

基于 K-PSO 稀疏表示的故障分类方法研究

傅蒙蒙¹ 王培良^{1,2}

(杭州电子科技大学新型电子器件研究所 杭州 310018)¹

(湖州师范学院信息与控制技术研究所 湖州 313000)²

摘要 针对现代复杂生产过程中不能准确识别、分类多种故障的问题,提出一种改进的稀疏表示故障分类方法。该方法依据信号的稀疏表示来判断故障所属类别。其具体实现过程首先是利用 K-均值奇异值分解(K-SVD)算法构造过完备字典,使其包含原信息的主要特征,再通过粒子群(PSO)算法有效地搜索并寻找稀疏分解中产生的在过完备字典范围中的最匹配原子,最后利用以该匹配原子为基础的稀疏表示结果实现对多故障问题的分类识别。运用数值仿真验证了该算法的可行性和有效性。同时,针对柴油机燃油系统的故障分类,将该方法与基于 BP 神经网络和 SVM 的分类识别方法进行比较,实验表明该算法在故障分类上具有更好的效果。

关键词 稀疏表示, K-均值奇异值分解算法, 粒子群算法, 故障分类

中图分类号 TP18 **文献标识码** A **DOI** 10.11896/j.issn.1002-137X.2016.12.056

Investigation on Fault Classification Method of K-PSO Sparse Representation

FU Meng-meng¹ WANG Pei-liang^{1,2}

(Institute of New Devices, Hangzhou Dianzi University, Hangzhou 310018, China)¹

(Institute of Information and Control Technology, Huzhou Teachers College, Huzhou 313000, China)²

Abstract In order to solve the problem of multiple faults which can not be identified and classified accurately in modern complex production process, an improved sparse representation fault classification method was proposed. This method is based on the sparse representation of the signal to determine the fault categories. First, the specific implementation process utilizes K-Means Singular Value De-composition(K-SVD) algorithm to construct over complete dictionary with main features in the original message, and then uses the particle swarm optimization(PSO) algorithm to search and find the most matching atom which is generated in sparse decomposition in the range of over complete dictionary. Finally, the results based on the sparse representation realizes classification and identification about multiple faults problem. The validity and practicability of the proposed method is verified by numerical simulation. Meanwhile, the proposed method was compared with the methods based on the BP neural network and SVM classification through the fault classification of diesel engine fuel system. Experiments show that the algorithm has good effect on fault classification.

Keywords Sparse representation, K-SVD algorithm, Particle swarm optimization algorithm, Fault classification

随着设备技术水平的提高和复杂度的日益增加,故障检测和分类成为了现代复杂生产过程中必不可少的部分。故障分类^[1]是在系统对象出现多种故障的情况下,根据类标签已知的对象学习获得一个分类标准,再通过该标准把不同种类的故障区分开来,实现多种故障诊断的方法。近年来,针对故障分类的研究,人们提出了许多方法,尤其是面对复杂工业过程的故障诊断问题。张敏等^[2]针对复杂生产过程中的小故障问题,采用了一对一法,运用多个支持向量机构造多分类器从而进行小故障层次分类。尹金良等^[3]为了克服支持向量机规则化稀疏和核函数参数难以确定等局限,提出了应用于变压器故障检测的基于拉普拉斯近似方法的高斯过程分类算法。贺建军等^[4]受到前人提出的后验概率支持向量机的启发,研究了一种新的高斯过程分类算法,该分类算法直接分析得到

了潜变量函数的后验概率表达式,避免了传统方法计算复杂的问题。李巍华等^[5]提出了一种改进证据合成方法,对各证据体进行组合并结合神经网络实现故障模式的分类识别。赵立杰等^[6]提出了一种非线性最小二乘类条件概率密度函数参数估计方法,该方法使用过程先验知识、概率密度函数和贝叶斯规则来增强对未知样本分类的可靠性,从而提高分类准确率。总体而言,针对不同系统的故障分类,人们都提出了相应的方法来实现,并取得了一定的成效。2006年, Candes 等人提出了压缩传感理论^[7],该理论的本质内容是利用信号具有稀疏性表示的先验知识,由投影获得的少量观测值来进行信号重建。随着对压缩传感器研究的深入,不少学者意识到故障分类问题也可利用优化压缩传感器来求解。稀疏表示分类算法是建立在压缩传感理论基础上的新型分类算法,并在语

到稿日期:2015-10-23 返修日期:2016-03-08 本文受国家自然科学基金项目(61573137)资助。

傅蒙蒙(1991-),女,硕士生,主要研究方向为智能检测与控制方向;王培良(1963-),男,教授,硕士生导师,主要研究方向为智能检测与控制、系统建模与故障诊断、工业自动化等(通信作者)。

音识别、图像识别等领域得到了初步应用^[8,9]。当然,也有不少学者将其理论应用于设备的故障诊断上。例如裴胜玉等^[10]在研究稀疏表示的基础上提出了一种崭新的基于最佳PCA的稀疏表示方法,该方法对直升机旋翼故障问题进行了分类诊断。朱启兵等^[11]提出了应用于滚动轴承故障问题的一种基于核映射的稀疏表达分类算法,该算法通过核映射将原样本映射到维数与训练样本个数相同的高维空间,不仅提高了样本间线性可分,而且改善了分类效果。

本文在基于稀疏表示理论知识的研究上提出了一种改进的故障分类算法,该算法集合了K-均值奇异值分解(K-Means Singular Value De-composition)算法和粒子群(Particle Swarm Optimization)算法优势,命名为K-PSO稀疏表示算法。该算法首先利用K-均值奇异值分解算法构造过完备字典,再利用粒子群算法有效地寻找稀疏分解中的最优原子,最后通过稀疏表示方法确定测试样本在训练样本中的分类。通过仿真实验进行算法的有效性验证,并将该方法与基于BP神经网络和SVM的分类识别方法进行比较分析,结果表明使用K-PSO稀疏表示方法对工业设备故障进行分类是有效的,并且分类效果更好。

1 稀疏表示分类算法

稀疏表示,顾名思义就是把原始信号替换成另一种稀疏或者接近稀疏的简要表达,即将信号投影到正交变换基时,使得很大一部分信号的变化系数的绝对值非常小^[12]。此时的变换基称为原子(Atom),原子所在的集合称为字典(Dictionary),求解稀疏表示的过程称为稀疏分解(Sparse Decomposition)。

根据文献^[13],训练集 X 由训练样本组成,测试集 Y 由剩余的样本组成,其中测试集 Y 中的样本可以由训练集 X 中的样本来稀疏表示。假设 $X_i = [x_{i,1}, x_{i,2}, \dots, x_{i,n_i}] \in R^{m \times n_i}$ 为第 i 类训练样本组成的集合, n_i 为第 i 类样本总数, m 为故障类别数。测试样本 $y \in R^m$ 可以表示为与 X_i 同类的训练样本的线性组合,即

$$y = a_{i,1}x_{i,1} + a_{i,2}x_{i,2} + \dots + a_{i,j}x_{i,j} + \dots + a_{i,n_i}x_{i,n_i}, \quad (1)$$

$a_{i,j} \in R, j=1, 2, \dots, n_i$

其中, $a_{i,j}$ 为线性表示系数。

将 m 类的 k 个训练样本组合在一起,构成了整体训练样本 $A = [A_1, A_2, \dots, A_i, \dots, A_k]$, k 为训练样本类别数。则式(1)中测试样本 $y \in R^m$ 重新定义为:

$$y = Ax \quad (2)$$

在已知 $y \in R^m, A \in R^{m \times n}$ 且 $n > m$ 的前提下,式(2)是一个未知数多于方程表达式个数的方程。求解此类方程,需加上零范数限制,对此限制条件的求解是一个典型的NP-hard难题,在实际中很难计算出其精确解,需寻求有效的近似算法。Candes和Tao提出了当字典和稀疏度满足RIP(Restricted Isometry Property)准则^[14]时 l_0 范数和 l_1 范数解等价理论,即在 x 的稀疏度足够大的条件下, l_0 范数的求解问题可以用过 l_1 范数的凸优化问题来解决。故上述求解问题变为:

$$x^* = \arg \min \|x\|_1 \quad \text{s. t. } y = Ax \quad (3)$$

求解式(3)得: $x = [0, \dots, 0, a_{i,1}, a_{i,2}, \dots, a_{i,n_i}, 0, \dots, 0]$,即

x 的维数 n 为各训练样本个数之和,有且只有第 i 类训练样本为非0元素,即测试样本 y 在训练集 A 上的表示系数 x 为稀疏向量。因此,判断测试样本 y 属于第 i 类。

2 字典的构造

为了使上述稀疏表达更加有效,字典构造是一个极其关键的问题。在早期压缩传感方法中,通常使用标准正交基对信号进行稀疏变换,这种方式展开简单且表示唯一。然而对于复杂的信号,采用固定的正交基不能准确描述信号的所有特征,使得信号达不到足够稀疏,从而影响信号的重构。

Mallat和Zhang等^[15]在小波分析理论的基础上,率先采用过完备字典对信号进行自适应分解。大量的实验表明,在过完备字典下的稀疏表达更为彻底且有效^[16]。K-均值奇异值分解(K-Means Singular Value De-composition, K-SVD)^[17,18]是一种性能优良的信号稀疏分解方法。与传统采用固定的正交基方法相比,K-SVD算法可以根据输入信号的不同进行自适应变化。基于K-SVD的稀疏表达方法是在式(3)的基础上构建出一个目标函数,针对目标函数进行迭代计算以求最优化解,从而获取信号的稀疏化表示。

假设 $A = \{a_i | i=1, 2, \dots, M\}$ 是已知的待训练的字典, $Y = \{y_i | i=1, 2, \dots, N\}$ 是训练信号, $X = \{x_i | i=1, 2, \dots, N\}$ 是稀疏系数,那么目标函数为:

$$\min_{A, X} \{\|y_i - Ax_i\|_F^2\} \quad \text{s. t. } \forall i, \|x_i\|_0 < T_0 \quad (4)$$

其中, T_0 表示稀疏度。

具体算法步骤如下:

1)初始字典 A 。字典矩阵 A 共有 n 个列向量,其中, n 代表信号的原子数目。

2)进行稀疏分解。使用贪婪算法中的正交匹配追踪(Orthogonal Matching Pursuit, OMP)^[19]算法对式(4)进行稀疏编码,并求得稀疏系数。

3)更新字典 A 。对式(5)中的误差 E_k 进行奇异值分解,得到的向量 a_k 作为字典第 k 列的更新。

$$E_k = Y - \sum_{j \neq k} a_j x_j \quad (5)$$

4)循环重复步骤2)和步骤3),直到达到终止条件时结束,最后得到稀疏化后的过完备字典 \hat{A} 。

3 PSO优化寻找最佳原子

研究者们提出了一类近似的计算方法来求解式(2),其中较受青睐的是匹配追踪(MP)^[15]和正交匹配追踪算法。其基本思想是从过完备字典中选择与当前信号残差最匹配的原子,直至残差满足一定条件后,最终信号就用选取出的最优原子线性部分加上最后的残差值来表示。显然,若残差值在可忽略的范围内,则信号由该原子的线性组合来表示。MP算法中信号在字典上的投影是非正交的,使得迭代的结果需进行多次收敛才能达到较好状态,故本文使用OMP算法。

正交匹配追踪OMP算法的具体步骤如下。

1)初始化:残差 $e_0 = y$,所选原子序号的初始集合 $D_0 = \text{null}$,迭代次数 $t=1$ 。

2)选择原子:选择与残差的內积距离最大的原子,即所选择的原子满足

$$\lambda_k = \arg \max_{j=1,2,\dots,N} |\langle e_{k-1}, a_j \rangle|$$

3)更新原子集合: $D_k = D_{k+1} \cup \{\lambda_k\}$ 。

4)求解并更新最优投影: $x^* = \arg \min_t \|y - D_t x\|_2$ 。

5)更新信号残差: $e_t = y - D_t x^*$ 。

6)循环迭代:循环指针 $k = k + 1$,如果满足终止条件则停止算法,否则循环步骤2)一步骤5)。

OMP算法原理简单,但从上述每一步的分解计算上看,其计算量大且复杂。本文为保证所有的原子都参与匹配,纵观全局角度,引入了粒子群(Particle Swarm Optimization, PSO)^[20]算法。它是J. Kennedy和R. C. Eberhart在1995年提出的一种基于群体智能原理的优化算法,源于对鸟群觅食过程中的迁徙和聚集的模拟。该算法采用基于种群的全局搜索策略和简单的速度-位移模式,避免了复杂的操作,具有简单、易实现且需调整参数少等优点。

一个由 m 个粒子组成的群体在 D 维搜索空间中以一定速度飞行,每个粒子在搜索时,在自己搜索的历史最好点和群体内其他粒子的历史最好点的基础上,通过式(6)和式(7)对位置进行变化。

$$v_i(t+1) = v_i(t) + c_1 r_1 (p_i - x_i(t)) + c_2 r_2 (p - x_i(t)) \quad (6)$$

$$x_i(t+1) = x_i(t) + v_i(t+1) \quad (7)$$

其中, t 为当前迭代次数; $v_i(t)$ 称为粒子 i 的当前速度; $x_i(t)$ 是第 i 个粒子的当前位置; p_i 是第 i 个粒子当前搜索到的最优位置; p 是整体搜索到的最优位置; c_1 和 c_2 是非负的加速常数; r_1 和 r_2 是服从 $[0, 1]$ 上均匀分布的随机数。

由于基于OMP算法的稀疏表达求解过程从本质上讲是一个优化问题,因此本文利用粒子群算法良好的全局搜索能力将其应用在过完备字典中选取最匹配原子的问题上,不仅提高了搜索速度,而且利于搜索的全面性。基于PSO算法选取最优原子的方法是以式(8)作为适应度函数,将原子作为待寻优参数,因粒子的飞行速度和位置需在过完备字典中各个参数界定的范围内,故对其做式(9)和式(10)的约束处理。

$$f(x) = \langle R^T f, g_{k_t} \rangle, x \in K \quad (8)$$

$$x_{id} = \begin{cases} X_{dmax}, & x_{id} > X_{dmax} \\ X_{dmin}, & x_{id} < X_{dmin} \end{cases} \quad (9)$$

$$v_{id} = \begin{cases} V_{dmax}, & v_{id} > V_{dmax} \\ -V_{dmax}, & v_{id} < -V_{dmin} \end{cases} \quad (10)$$

为了提高粒子群算法的全局寻优能力,在其定义中加入惯性权重值 ω 。若 $\omega = 0$,则粒子速度并不受其他位置影响,只受当前 p_b 和 g_b 影响;若 $\omega \neq 0$,则粒子有扩展搜索空间的趋势。粒子进行全局搜索的范围取决于 ω 的大小, ω 的值如式(11)所示。粒子搜索步长和 ω 呈递增关系, ω 越大,搜索越广泛; ω 越小,搜索越精细。

$$\omega = \omega_{max} - \frac{\omega_{max} - \omega_{min}}{T_{max}} t \quad (11)$$

其中, ω_{max} 和 ω_{min} 是惯性权值的最大值和最小值,典型取值 $\omega_{max} = 0.9 \sim 1.4$,本文中 $\omega_{max} = 1$, $\omega_{min} = 0.4$, t 是当前进化代数, T_{max} 为最大进化代数。

基于PSO算法选取最优原子方法的具体步骤如下。

1)初始化:确定种群规模 M ,总迭代次数 T ,随机设置粒子的初始位置 $x(t)$ 和速度 $v(t)$ (需以四舍五入原则进行取整操作),每个粒子的 p_b 设为初始值, p_b 中最好的设为 g_b ,并计算粒子的适应度函数。

2)根据式(11)计算并更新 ω 值。

3)更新粒子的飞行速度和位置:根据式(6)和式(7)更新粒子的飞行速度和位置。

4)判断粒子参数是否超出界限并更替:判断当前粒子的位置,若不在过完备字典中,则依照式(9)取边界替换当前粒子位置;判断当前粒子速度,若超出界限,则依照式(10)取边界替换当前粒子速度。

5)计算并评价粒子的适应度值:利用式(8)计算每个粒子的适应度,若该值优于 p_b ,则 p_b 被其代替;若所有粒子中都有 p_b 优于 g_b ,则重新设置。

6)循环迭代:若达到最大的迭代次数,则终止迭代,输出 g_b 和相应的位置参数,否则转向步骤2)继续循环。

7)更新残差:找到最佳匹配原子后,利用式(12)更新残差。

$$e_{k+1} = e_k - |\langle e_k, a_j \rangle| \quad (12)$$

4 K-PSO 稀疏表示算法

本文提出的基于K-PSO稀疏表示的算法首先利用K-均值奇异值分解方法得到既稀疏又包含大量原始信息的过完备字典,然后利用具有良好的全局搜索能力的粒子群算法优化正交匹配追踪算法以求得最优稀疏解,最后通过最优稀疏解呈现出的最佳稀疏表示来判断故障类别。该算法主要步骤如图1所示。




图1 K-PSO稀疏表示算法

(1)生成样本集: k 类的训练样本集 A ,某一类的测试样本 y ,给定稀疏度 T_0 。

(2)归一化处理:对训练样本和测试样本进行归一化处理。

(3)设计过完备字典:使用K-SVD算法对初始字典进行训练得到稀疏化过完备字典。


(4)求解稀疏系数:使用PSO优化OMP算法来对样本求解最优稀疏系数。

(5)分类识别:通过稀疏表示对各样本进行分类识别。


5 实验结果及分析

5.1 数值分析


信号的稀疏表示是在过完备字典下对信号进行稀疏分解。本节通过数据仿真来解析本文提出的K-PSO算法在稀疏表示应用上的可行性。利用Matlab平台中随即产生的250组采样点建立实验模型。粒子群参数的设置:常数 $c_1 = c_2 = 1$,迭代次数 $T = 100$,种群规模 $M = 50$,速度 $V_{max} = (v_1, v_2, v_3, v_4) = (50, 50, 10, 10)$ 。图2(a)~图2(c)分别表示了实际原始采样点数据及利用不同方法构建的稀疏表示。从图中可以看出,OMP算法较好地重构出原始信号,但仍存在一定的偏差,如图2(b)所示,在区间 $[60, 100]$ 和 $[150, 200]$ 组数据重构的误差较为明显。本文提出的K-PSO稀疏表示算法能很好地表示原始信号,其重建的信号与原始信号的差异很小,几乎为0,较经典OMP方法更接近原始信号。故本文提出的基于K-PSO稀疏表示具有一定的可行性。



(a) 原始信号



(b) OMP 稀疏表示信号



(c) K-PSO 稀疏表示信号

图 2 不同方法构建的稀疏表示

5.2 基于 K-PSO 稀疏表示的故障分类实验

燃油系统是柴油机不可缺少的部分,其质量直接影响柴油机的工作过程及整机性能,并且决定其运行的可靠性。本文通过对柴油机燃油系统的故障进行分类实验来验证所提算法的有效性。根据经验,常见的燃油系统的故障主要有针阀卡死、针阀泄漏、出油阀失效、怠速油量、75%供油量和 25% 供油量 6 种故障类型^[21]。依照对燃油设备系统和故障类型的分析,本文选取了最能体现柴油机运行状况的 8 个影响因素,包括最大压力、次最大压力、波形幅度、上升沿宽度、波形宽度、最大余波的宽度、落座压力以及起喷压力。

本研究中,每种故障状态各取 70 个数据样本,其中随机选取 50 个作为训练样本,20 个作为测试样本,对 6 种故障进行分类识别测试,构成如下样本训练数据矩阵:

$$A = [A_1, A_2, A_3, A_4, A_5, A_6]$$

$$= [x_{1,1}, \dots, x_{1,50}, x_{2,1}, \dots, x_{2,50}, \dots, x_{6,1}, \dots, x_{6,50}]$$

5.2.1 数据预处理

由于提取的柴油机燃油系统故障特征参数的物理意义和数量级均有所差异,因此在建立故障训练样本之前需将实验得到的故障特征参数进行归一化处理。

1) 求出训练样本中每个特征参数的最大值:

$$r_{i,\max} = \max(A_i), i=1, \dots, 6$$

2) 对所求得的特征参数通过式(13)进行处理,得到归一化训练样本。

$$A_i^* = A_i / r_{i,\max}, i=1, \dots, 6 \quad (13)$$

其中, A_i^* 为处理后的数据; A_i 为原始数据; $r_{i,\max}$ 为原始数据中特征参数最大值。

5.2.2 实验结果与分析

基于 BP 神经网络、基于 SVM 和基于 K-PSO 方法的训练故障分类识别结果分别如图 3—图 5 所示,其误差如图 6 所示。




图 3 基于 BP 神经网络的故障分类




图 4 基于 SVM 的故障分类




图 5 基于 K-PSO 的故障分类




图 6 分类误差图

从图 3—图 5 的结果可得,实验结果和理想结果的重叠程度不断加强即分类识别准确度不断增加。从图 3 可以看出,BP 神经网络对柴油机燃油系统故障 2 的分类相对其他故障类别的分类效果较好,但对于故障 1 的分类存在较大的误判;从图 4 可知,SVM 方法对各个故障类别都能较均衡地识别出来,各类故障间不存在明显偏差;从图 5 中看出,尽管 K-PSO 稀疏表示方法存在分类识别失误,但对各故障分类判断比其他两类方法准确。从各对比实验图可以看出具有较好分类能力的 SVM 在整体上的分类结果都优于 BP 神经网络方法,但略低于本文提出的基于 K-PSO 稀疏表示方法,尤其是在故障 1、故障 4 和故障 6 上。在柴油机燃油系统故障 6 的诊断上,K-PSO 稀疏表示算法所体现的分类准确率接近 100%,相比其他两种算法明显具有一定的优势。从图 6 还可以看出,K-PSO 稀疏表示方法的误差远小于 BP 神经网络方法和 SVM 方法。

表 1 为在相同的训练样本数据和测试样本数据下不同方法所得故障分类结果的准确度。从中可得出,BP 神经网络和支持向量机的方法对实验故障进行分类的平均识别准确率分

别为 88.66% 和 92.29%。本文提出的基于 K-PSO 稀疏表示分类方法对柴油机燃油系统的各个故障类别的识别分类可达到 90% 以上,其平均识别准确率为 95.49%,较其他两种方法准确率分别提高了 7.7% 和 3.5%。可见,基于 K-PSO 稀疏表示故障分类的方法具有良好的分类识别效果。

表 1 故障分类测试结果

故障类别	测试分类的准确率(%)		
	BP 神经网络	SVM	K-PSO 稀疏表示
1	86.36	92.65	96.82
2	91.75	93.20	92.35
3	87.13	93.09	96.33
4	89.52	89.52	94.19
5	87.54	92.18	95.53
6	89.67	93.09	97.70

结束语 本文提出了一种新型的故障诊断方法,即以稀疏系数为分类依据,对信号进行稀疏表示。具体实现中采用 K-均值奇异值分解算法训练得到过完备字典,使其在一定程度上包含了原信息的主要特征,再使用既简单又具有全局搜索能力的粒子群算法来优化寻找最佳原子,利用优化后的 OMP 算法对实际信号样本进行稀疏系数求解。实验结果表明,使用所提出的方法在分类识别上有较好的性能,本方法具有一定的适用价值。值得注意的是,在训练过程中该算法需花费较长时间,本文由于主要研究故障分类,暂且对时间不做具体的要求。

参 考 文 献

[1] Zhu Z B. Intergrating clustering analysis for fault detection and classification[D]. Hangzhou: Zhejiang University, 2012 (in Chinese)
祝志博. 融合聚类分析的故障检测和分类研究[D]. 杭州: 浙江大学, 2012

[2] Zhang M, Cheng W M, Liu J. Small fault detection and classification method for complex production process[J]. Southwest Jiaotong University, 2014, 49(5): 842-847 (in Chinese)
张敏, 程文明, 刘娟. 复杂生产过程的小故障检测与分类方法[J]. 西南交通大学学报, 2014, 49(5): 842-847

[3] Yin J L, Zhu Y L, Yu G Q, et al. Fault diagnosis of transformers based on Gaussian process classifier[J]. Transactions of China Electrotechnical Society, 2013, 28(1): 158-164 (in Chinese)
尹金良, 朱永利, 俞国勤, 等. 基于高斯过程分类器的变压器故障诊断[J]. 电工技术学报, 2013, 28(1): 158-164

[4] He J J, Zhang J X, Jia S Q, et al. A new Gaussian process classification algorithm[J]. Control and Decision, 2014, 29(9): 1587-1592 (in Chinese)
贺建军, 张俊星, 贾思齐, 等. 一种新高斯过程分类算法[J]. 控制与决策, 2014, 29(9): 1587-1592

[5] Li W H, Zhang S G. Fault classification based on improved evidence theory and multiple neural network fusion[J]. Journal of Mechanical Engineering, 2010, 46(9): 93-99 (in Chinese)
李巍华, 张盛刚. 基于改进证据理论及多神经网络融合的故障分类[J]. 机械工程学报, 2010, 46(9): 93-99

[6] Zhao L J, Yuan D C, Chai T Y. Identification of wastewater operational conditions based on multi-classification probabilistic extreme learning machine [J]. CIESC Journal, 2012, 63(10): 3173-3182 (in Chinese)
赵立杰, 袁德成, 柴天佑. 基于多分类概率极限学习机的污水处理过程操作工况识别[J]. 化工学报, 2012, 63(10): 3173-3182

[7] Donoho D L. Compressed sensing [J]. IEEE Transactions on In-

formation Theory, 2006, 52(4): 1289-1306

[8] Hu Z P, Song S F. Robust image recognition algorithm of maximum likelihood estimation sparse representation based on class-related neighbors subspace[J]. Acta Automatica Sinica, 2012, 38(9): 1420-1427 (in Chinese)
胡正平, 宋淑芬. 基于类别相关邻域子空间的极大似然稀疏表示鲁棒图像识别算法[J]. 自动化学报, 2012, 38(9): 1420-1427

[9] Dong J J, Mao Q R, Hu S L, et al. Sub-coding and Entire-coding Jointly Penalty Based Sparse Representation Dictionary Learning[J]. Computer Science, 2014, 41(10): 122-127 (in Chinese)
董俊健, 毛启容, 胡素黎, 等. 基于子编码和全编码联合惩罚的稀疏表示字典学习方法[J]. 计算机科学, 2014, 41(10): 122-127

[10] Pei S Y, Tong L. A global sparse representation scheme based on PCA for fault identification of helicopter rotor computer engineering and applications[J]. Electronic World, 2014(5): 94-95 (in Chinese)
裴胜玉, 童浪. 最佳 PCA 稀疏表示方法及在直升机旋翼故障识别中的应用[J]. 电子世界, 2014(5): 94-95

[11] Zhu Q B, Yang B, Huang M. Bearing fault diagnosis based on a kernel-mapping sparse representation classification[J]. Journal of Vibration and Shock, 2013, 32(11): 30-34 (in Chinese)
朱启兵, 杨宝, 黄敏. 基于核映射稀疏表示分类的轴承故障诊断[J]. 振动与冲击, 2013, 32(11): 30-34

[12] Olshausen B A, Field D J. Emergence of simple-cell receptive field properties by learning a sparse code for natural images[J]. Nature, 1996, 381(6583): 607-609

[13] Zhou Y, Wang L. Fault signal extraction method based on sparse encoding and Tabu optimization algorithm[J]. Computer Measurement & Control, 2014, 22(7): 2164-2181 (in Chinese)
周晏, 王璐. 基于稀疏编码和禁忌优化的故障信号抽取方法[J]. 计算机测量与控制, 2014, 22(7): 2164-2181

[14] Candès E, Romberg J. Sparsity and incoherence in compressive sampling[J]. Inverse Problems, 2006, 23(3): 969-985

[15] Mallat S G, Zhang Z F. Matching Pursuits With Time-Frequency Dictionaries[J]. IEEE Transactions on Signal Processing, 1993, 41(12): 3397-3415

[16] Wang Z Y, Qin L L, Diao J L. Digital Modulation Recognition Based on Sparse Representation and K-SVD[J]. Computer Science, 2013, 40(10): 65-67 (in Chinese)
王振宇, 秦立龙, 刁俊良. 基于 K-SVD 和稀疏表示的数字调制模式识别[J]. 计算机科学, 2013, 40(10): 65-67

[17] Aharon M, Elad M, Bruckstein A. An K-SVD algorithm for designing overcomplete dictionaries for sparse representation[J]. IEEE Transactions on Signal Processing, 2006, 54(11): 4311-4322

[18] Rubinstein R, Zibulevsky M, Elad M. Efficient Implementation of the K-SVD Algorithm using Batch Orthogonal Matching Pursuit[R]. Technical Report CS, 2009

[19] Pati Y C, Rezaiifar R, Krishnaprasad P S. Orthogonal matching pursuit; recursive function approximation with applications to wavelet decomposition [C] // Proceedings of Asilomar Conference on Signals, Systems and Computers, 1993: 40-44

[20] Kennedy J, Eberhart R. Particle swarm optimization [C] // Proc. IEEE. Int'l. Conf. on Neural Networks, IV. Piscataway NJ: IEEE Service Center, 1995: 1942-1948

[21] Fu Y X, Zhao H, et al. MATLAB neural network application design [M]. Beijing: Machinery Industry Press, 2010 (in Chinese)
傅荟璇, 赵红, 等. MATLAB 神经网络应用设计 [M]. 北京: 机械工业出版社, 2010