

多 PCA 模型及 SVM-DS 融合决策的 服务机器人故障诊断*

袁宪锋¹, 宋沐民¹, 周风余¹, 陈竹敏²

(1. 山东大学控制科学与工程学院 济南, 250061) (2. 山东大学计算机科学与技术学院 济南, 250101)

摘要 针对轮式服务机器人驱动系统故障诊断问题, 提出一种基于多主成分分析 (principal component analysis, 简称 PCA) 模型及支持向量机和 DS 证据理论 (support vector machine and dempster-shafer, 简称 SVM-DS) 融合决策的故障诊断方法, 分别利用正常状态和故障状态下的传感器数据建立多个 PCA 模型。利用正常状态下的 PCA 模型实现故障的检测。传感器数据经多 PCA 模型特征提取后作为 SVM 的输入向量, 实现故障的初步分离。基于混淆矩阵定义 SVM 的全局及局部可信度, 并依据可信度值和故障初步分离结果完成基本概率分配函数的赋值, 以实现 SVM 和 DS 证据理论在故障分离中的有效结合。实验结果表明, 本研究方法能灵敏检测到机器人驱动系统故障的发生, 故障分离平均正确率达 92.6%, 与传统单 PCA 模型的方法相比有更高的正确率和稳定性。

关键词 服务机器人; 故障诊断; 主成分分析; 支持向量机; DS 证据理论

中图分类号 TP206.3; TP242.6; TH17

引言

人口老龄化及劳动力成本大幅度提高等社会问题促使越来越多的服务机器人走入了人们的日常生活, 对服务机器人的可靠性和安全性提出了越来越高的要求, 开展服务机器人故障诊断方法的研究势在必行。在前期的机器人故障诊断研究中, 基于模型的故障诊断方法, 如基于粒子滤波器的机器人故障诊断^[1]、基于卡尔曼滤波的机器人故障诊断^[2]等, 在诊断精度和故障机理阐述方面有着独到的优势, 但随着机器人系统复杂程度的提高, 获取其精确的数学模型十分困难, 限制了该类方法的实际应用。基于数据驱动的故障诊断方法由于不需要系统的精确模型, 仅通过对系统运行数据的挖掘与分析, 即可实现故障诊断功能, 已逐渐成为故障诊断领域的研究热点^[3-4]。

基于 PCA 的故障诊断是数据驱动故障诊断方法的典型代表之一。单独的 PCA 故障诊断方法已经被证实具有较好的故障检测能力^[5], 但在故障分离能力方面存在不足; 因此, PCA 方法通常与神经网络、支持向量机等分类器结合使用, 目前已在内燃

机^[6]、电力系统^[7]等多种场合获得应用。学习机或分类器的引入在一定程度上提高了故障分离的能力, 但这种方法在故障特征向量提取时仅利用了系统正常状态下的单一主元模型, 无法最优描述不同故障状态下的数据变化方向, 导致对系统感知不全面, 故障误诊率较高。

为解决上述问题, 笔者提出一种基于多 PCA 模型及 SVM-DS 融合决策的故障诊断方法。首先, 离线训练阶段, 通过对正常状态数据和各类故障状态数据分别处理, 获得多个 PCA 模型, 利用多 PCA 模型提取相应的故障特征向量, 并对多分类概率型 SVM 进行训练; 其次, 在线诊断阶段, 利用正常状态下的 PCA 主元模型实现故障的检测; 然后, 故障分离时, 分别利用正常状态及不同故障状态下的多 PCA 模型进行特征提取, 将特征向量输入训练好的 SVM, 利用 SVM 的混淆矩阵计算其全局和局部可信度, 基于各 SVM 的可信度值和概率型输出结果实现基本概率分配 (basic probability assignment, 简称 BPA) 赋值; 最后, 通过 DS 算法对各 BPA 进行融合, 给出最终的故障分离结果。陪护机器人驱动系统故障诊断实验表明, 该方法能够有效地降低误诊率。

* 国家自然科学基金资助项目 (61375084); 山东大学基本科研业务费资助项目 (2014JC034)
收稿日期: 2014-05-04; 修回日期: 2014-06-27

1 机器人驱动系统的构成及故障诊断

1.1 轮式服务机器人驱动系统构成

可靠的驱动系统是服务机器人完成高精度自主导航定位的重要保证。与腿足式等驱动方式相比,轮式驱动具有运动精度高、反应灵敏、控制简单等优点;因此,目前的家庭服务机器人大多采用轮式驱动。轮式服务机器人驱动系统通常由车轮、电机、码盘、陀螺仪、电机驱动器以及相应的机械结构等组成,其结构框图如图 1 所示。

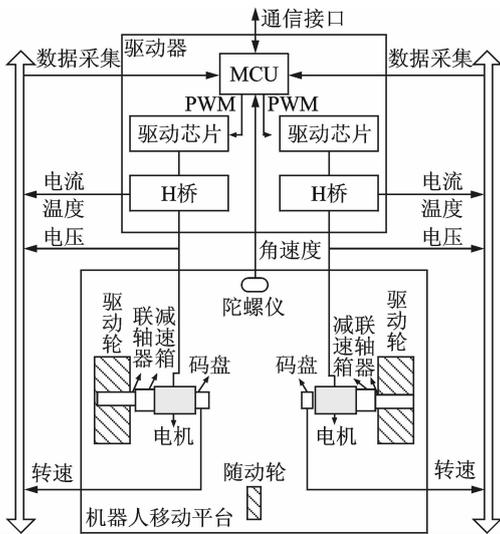


图 1 轮式服务机器人驱动系统结构框图

Fig.1 Structure diagram of the wheeled robot driving system

1.2 驱动系统故障诊断问题

轮式服务机器人驱动系统的故障可以分为机械故障和传感器故障两大类,每一类又可细分为很多小类。通过对机器人实际使用过程中驱动系统故障出现部位的统计分析及相关文献^[1,8],结合机器人驱动系统的构成,讨论机器人在使用过程中发生概率较高及危险程度较大的 7 种典型故障,如表 1 所示,相应的故障空间为 $S_{err} = \{S_1, S_2, \dots, S_7\}$ 。

为了对表 1 所示的 7 种故障进行有效的检测和分离,需要确定故障征兆空间即驱动系统可用的有效传感信号。其中,电机转速、驱动电压、电枢电流、角速度 4 种信号与机器人驱动系统工作状态密切相关^[8],可作为特征信号对驱动系统运行状况进行监测。H 桥温度可间接反应驱动系统的工作状况,但会受环境温度影响。笔者将其变化率作为第 5 个特征信号,最终确定的故障征兆空间为{左轮转速 V_l ,

表 1 故障类型

Tab.1 Fault categories

故障种类	故障部位	故障模式	代码
机械故障	左车轮	胎压不足	S_1
	右车轮	胎压不足	S_2
	左侧联轴器	松动	S_3
	右侧联轴器	松动	S_4
传感器故障	左侧码盘	丢码	S_5
	右侧码盘	丢码	S_6
	陀螺仪	常值漂移	S_7

右轮转速 V_r ,左轮驱动电压 U_l ,右轮驱动电压 U_r ,左轮电枢电流 I_l ,右轮电枢电流 I_r ,左侧 H 桥温度变化率 T_l ,右侧 H 桥温度变化率 T_r ,角速度 W }。

2 多 PCA 模型的 SVM-DS 融合决策故障诊断方法

多 PCA 模型的 SVM-DS 融合决策故障诊断方法包括离线建模和在线监控两个过程。离线建模主要包括机器人各运行状态下传感器数据的采集与处理、多 PCA 模型的建立、故障检测阈值的设定、故障特征向量的提取及多分类概率型 SVM 的训练。在线诊断阶段包括故障检测与故障分离,利用正常状态 PCA 模型的 Q 统计量作为检测阈值实现故障的检测。故障分离时,利用多 PCA 模型提取故障特征向量,将其输入训练好的支持向量机,其概率型输出结果作为初步判决结果,结合其全局和局部可信度值完成 BPA 的赋值,利用 DS 算法实现各 BPA 融合,给出最终故障分离结果。算法整体流程图见图 2。

2.1 离线建模过程

设机器人共有 $h + 1$ 种运行状态 $S_{all} = \{S_0, S_1, \dots, S_i \dots S_h\}$,其中: S_0 为正常运行状态; $S_1 \sim S_h$ 为 h 种故障状态。机器人驱动系统共装配有 m 个传感器,本研究中, $h = 7, m = 9$ 。设每种运行状态下采集 n 组样本数据,则所有离线训练数据集可以记为 $D_{all} = [D_0, D_1 \dots D_i \dots D_h]^T$ 。其中: $D_i \in R^{n \times m}$ ($i = 0, 1, \dots, h$); D_0 为正常状态下的采样数据集; $D_i = [d_{i(1)} \dots d_{i(j)} \dots d_{i(m)}]^T$ 为第 i 种故障状态下的采样数据集; $d_{i(j)} \in R^{m \times 1}$ ($j = 1, 2, \dots, n$), j 为采样次数, $d_{i(j)}$ 为第 i 种状态下第 j 次采集的 m 个传感器数据。

2.1.1 PCA 模型的建立及故障阈值的设定

利用不同状态下的采样数据集 $D_i = [d_{i(1)}, d_{i(2)} \dots d_{i(j)} \dots d_{i(m)}]^T \in R^{n \times m}$, ($i = 0, 1, \dots, h$),重复步骤 1~3,直到分别建立各状态下的 PCA 模型。建模

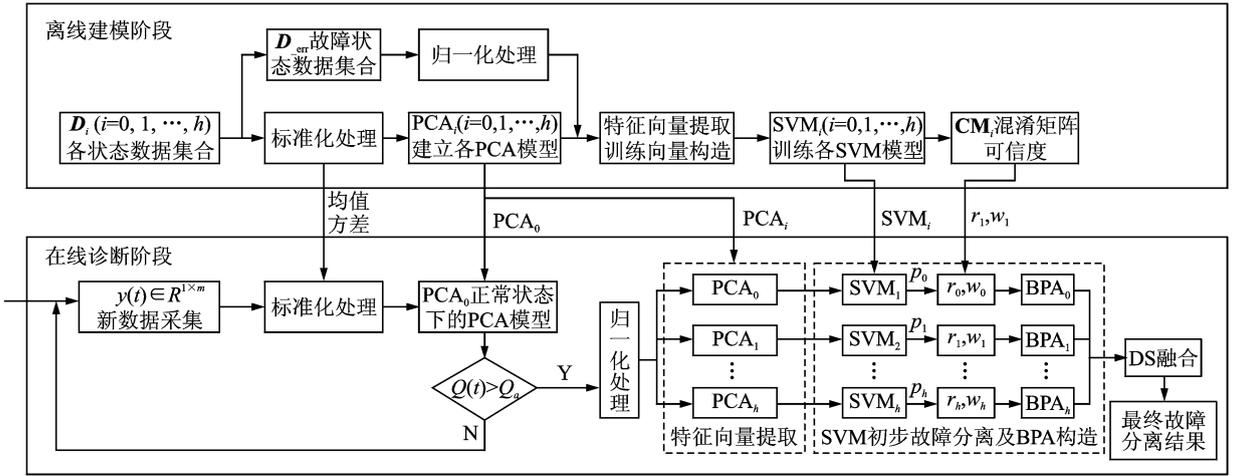


图2 算法整体流程图

Fig. 2 Flowchart of the overall algorithm

步骤如下。

1) 数据的标准化处理

$$\bar{D}_i = (D_i - I_n D_{\text{mean}_i}^T) / \sqrt{D_{\text{var}_i}} \quad (1)$$

其中: $D_{\text{mean}_i} \in R^{m \times 1}$ 为 D_i 的各维均值列向量; I_n 为 n 维全 1 列向量; $D_{\text{var}_i} = \text{dig}(\sigma_1^2, \sigma_2^2 \cdots \sigma_j^2 \cdots \sigma_m^2)$, σ_j^2 为第 j 个传感器的测量值的方差, 通过归一化处理降低了传感器数据不同量纲对建模的影响。

2) 计算样本的协方差矩阵

$$C_i = \bar{D}_i^T \bar{D}_i / (m - 1) \quad (2)$$

对 C_i 进行正交分解得: $C_i = V_i \Lambda_i V_i^T$ 。其中: $\Lambda_i = \text{dig}(\lambda_1, \lambda_2 \cdots \lambda_r \cdots \lambda_m)$ ($\lambda_1 \geq \lambda_2 \geq \cdots \lambda_r \cdots \geq \lambda_m$); $V_i = [v_1, v_2, \cdots, v_r, \cdots, v_m]$ 为特征值 λ_r ($r = 1, 2, \dots, m$) 对应的特征向量 v_r 构成的特征矩阵。

3) 确定主元个数

$$\eta_r(k) = \sum_{r=1}^k \lambda_r / \sum_{r=1}^m \lambda_r \quad (3)$$

一般要求主元贡献率 $\eta_r \geq 85\%$, 笔者取 $\eta_r \geq 90\%$ 。前 k 个特征向量构成的组合 $\tilde{V}_i = [v_1, v_2, \dots, v_k]$ 构成主元空间即载荷矩阵, $\hat{V}_i = [v_k, v_{k+1} \cdots v_m]$ 构成残差空间。经 PCA 处理后, \bar{D}_i 可以分解为

$$\bar{D}_i = \hat{D}_i + e_i = T_s \tilde{V}_i^T + T_e \hat{V}_i^T \quad (4)$$

其中: $T_s = \bar{D}_i \tilde{V}_i$, T_s 为主元得分矩阵; $T_e = \bar{D}_i \hat{V}_i^T$, T_e 为残差矩阵。

Q 统计量描述了测量值相对主元模型的偏离程度, 其控制限常被用作一种有效的故障检测阈值。 Q 统计量的控制限可以通过式(5)^[5]计算

$$Q_c = \theta_1 \left[\frac{h_0 c_\alpha \sqrt{2\theta_2}}{\theta_1} + 1 + \frac{\theta_2 h_0 (h_0 - 1)}{\theta_1^2} \right]^{1/h_0} \quad (5)$$

$$\text{其中: } h_0 = 1 - \frac{2\theta_1 \theta_3}{3\theta_2^2}; \theta_1 = \sum_{r=k+1}^m \lambda_r; \theta_2 = \sum_{r=k+1}^m \lambda_r^2; \theta_3 =$$

$\sum_{r=k+1}^m \lambda_r^3$; λ_r 为协方差矩阵 C_0 的特征值; c_α 为正态分布在显著性水平为 α 下的临界值(本研究取 $\alpha = 0.05$); k 为主元个数, k 值由式(3)确定。

2.1.2 多分类概率型 SVM 的训练

SVM 是近年来发展起来的基于统计学习理论和结构风险最小化原则的新型学习机, 与神经网络相比, SVM 可以更好地适应于小样本学习问题^[9]。

传统的 SVM 只能实现样本的二分类, 且 SVM 的输出结果为硬判型输出。为了实现 DS 融合, 需要在融合前将 SVM 输出映射为后验概率输出。笔者利用逐对耦合法和一对一多分类 SVM 方法^[10]实现由二分类 SVM 到多分类概率型 SVM 的转换, 通过求解式(6)所示的优化问题得到各类的后验概率 $p_i (y = i | x)$

$$\begin{cases} \min_p \frac{1}{2} \sum_{i=1}^h \sum_{j=1, j \neq i}^h (r_{ji} p_i - r_{ij} p_j)^2 \\ \text{s. t. } \sum_{i=1}^h p_i = 1 \quad (p_i \geq 0, \forall i) \end{cases} \quad (6)$$

其中: $i, j = 1, 2, \dots, h$, 且 $i \neq j$, h 为类别数; r_{ij} 为第 i 类和第 j 类两两配对时 x 属于 i 类的后验概率。

多分类概率型 SVM 训练的具体步骤为: 首先, 对 h 种故障样本数据 $D_{\text{err}} = [D_1 \cdots D_i \cdots D_h]^T \in R^{h \times m}$ 进行归一化处理得 $\bar{D}_{\text{err}} \in [0, 1]$; 然后, 将归一化后的数据分别向建立各 PCA_i 模型投影, 得 $D_{\text{train}_i} = \bar{D}_{\text{err}} \tilde{V}_i \in R^{h \times k}$, \tilde{V}_i 为 PCA_i 的载荷矩阵, k 为主元个数; 最后, 以投影后的矩阵 D_{train_i} ($i = 0, 1, \dots, h$) 作为 SVM_i ($i = 0, 1, \dots, h$) 的训练样本。SVM _{i} 核函数采

用径向基高斯核函数,利用粒子群算法^[11](particle swarm optimization,简称PSO)完成SVM_{*i*}参数*c*和*g*的寻优工作,并采用5折交叉验证的方式保证分类器的推广能力。

2.1.3 DS融合决策BPA的构造

DS证据理论的基本思想是通过合成规则将来自多个证据体的信任函数融合为一个新的信任函数,并以此作为决策依据^[12]。

构造客观合理的BPA是DS证据理论应用中至关重要的一步,为了保证BPA赋值的客观性,需要对SVM_{*i*}(*i* = 0, 1, ..., *h*)的分类结果进行评价。混淆矩阵能够描述样本真实属性和分类结果之间的关系,可用于分类器性能评价。对于*h*种故障分离问题,SVM_{*i*}的混淆矩阵可以表示为

$$\mathbf{CM}_i = \begin{bmatrix} c_{11} & c_{12} & \cdots & c_{1h} \\ c_{21} & c_{22} & \cdots & c_{2h} \\ \vdots & \vdots & c_{pq} & \vdots \\ c_{h1} & c_{h2} & c_{h3} & c_{hh} \end{bmatrix} \quad (7)$$

其中:*c_{pq}*表示真实属性为*p*的故障被分类器SVM_{*i*}判别为第*q*种故障的数目占*p*类故障样本总数的百分比;元素的行下标表示故障的真实类型,列下标表示分类器的识别类型。

定义SVM_{*i*}的分类平均正确率为

$$\bar{\gamma}_i = \sum_{p=1}^h (c_{pp} N_p) / N \quad (8)$$

其中:*N_p* = *n*, *N* = *hn*,分别表示第*p*类故障的样本数和D_{train_{*i*}}包含的训练样本总数,化简得 $\bar{\gamma}_i = \sum_{p=1}^h c_{pp} / h$; $\bar{\gamma}_i$ 为对分类器SVM_{*i*}判决结果的一种全局可信度。

混淆矩阵行向量*c_p*(*p* = 1, 2, ..., *h*)表示第*p*类故障样本进行分离时对各故障模式的倾向性,列向量*c_q*(*q* = 1, 2, ..., *h*)则能反映出分类器对第*q*类故障的局部可信度。定义SVM_{*i*}的局部可信度为

$$\omega_{iq} = c_{iq} / \sum_{p=1}^h c_{pq} \quad (q = 1, 2, \dots, h) \quad (9)$$

将其融入SVM_{*i*}的概率型判决输出*p_{iq}*并归一化可得

$$p'_{iq} = \omega_{iq} p_{iq} / \sum_{q=1}^h \omega_{iq} p_{iq} \quad (10)$$

由此,可以定义其BPA为

$$m_i(S_1, S_2, \dots, S_h, \Theta, \phi) = (\bar{\gamma}_i p'_{i1}, \bar{\gamma}_i p'_{i2}, \dots, \bar{\gamma}_i p'_{ih}, 1 - \bar{\gamma}_i, 0) \quad (11)$$

由式(11)可知,识别框架 $\Theta = \{S_1, S_2, \dots, S_h, \Theta, \phi\}$,其中*S_h*为机器人的第*h*种故障状态,式(11)满足*m*(*S₁*) + *m*(*S₂*) + ... + *m*(*S_h*) + *m*(Θ) = 1, *m*(ϕ) = 0,符合BPA的定义要求。

2.2 在线诊断过程

2.2.1 基于Q统计量的故障检测

设*y*(*t*) ∈ *R*^{1×*m*}为*t*时刻采集得到的*m*个传感器的数据,利用式(1),对*y*(*t*)进行标准化处理得 $\bar{\mathbf{y}}(t) = (\mathbf{y}(t) - \mathbf{D}_{\text{mean}_0}^T) \mathbf{D}_{\text{var}_0}^{-\frac{1}{2}}$,其中D_{mean₀}和D_{var₀}分别表示D₀的各维均值列向量和各传感器测量方差。由式(4)可将 $\bar{\mathbf{y}}(t)$ 在主元空间 $\tilde{\mathbf{V}}_0$ 和残差空间 $\hat{\mathbf{V}}_0$ 分别投影,进而求得估计 $\mathbf{e}(t) = \bar{\mathbf{y}}(t) \mathbf{V}_0 \mathbf{V}_0^T$,计算*y*(*t*)的均方预测误差*Q*(*t*),并将其与式(5)得到的故障检测阈值*Q_a*比较,若*Q*(*t*) > *Q_a*,则认为出现故障进入故障分离阶段。

2.2.2 故障分离

对*y*(*t*)进行归一化处理得 $\bar{\mathbf{y}}(t)$,将 $\bar{\mathbf{y}}(t)$ 分别向PCA_{*i*}做投影得到 $\mathbf{y}_{\text{train}_i} = \bar{\mathbf{y}}(t) \tilde{\mathbf{V}}_i$ (*i* = 0, 1, ..., *h*),将 $\mathbf{y}_{\text{train}_i}$ 分别输入已经训练好的SVM_{*i*},由式(11)可得各SVM_{*i*}对应的BPA,利用DS算法进行决策层次融合,给出最终的故障分离结果。

3 故障诊断实例与结果分析

3.1 实验条件与数据获取

实验是在图3所示的陪护机器人样机上进行的。该机器人驱动系统采用双轮差分驱动,装备有1个L3GD20陀螺仪、2个增量式码盘、2个DS18B20温度传感器、2路电压检测电路及2路电流检测电路,完全满足本研究故障诊断算法的硬件要求。通过机器人底层主控ARM芯片完成传感器数据的采集与上传工作,数据采样频率设定为10 Hz,分别在{*S₀*, *S₁* ... *S_i* ... *S₇*} 8种运行状态下,对驱动系统的9个传感器连续采样150组数据,得到第*i*种状态下的采样数据集*D_i* ∈ *R*^{150×9}(*i* = 0, 1, ..., 7)。从每组*D_i*中取前100组数据作为训练数据D_{train_{*i*}} ∈ *R*^{100×9},后50组作为测试数据D_{test_{*i*}} ∈ *R*^{50×9}。



(a) 机器人外观
(a) Appearance of the companion robot
(b) 内部控制系统及结构
(b) Internal control system and structure

图3 陪护机器人样机

Fig. 3 Prototype of the companion robot

3.2 建模过程及分析

3.2.1 PCA模型的建立

按照各 PCA 模型的建立过程,分别建立 $\{S_0, S_1 \cdots S_i \cdots S_7\}$ 对应的 8 个 PCA 模型。以 S_0 运行状态为例,图 4 给出了 PCA_0 对应的主元方差贡献率图。由图 4 可知,当主元贡献率 $\eta_r = 90\%$ 时,主元个数 $k_0 = 5$ 。实验中,由式(5)得到的故障检测阈值 $Q_0 = 4.20$ 。

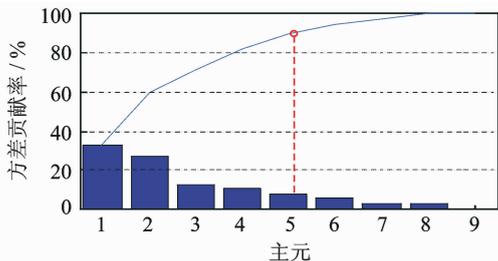
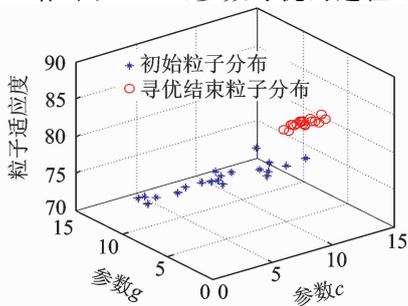


图 4 PCA_0 主元方差贡献率

Fig. 4 The primary variance contribution rate of PCA_0

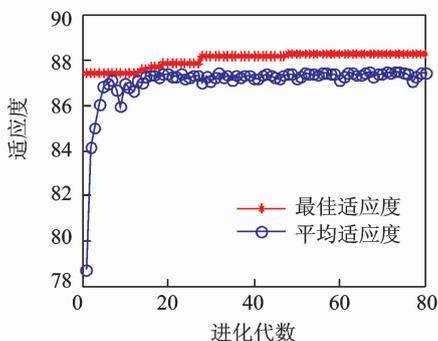
3.2.2 SVM的训练及可信度的计算

利用 7 种故障状态数据集 $D_{err} \in R^{700 \times 9}$ 及 $PCA_i (i=0, 1, \dots, 7)$ 模型,构造 SVM_i 的训练向量 $D_{train_i} \in R^{700 \times 5}$,利用 PSO 算法实现参数 c 和 g 的寻优。图 5 给出了 SVM_0 参数寻优的过程,通过 PSO



(a) 粒子分布情况

(a) Distribution of the particles



(b) 粒子适应度曲线

(b) Fitness curve of the particles

图 5 PSO 参数寻优过程

Fig. 5 Parameter optimization using PSO

算法得到 SVM_0 的最优参数: $c=6.880, g=0.178$, 其余 $SVM_i (i=1, 2, \dots, 7)$ 最优参数见表 2。

以 SVM_0 为例,其混淆矩阵为

$$\begin{bmatrix} 43 & 0 & 7 & 0 & 0 & 0 & 0 \\ 0 & 43 & 0 & 7 & 0 & 0 & 0 \\ 20 & 0 & 29 & 0 & 1 & 0 & 0 \\ 0 & 5 & 0 & 45 & 0 & 0 & 0 \\ 0 & 0 & 1 & 0 & 49 & 0 & 0 \\ 0 & 1 & 0 & 0 & 0 & 49 & 0 \\ 0 & 0 & 0 & 0 & 0 & 0 & 50 \end{bmatrix}$$

按照笔者给出的可信度值计算方法,可以算出 SVM_0 的全局可信度 $\bar{\gamma}_0 = 0.880$,局部可信度 $\omega_0 = \{0.683, 0.878, 0.784, 0.865, 0.980, 1.000, 1.000\}$, 其余 $SVM_i (i=1, 2, \dots, 7)$ 的可信度值及最优参数值已在表 2 中给出。

3.3 故障检测与分离结果分析

3.3.1 基于 Q 统计的故障检测

对测试样本 $D_{test_i} \in R^{50 \times 9} (i=0, 1, 2, \dots, 7)$ 按顺序进行组合构成测试样本集合 $D_{test} \in R^{400 \times 9}$, 利用所述步骤进行故障检测试验,故障检测的结果见图 6。由图 6 可见,前 50 组为正常样本,51~400 组为 7 类故障样本。基于 Q 统计的 PCA 故障检测灵敏地检测出了机器人驱动系统故障的发生。

3.3.2 BPA 的构造与故障分离

利用表 2 给出的 SVM_i 全局及局部可信度值,结合式(11)可计算出相应的 BPA 值,以故障 1 (S_1) 和故障 3 (S_3) 为例,在实验过程中随机抽取了 2 组记录,如表 3 所示。

通过分析表 3 第 11 列的识别结果可知,利用单 PCA 模型进行特征提取并利用 SVM 对故障 S_1 和故障 S_3 进行分离时会出现误诊现象,但是通过 DS 融合可以得到正确的故障类别信息。误诊现象出现,既说明 S_1 和 S_3 的故障征兆较为相似,也说明了单 PCA 模型存在对系统感知不全面的问题。

通过分析表 3 中 $m(S_1)$ 和 $m(S_3)$ 的值可知,初步判决结果通过 DS 融合后的 BPA 值与融合前单特征 BPA 值相比,增大了实际目标的信任度,有效降低了故障分离的不确定性。说明多 PCA 模型能够更加全面地感知系统的运行信息,DS 融合利用多特征信息,能够更准确地实现故障的分离。

采用笔者给出的故障诊断方法,得到 350 组测试样本最终的故障分离效果,如图 7 所示。

由图 7 可见,当故障征兆极为相似时(如部分

S_1, S_3 故障样本),采用本研究方法虽然仍会存在少量分离错误的现象,但融合后的故障分离正确率达到了 92.0%,与传统单 PCA₀ 故障诊断方法的正确率相比提高了 4 个百分点。

3.3.3 对比实验

为了进一步验证算法效果,设计对比实验:首

先,分别采集 10 组测试样本集合,每组包含 140 个故障样本(7 类故障,每类 20 个样本),仅利用正常状态下的单 PCA₀ 模型进行特征提取;然后,利用 SVM 进行故障分离,仍采用 PSO 算法实现 SVM 的参数寻优,连续进行 10 次试验。10 次实验的故障分离正确率对比如图 8 所示。

表 2 SVM_i 可信度值及最优参数

Tab. 2 Confidence values and optimal parameters of SVM_i

分类器	全局可信度	局部可信度							最优参数	
	γ_0	ω_{i1}	ω_{i2}	ω_{i3}	ω_{i4}	ω_{i5}	ω_{i6}	ω_{i7}	c	g
SVM ₁	0.914	0.887 0	0.870	0.915	0.854	0.980	0.958	1.000	6.384	0.110
SVM ₂	0.900	0.935 1	0.796	0.855	0.741	1.000	1.000	1.000	10.420	0.100
SVM ₃	0.868	0.729 4	0.902	0.750	0.878	0.855	0.960	1.000	9.740	0.105
SVM ₄	0.894	0.820 0	0.880	0.804	0.808	1.000	0.958	0.970	10.278	0.100
SVM ₅	0.903	0.732 1	0.909	0.756	1.000	0.924	1.000	1.000	10.471	0.165
SVM ₆	0.842	0.769 0	0.770	0.733	0.727	0.906	1.000	1.000	2.304	0.100
SVM ₇	0.883	0.820 0	0.857	0.800	0.827	0.891	0.979	0.980	12.000	0.113

表 3 BPA 赋值及融合实验记录

Tab. 3 Assignment of BPA and record of the fusion experiment

故障模式	PCA _i	$m(S_1)$	$m(S_2)$	$m(S_3)$	$m(S_4)$	$m(S_5)$	$m(S_6)$	$m(S_7)$	$m(\Theta)$	识别结果
故障 1(S_1) 左轮胎压不足	PCA ₀	0.518	0.002	0.350	0.003	0.002	0.002	0.003	0.120	S_1
	PCA ₁	0.734	0.002	0.124	0.002	0.057	0.001	0.003	0.077	S_1
	PCA ₂	0.461	0.001	0.406	0.002	0.025	0.002	0.003	0.100	S_1
	PCA ₃	0.432	0.002	0.305	0.002	0.123	0.002	0.003	0.131	S_1
	PCA ₄	0.429	0.002	0.441	0.002	0.015	0.002	0.003	0.106	S_3
	PCA ₅	0.607	0.002	0.234	0.003	0.049	0.002	0.003	0.100	S_1
	PCA ₆	0.670	0.001	0.115	0.002	0.051	0.002	0.002	0.157	S_1
	PCA ₇	0.536	0.002	0.155	0.002	0.182	0.002	0.003	0.118	S_1
	融合	0.991	0	0.009	0	0	0	0	0	S_1
故障 3(S_3) 左侧联轴器松动	PCA ₀	0.708	0.002	0.154	0.002	0.009	0.002	0.003	0.120	S_1
	PCA ₁	0.034	0.002	0.876	0.003	0.004	0.001	0.002	0.078	S_3
	PCA ₂	0.256	0.001	0.626	0.001	0.012	0.002	0.002	0.100	S_3
	PCA ₃	0.558	0.002	0.289	0.003	0.013	0.002	0.002	0.131	S_1
	PCA ₄	0.535	0.001	0.335	0.002	0.015	0.001	0.001	0.110	S_1
	PCA ₅	0.494	0.002	0.367	0.003	0.032	0.002	0.003	0.097	S_1
	PCA ₆	0.335	0.002	0.464	0.003	0.034	0.002	0.003	0.157	S_3
	PCA ₇	0.234	0.002	0.611	0.003	0.028	0.002	0.003	0.117	S_3
	融合	0.168	0	0.832	0	0	0	0	0	S_3

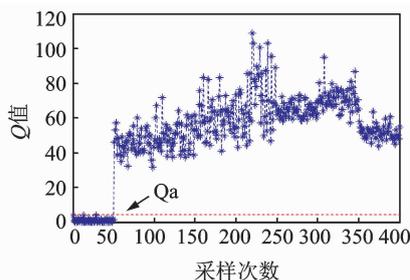


图 6 故障检测结果

Fig. 6 Fault detection result

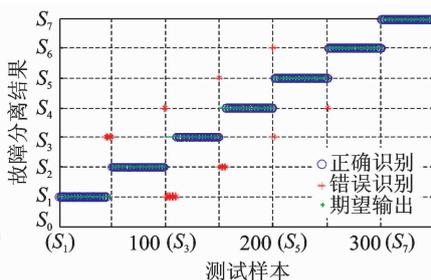


图 7 故障分离效果图

Fig. 7 Fault isolation result

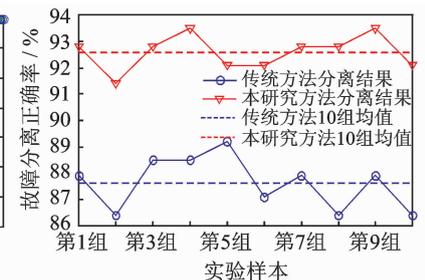


图 8 故障分离对比实验

Fig. 8 Fault isolation contrast experiment

由图8可见,在10次实验过程中,利用本研究基于多PCA模型的SVM-DS融合决策故障诊断算法的故障分离正确率最低为91.4%,均值为92.6%,方差为 6.5×10^{-3} ;而传统方法最高正确率仅为89.2%,均值为87.6%,方差为 10×10^{-3} 。通过对比实验,进一步说明笔者所提方法在故障分离正确率和稳定性方面较传统单PCA模型故障诊断方法均有较好的提升。

4 结论

1) 基于多PCA模型的SVM-DS融合决策故障诊断方法,不仅具有传统PCA故障检测灵敏度高的优点,而且通过多PCA模型及DS证据理论的引入,较好地解决了传统的单PCA模型故障诊断方法对系统运行信息感知不全面的问题。

2) 给出了一种利用混淆矩阵计算SVM分类器可信度值的方法,基于该可信度值并结合SVM分类器的概率型输出结果构造BPA。这种BPA构造方法提高了BPA赋值的客观性,减少了证据间的冲突,有利于融合出正确的故障类别属性。

3) 针对服务机器人驱动系统7种常见故障的诊断问题,给出了详细的实验步骤和数据。结果表明所提出的故障诊断方法能有效提高故障分离能力和稳定性,对机器人驱动系统故障诊断具有较高的实用价值,为机器人故障自诊断提供了一种途径。

参 考 文 献

- [1] Yu Lingli, Wu Min, Cai Zixing, et al. A particle filter and SVM integration framework for fault-proneness prediction in robot dead reckoning system[J]. WSEAS Transactions on System, 2011, 10(11): 363-375.
- [2] Auger F, Hilairret M, Guerrero J M, et al. Industrial applications of the kalman filter: a review[J]. IEEE Transactions on Industrial Electronics, 2013, 60(12): 5458-5471.
- [3] Wang Hong, Chai Tianyou, Ding Jinliang, et al. Data driven fault diagnosis and fault tolerant control: some advances and possible new directions[J]. Acta Automatica Sinica, 2009, 35(6): 739-747.
- [4] 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, 26(1): 1-9.
Li Han, Xiao Deyun. Survey on data driven fault diagnosis methods [J]. Control and Decision, 2011, 26(1): 1-9. (in Chinese)
- [5] Ding S, Zhang P, Ding E, et al. On the application of PCA technique to fault diagnosis[J]. Tsinghua Science & Technology, 2010, 15(2): 138-144.

- [6] 刘永斌, 何清波, 孔凡让, 等. 基于PCA和SVM的内燃机故障诊断[J]. 振动、测试与诊断, 2012, 32(2): 250-255.
Liu Yongbin, He Qingbo, Kong Fanrang, et al. Fault diagnosis of internal combustion engine using PCA and SVM[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(2): 250-255. (in Chinese)
- [7] Ni Jianjun, Zhang Chuanbiao, Yang Simon X. An adaptive approach based on KPCA and SVM for real-time fault diagnosis of HVCBs[J]. IEEE Transactions on Power Delivery, 2011, 26(3): 1960-1971.
- [8] 林吉良, 蒋静坪. 基于模糊聚类的移动机器人并发故障诊断[J]. 浙江大学学报:工学版, 2010, 44(3): 453-457.
Lin Jiliang, Jiang Jingping. Diagnosis of simultaneous faults for mobile robots based on fuzzy clustering method[J]. Journal of Zhejiang University: Engineering Science, 2010, 44(3): 453-457. (in Chinese)
- [9] 肖剑, 周建中, 张孝远, 等. 基于Levy-ABC优化SVM的水电机组故障诊断方法[J]. 振动、测试与诊断, 2013, 33(5): 839-844.
Xiao Jian, Zhou Jianzhong, Zhang Xiaoyuan, et al. Fault diagnosis for hydroelectric generator unit based on levy flight-artificial bee colony and support vector machine[J]. Journal of Vibration, Measurement & Diagnosis, 2013, 33(5): 839-844. (in Chinese)
- [10] Chang C C, Lin C J. LIBSVM: a library for support vector machines[J]. ACM Transactions on Intelligent Systems and Technology (TIST), 2011, 2(3): 1-27.
- [11] Liu Zhiwen, Cao Hongrui, Chen Xuefeng, et al. Multi-fault classification based on wavelet SVM with PSO algorithm to analyze vibration signals from rolling element bearings[J]. Neurocomputing, 2013, 99: 399-410.
- [12] 曹建福, 曹雯. 基于改进证据理论的大型制造装备故障诊断[J]. 振动、测试与诊断, 2012, 32(4): 532-537.
Cao Jianfu, Cao Wen. Fault diagnosis of large manufacturing equipment based on improved evidence fusion theory[J]. Journal of Vibration, Measurement & Diagnosis, 2012, 32(4): 532-537. (in Chinese)



第一作者简介:袁宪锋,男,1989年3月生,博士研究生。主要研究方向为服务机器人技术、故障诊断与预测。
E-mail: yuanxianfeng_sdu@126.com

通信作者简介:周凤余,男,1969年3月生,博士、教授、博士生导师。主要研究方向为智能机器人技术、故障诊断与容错控制等。
E-mail: zhoufengyu@sdu.edu.cn