9+16.  
LI Han, XIAO Deyun. Survey on data driven fault diagnosis methods [J]. *Control and Decision*, 2011(01): 1-9. (in Chinese)
- [11] Qiu Z W, Peng X H. Study for monitoring three-way catalyst converter efficiency based on BP ANN and exotherm[C]//*Electric Information and Control Engineering (ICEICE)*. Xi'an: IEEE, 2011: 2640-2644.
- [12] McDowell N, McCullough G, Wang X, et al. Application of auto-associative neural networks to transient fault detection in an IC engine[J]. *Digital Collection*, 2010, 11(2): 555-562.
- [13] Kumar P, Makki I, Filev D, et al. Anon-intrusive three-way catalyst diagnostics monitor based on support vector machines[C]//*Systems, Man and Cybernetics (SMC)*. [S.L.]: IEEE, 2014: 1630-1635.
- [14] Lughofer V, Macián C, Guardiola E P, et al. KlementIdentifying static and dynamic prediction models for NOx emissions with evolving fuzzy systems[J]. *Applied Soft Computing*, 2011, 11(2): 2487-2500.
- [15] Sankavaram C, Kodali A, Pattipati K R, et al. Incremental classifiers for data-driven fault diagnosis applied to automotive systems[J]. *Access IEEE*, 2015, 3: 407-419.
- [16] 阳同光,蒋新华,付强.混合蛙跳脊波神经网络观测器电机故障诊断研究[J].*仪器仪表学报*,2013,34(1):193-199.

- YANG Tongguang, JIANG Xinhua, FU Qiang. Study on motor fault diagnosis using ridgelet neural network observer optimized by shuffled frog leaping algorithm [J]. Chinese Journal of Scientific Instrument, 2013, 34(1): 193-199. (in Chinese)
- [17] Ajami A, Daneshvar M. Data driven approach for fault detection and diagnosis of turbine in thermal power plant using Independent component analysis (ICA)[J]. International Journal of Electrical Power & Energy Systems, 2012, 43(1): 728-735.
- [18] 周东华, 胡艳艳. 动态系统的故障诊断技术[J]. 自动化学报, 2009, 35(6): 748-758.  
ZHOU Donghua, HU Yanyan. Fault diagnosis techniques for dynamic systems [J]. Acta Automatica Sinica, 2009, 35(6): 748-758. (in Chinese)
- [19] 罗慧, 王友仁, 崔江. 基于最优分数阶傅里叶变换的模拟电路故障特征提取新方法[J]. 仪器仪表学报, 2009, 30(5): 997-1001.  
LUO Hui, WANG Youren, CUI Jiang. New approach to extract analog circuit fault features based on optimal fractional fourier transform [J]. Chinese Journal of Scientific Instrument, 2009, 30(5): 997-1001. (in Chinese)
- [20] 肖迎群, 何怡刚. 基于小波分形分析和脊波网络的模拟电路故障诊断方法[J]. 电工技术学报, 2011(11): 105-114.  
XIAO Yingqun, HE Yigang. A fault diagnosis approach for analog circuits based on wavelet fractal analysis and ridgelet network [J]. Transactions of China Electrotechnical Society, 2011(11): 105-114. (in Chinese)
- [21] Jenssen R. Kernel entropy component analysis [J]. Pattern Analysis & Machine Intelligence, 2009, 32(5): 847-860.
- [22] Shekar B H, Kumari M S, Mestetskiy L M, et al. Face recognition using kernel entropy component analysis [J]. Neurocomputing, 2011, 74(6): 1053-1057.
- [23] Xie Z B, Guan L. Multimodal information fusion of audio emotion recognition based on kernel entropy component analysis[C]// IEEE International Symposium on Multimedia. [S.L.]: IEEE Computer Society, 2012: 1-8.
- [24] 冯金富, 鲁卿, 张佳强, 等. 一种基于鲁棒 FCM 算法的故障诊断方法[J]. 仪器仪表学报, 2008, 29(10): 2175-2180.  
FENG Jinfu, LU Qing, ZHANG Jiaqiang, et al. Fault diagnosis based on robust FCM algorithm [J]. Chinese Journal of Scientific Instrument, 2008, 29(10): 2175-2180. (in Chinese)
- [25] 王凤利, 段树林, 于洪亮, 等. 基于 EEMD 和形态学分形维数的柴油机故障诊断[J]. 内燃机学报, 2012(6): 557-562.  
WANG Fengli, DUAN Shulin, YU Hongliang, et al. Fault diagnosis of diesel engine based on EEMD and morphology fractal dimension [J]. Transactions of CSICE, 2012(6): 557-562. (in Chinese)

(编辑 侯 湘)