

基于 KPCA 和 PSOSVM 的异步电机故障诊断*

李平, 李学军, 蒋玲莉, 曹宇翔

(湖南科技大学机械设备健康维护省重点实验室 湘潭, 411201)

摘要 针对异步电机故障振动信号具有较强的非线性特征, 而传统的线性分析方法易造成振动信号非线性成分的丢失这一情况, 提出一种核主元分析和粒子群支持向量机相结合的异步电机故障诊断方法。利用核函数实现输入空间到高维特征空间的非线性映射以及对映射数据的主元分析, 得到原始样本的非线性主元, 实现特征提取和数据压缩, 将获得的核主元特征通过支持向量机进行模式识别。采用距离比值法和粒子群算法分别对核主元分析和支持向量机的参数进行双重优化选择。实验结果表明, 该方法能有效提取故障信号的非线性特征, 具有较强的非线性模式识别能力, 相比主元分析和支持向量机方法, 分类效果更好, 实时性更强, 可快速有效实现异步电机故障诊断。

关键词 核主元分析; 支持向量机; 异步电机; 故障诊断

中图分类号 TM343.2; TP306.3; TH165.3

引言

信号特征提取是异步电机状态监测与故障诊断的关键技术, 它关系到故障诊断的准确性和早期预报的可靠性^[1]。主元分析 (principle component analysis, 简称 PCA)^[2] 是一种常用的特征提取方法。它通过提取原变量的主元特征, 把多个变量化为少数几个主元, 这些主元是原变量的线性组合, 尽可能多地表征了原变量的数据结构信息, 且各主元所包含的信息互不重叠、互不相关^[3]。然而, 主元分析是基于高斯统计假说的, 从本质上讲是一种线性方法, 处理非线性问题的效果较差。

异步电机是由多种机械系统和电气系统组成的动力设备, 内部存在多种场的耦合, 如机电耦合和电磁耦合等, 是一个典型的多变量、强耦合、非线性系统。在运行过程中, 各部件相互关联、相互影响, 当某一个或几个部位发生故障时, 由于系统内外的非线性因素常引起设备的非线性振动, 采集的振动信号具有较强的非线性特征。它携带了丰富的设备运行状态信息, 用传统的线性方法处理非线性信号易造成非线性成分的丢失, 影响故障诊断的效果。可见, 需要采用非线性方法对故障信号进行分析和处理。

核主元分析 (kernel principle component analysis, 简称 KPCA) 是一种非线性主元分析方法, 它不仅保持了 PCA 的各种数学与统计性质, 同时具有较强的处理非线性问题的能力。异步电机故障诊断属于典型的小样本问题, 支持向量机 (support vector machines, 简称 SVM) 处理小样本非线性分类问题具有传统方法无可比拟的优势。笔者将 KPCA 和 SVM 结合应用于异步电机故障诊断, 采用 KPCA 提取故障信号的非线性主元特征, 以核主元特征子集作为 SVM 的训练样本, 结合一对一分类法构建多类 SVM 分类器, 实现对异步电机故障的分类识别。

1 核主元分析与支持向量机基本原理

1.1 核主元分析与核参数寻优

核主元分析^[4-6] 是主元分析的非线性推广, 其基本思想是通过非线性映射 Φ 将输入空间的数据样本 x_1, x_2, \dots, x_n 映射到高维特征空间, 在高维特征空间进行主元分析, 从而有效提取数据样本的非线性结构信息。假设映射数据的均值为零, 则其协方差矩阵为

* 国家高技术研究发展计划 (“八六三” 计划) 资助项目 (2013AA041105); 国家自然科学基金资助项目 (51105138); 湖南省教育厅资助项目 (11A034); 湖南省科技计划资助项目 (2012GK3100); 湖南省高校科技创新团队支持计划资助项目
收稿日期: 2012-08-05; 修回日期: 2012-11-23

$$C = \frac{1}{n} \sum_{i=1}^n \Phi(\mathbf{x}_i) \Phi(\mathbf{x}_i)^T \quad (1)$$

对 C 进行特征向量分解, 设特征值 λ 对应的特征向量为 \mathbf{v} , 则有

$$\lambda \mathbf{v} = C\mathbf{v} \quad (2)$$

其中: $\mathbf{v} = \sum_{i=1}^n a_i \Phi(\mathbf{x}_i)$ 。

将 $\Phi(\mathbf{x}_k)$ ($k=1, 2, \dots, n$) 与式(2)两端作内积, 得到

$$\lambda \sum_{i=1}^n a_i (\Phi(\mathbf{x}_k) \cdot \Phi(\mathbf{x}_i)) = \frac{1}{n} \sum_{i=1}^n a_i \sum_{j=1}^n (\Phi(\mathbf{x}_k) \cdot \Phi(\mathbf{x}_j)) (\Phi(\mathbf{x}_j) \cdot \Phi(\mathbf{x}_i)) \quad (3)$$

定义核矩阵 $\mathbf{K} = (k_{ij})_{n \times n}$, $k_{ij} = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j))$, 则式(3)简化为

$$n\lambda \boldsymbol{\alpha} = \mathbf{K}\boldsymbol{\alpha} \quad (4)$$

其中: $\boldsymbol{\alpha} = (a_1, a_2, \dots, a_n)^T$ 。

问题转化为求核矩阵 \mathbf{K} 的特征值和特征向量。设 $\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_m$ ($m \leq n$) 为 \mathbf{K} 的非零特征值, $\boldsymbol{\alpha}^1, \boldsymbol{\alpha}^2, \dots, \boldsymbol{\alpha}^m$ 为相应的特征向量, 进而求出协方差矩阵 C 的归一化特征向量 \mathbf{v}^k ($k=1, 2, \dots, m$), 则样本 \mathbf{x} 的第 k 个非线性主元为

$$h_k = (\mathbf{v}^k \cdot \Phi(\mathbf{x})) = \sum_{i=1}^n a_i^k K(\mathbf{x}_i, \mathbf{x}) \quad (5)$$

如果映射数据均值不为零, 就要对其进行中心化, 可通过用 $\bar{\mathbf{K}}$ 代替式(4)中的 \mathbf{K} 来实现

$$\bar{\mathbf{K}} = \mathbf{K} - \mathbf{A}_n \mathbf{K} - \mathbf{K} \mathbf{A}_n + \mathbf{A}_n \mathbf{K} \mathbf{A}_n \quad (6)$$

其中: $\mathbf{A}_n = (a_{ij})_{n \times n}$; $a_{ij} = 1/n$ 。

从输入空间到高维特征空间的非线性映射是通过核函数内积运算实现的。目前, 常用的核函数有高斯径向基(RBF)核函数、多项式(Poly)核函数和神经网络(sigmoid)核函数等。RBF 核函数具有计算过程简单和分类效果好等特点。笔者选用高斯径向基核函数, 其表达式为

$$K(\mathbf{x}, \mathbf{y}) = \exp\left(-\frac{\|\mathbf{x} - \mathbf{y}\|^2}{2\sigma^2}\right) = \exp(-g \|\mathbf{x} - \mathbf{y}\|^2) \quad (7)$$

核参数 σ 的取值对 KPCA 性能有很大影响, 应用 KPCA 时应当对核参数进行优化选择, 优化的目标是降低特征维数, 提高特征数据的可分性。设有 k 类数据样本 $\mathbf{x}_{i1}, \mathbf{x}_{i2}, \dots, \mathbf{x}_{in_i}$ ($i=1, 2, \dots, k$), 经 KPCA 处理后的低维核主元特征为 $\mathbf{y}_{i1}, \mathbf{y}_{i2}, \dots, \mathbf{y}_{in_i}$, 其聚类中心为 $\bar{\mathbf{y}}_i = \frac{1}{n_i} \sum_{j=1}^{n_i} \mathbf{y}_{ij}$ ($i=1, 2, \dots, k$)。 k

类核主元特征的内类距离和类间距离分别定义为

$$c_\sigma = \sum_{i=1}^k \frac{1}{n_i} \sum_{s=1}^{n_i} \|\mathbf{y}_{is} - \bar{\mathbf{y}}_i\| \quad (8)$$

$$d_\sigma = \sum_{1 \leq i < j \leq k} \|\bar{\mathbf{y}}_i - \bar{\mathbf{y}}_j\| \quad (9)$$

各类核主元特征数据的类间距离越大, 类内距离越小, 则类别的可分性越好, 建立优化函数为

$$F(\sigma) = \frac{d_\sigma}{c_\sigma} \quad (10)$$

求解 $\max(F(\sigma))$, 对应的 σ 便为优化参数。

1.2 支持向量机与粒子群算法

支持向量机^[7-8]是建立在统计学习理论和结构风险最小化原理基础上的新型机器学习方法。设有二类线性可分样本集 $(\mathbf{x}_i, \mathbf{y}_i)$ ($\mathbf{x}_i \in \mathbf{R}^m$; $\mathbf{y}_i \in \{-1, +1\}$; $i=1, 2, \dots, n$), 寻求分类间隔最大的最优分类面可归结为求解凸二次优化问题

$$\begin{cases} \min \frac{1}{2} \|\boldsymbol{\omega}\|^2 + C \sum_{i=1}^n \xi_i \\ \text{s. t. } \mathbf{y}_i [(\boldsymbol{\omega} \cdot \mathbf{x}_i) + b] \geq 1 - \xi_i \\ (\xi_i \geq 0; i=1, 2, \dots, n) \end{cases} \quad (11)$$

其中: $\boldsymbol{\omega}$ 为权重向量; b 为分类阈值; ξ_i 为松弛因子; C 为惩罚因子。

利用拉格朗日乘数法求解优化问题(11), 得到最优分类函数为

$$f(\mathbf{x}) = \text{sgn}\left(\sum_{i=1}^N \alpha_i \mathbf{y}_i (\mathbf{x}_i \cdot \mathbf{x}) + b\right) \quad (12)$$

其中: N 为支持向量个数; α_i ($i=1, 2, \dots, N$) 为拉格朗日乘数。

若样本集非线性可分, 则通过非线性映射 Φ 将输入空间的样本映射到线性可分的高维特征空间, 在高维特征空间中构造最优分类面。分类算法仅使用点积运算 $(\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j))$, 对于满足 Mercer 条件的核函数 $K(\mathbf{x}_i, \mathbf{x}_j)$ 存在对应关系 $K(\mathbf{x}_i, \mathbf{x}_j) = (\Phi(\mathbf{x}_i) \cdot \Phi(\mathbf{x}_j))$ 。因此, 在最优分类面中采用适当的核函数就可实现高维特征空间的线性分类, 其最优分类函数为

$$f(\mathbf{x}) = \text{sgn}\left(\sum_{i=1}^N \alpha_i \mathbf{y}_i K(\mathbf{x}_i, \mathbf{x}) + b\right) \quad (13)$$

多类 SVM 分类问题可看成是多个二分类问题的组合。目前, 常见的 SVM 多分类方法有一对多、一对一和有向无环图等。在大多数情况下, RBF 核函数和一对一分类法将获得更高的分类精度^[9]。笔者选用一对一分类法来构建异步电机的多类 SVM 分类器。

RBF 核函数参数 g 及惩罚因子 C 直接影响到

SVM 的分类效果。可见,合理选择参数值对保证 SVM 性能至关重要。

粒子群算法(particle swarm optimization,简称 PSO)^[10-11]是一种基于群体智能理论的全局寻优方法,它通过群体中粒子间的协作与竞争实现复杂空间中最优解的搜索。在解空间中初始化一群粒子,每个粒子都表示优化问题的一个解,用位置、速度和适应度值刻画其特征,适应度值由适应度函数确定。每个粒子都在解空间中迭代搜索,通过不断调整自身的速度和位置来搜索新解。速度和位置的更新公式为

$$\mathbf{v}_i^{k+1} = \omega \mathbf{v}_i^k + c_1 r_1 (\mathbf{p}_i^k - \mathbf{x}_i^k) + c_2 r_2 (\mathbf{p}_g^k - \mathbf{x}_i^k) \quad (14)$$

$$\mathbf{x}_i^{k+1} = \mathbf{x}_i^k + \mathbf{v}_i^{k+1} \quad (15)$$

其中: k 为当前迭代次数; $\mathbf{v}_i^k, \mathbf{x}_i^k$ 为粒子 i 当前的速度和位置; $\mathbf{p}_i^k, \mathbf{p}_g^k$ 为当前个体最优解和全局最优解; ω 为惯性权重; c_1, c_2 为加速度因子; r_1, r_2 为 $[0,1]$ 内随机数,这里选用 PSO 算法来优化 SVM 的参数。

2 实验分析

2.1 振动信号采样

故障实验在美国 SpectraQuest 公司的机械故障综合模拟实验台上进行,被测设备为 Marathon 公司的三相变频调速异步电机,功率为 2.24kW,频率为 50Hz,电压为 380V。采用美国 PCB608A11 加速度传感器和奥地利 Dewetron 公司 DEWE-16 通道高精度测试系统对异步电机振动信号进行检测,采样频率为 8kHz。实验分别采集正常电机 F_1 、转子弯曲 F_2 、转子断条 F_3 、转子不平衡 F_4 这 4 种状态下的异步电机振动信号若干组,以此作为原始数据样本。

2.2 原始特征生成

为应用 KPCA 从数据样本中提取故障的有效特征,先对样本数据进行预处理。采用均值 \bar{x} 、峰值 x_p 、幅值平方和 x_e 、均方根 x_{rms} 、方根幅值 x_r 、标准差 x_{std} 、偏度 x_{ske} 、峭度 x_{kur} 、波形因子 x_{SF} 、峰值因子 x_{CF} 、脉冲因子 x_{IF} 和裕度因子 x_{CIF} 12 个时域特征参数^[12]作为振动信号的特征量,每种状态取 100 组(共 400 组)样本数据,计算每组数据的 12 个特征量,从而得到 400×12 的原始特征向量集。从每种状态的 100 个原始特征向量中随机取 50 个(共 200 个)作为训练样本,余下的特征向量作为测试样本。

2.3 KPCA 特征提取

为了提高分类器的识别能力,先对训练样本应用 KPCA。首先,对核参数 $\sigma \in [0, 2^{13}]$ 进行优化选择。核参数与累计贡献率大于 90% 的核主元个数的关系以及核参数与优化函数的关系如图 1,2 所示。从图 1 可以看出,当 $\sigma \geq 9$ 时,核主元个数最少且保持不变,但并不是每一个 $\sigma (\geq 9)$ 对应的核主元特征都具有较好的可分性。从图 2 可知,当 $\sigma = 10$ 时,优化函数 $F(\sigma)$ 取最大值 4.964。综合图 1 和图 2 选定 $\sigma = 10$,此时核主元特征的维数为 3 且具有较好的可分性。利用取定的核参数值对训练样本运用 KPCA,得到 200×3 的核主元训练样本集。




图 1 核参数与核主元个数的关系

Fig. 1 Relationship between kernel parameter and the number of kernel principal component




图 2 核参数与优化函数的关系

Fig. 2 Relationship between kernel parameter and optimal function

2.4 故障模式识别

将 200×3 的核主元训练样本集输入 SVM 构建多故障分类器,SVM 仍选用 RBF 核函数。首先,利用 PSO 算法对惩罚因子 C 和核参数 g 进行优化选择。种群粒子数为 20,最大迭代次数为 200,适应度函数为训练样本的故障识别率,惯性权重 $\omega = 1$,加速度因子 $c_1 = c_2 = 1.5$ 。经优化计算,取 $C =$

12.415 7, $g = 32\ 768$ 。利用上述参数,结合一对一分类法构建 SVM 多故障分类器。然后,对测试样本应用 KPCA 得到 200×3 的核主元测试样本集,用构建的分类器对测试样本进行分类识别。

2.5 实验结果分析

为了进一步说明核主元分析-粒子群支持向量机(KPCA-PSOSVM)方法的有效性,对取定的训练样本和测试样本分别采用粒子群支持向量机(particle swarm optimization support vector machines,简称 PSOSVM)、主元分析和粒子群支持向量机(PCA-PSOSVM)、核主元分析和粒子群支持向量机(KPCA-PSOSVM)进行故障诊断,结果如表 1 所示。由表 1 可知,在同样的训练样本和测试样本条件下,3 种方法的诊断效果有较大差别。PCA-PSOSVM 的诊断效果比 PSOSVM 还差,这说明 PCA 不能有效提取异步电机故障的非线性特征,导致有效故障信息的丢失,所选主元不足以综合反映原始变量的结构信息,而降低了故障识别率。KPCA 通过利用核方法,将非线性问题转化为线性问题来处理,不仅能有效提取故障特征的非线性结构信息,而且能最大限度地降低特征向量的维数,提高了分类器的性能,使得 KPCA-PSOSVM 的诊断效果明显优于其他两种方法。下面的实验将进一步证实这一点。

表 1 故障识别率

Tab. 1 Fault recognition rate %

方法	维数	F_1	F_2	F_3	F_4	平均
PSOSVM	12	88	92	78	92	87.5
PCA-PSOSVM	2	96	94	68	78	84.0
KPCA-PSOSVM	3	98	96	86	98	94.5

从采集的数据中重新取 480 组构造 480×12 的数据样本集,用它进行 20 次对比实验,每次从中随机取 160 个样本作为测试样本,分别采用上述 3 种方法的分类器对其进行分类诊断,诊断结果与测试时间如图 3,4 所示。结果表明,在每一次实验中,KPCA-PSOSVM 的分类效果最好且耗时最少,甚至不到 PSOSVM 诊断时间的一半。这大大节省了诊断成本,提高了诊断效率,为快速实现异步电机实时故障诊断提供了一条新途径。

3 结 论

1) 基于 KPCA-PSOSVM 的故障诊断方法充

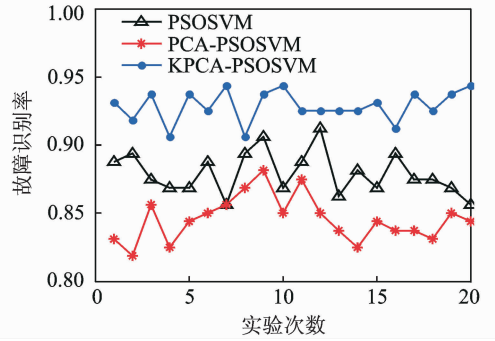


图 3 故障识别率对比

Fig. 3 Contrast of fault recognition rate

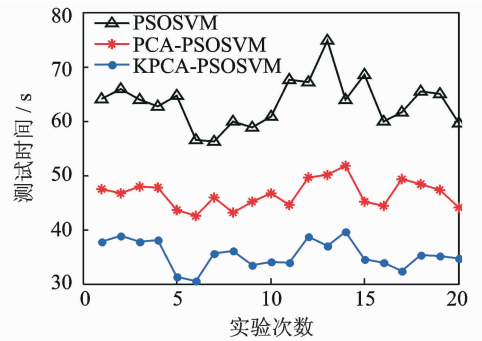


图 4 测试时间对比

Fig. 4 Contrast of test time

分利用了 KPCA 提取非线性特征的优势和 SVM 处理小样本问题的良好性能,分类效果好,实时性强,能快速有效实现异步电机的故障诊断。

2) 相比于 PCA, KPCA 对异步电机的非线性特征更为敏感,能充分利用数据间的非线性关系,通过参数的调节使核主元的提取更为灵活。它不仅能有效提取故障的非线性结构信息,而且能最大限度地降低特征维数,提高故障识别系统的分类能力。

3) 基于类间类内距离比的寻优方法和 PSO 算法能较好地解决 KPCA 与 SVM 的参数优化问题。

参 考 文 献

[1] 马宏忠. 电机状态监测与故障诊断[M]. 北京:机械工业出版社,2008:296-310.
 [2] Jolliffe I T. Principal component analysis[M]. 2nd ed. New York:Springer,2002:1-9.
 [3] 潘明清,周晓军,吴瑞明,等. 基于主元分析的支持向量数据描述机械故障诊断[J]. 传感技术学报,2006,19(1):129-131.
 Pan Mingqing, Zhou Xiaojun, Wu Ruiming, et al. Re-

- search of machine fault diagnosis based on PCA and SVDD [J]. Chinese Journal of Sensors and Actuators, 2006, 19(1): 129-131. (in Chinese)
- [4] Zvokelj M, Zupan S, Prebil I. Non-linear multivariate and multiscale monitoring and signal denoising strategy using kernel principal component analysis combined with ensemble empirical mode decomposition method [J]. Mechanical Systems and Signal Processing, 2011, 25(7): 2631-2653.
- [5] 魏秀业, 潘宏侠, 王福杰. 基于粒子群优化的核主元分析特征的提取技术[J]. 振动、测试与诊断, 2009, 29(2): 162-166.
Wei Xiuye, Pan Hongxia, Wang Fujie. Feature extraction based on kernel principal component analysis optimized by particle swarm optimization algorithm [J]. Journal of Vibration, Measurement & Diagnosis, 2009, 29(2): 162-166. (in Chinese)
- [6] 胡金海, 谢寿生, 侯胜利, 等. 核函数主元分析及其在故障特征提取中的应用[J]. 振动、测试与诊断, 2007, 27(1): 48-52.
Hu Jinhai, Xie Shousheng, Hou Shengli, et al. Kernel principal component analysis and its application to fault feature extraction [J]. Journal of Vibration, Measurement & Diagnosis, 2007, 27(1): 48-52. (in Chinese)
- [7] Widodo A, Yang B S. Support vector machine in machine condition monitoring and fault diagnosis [J]. Mechanical Systems and Signal Processing, 2006, 12(7): 2561-2572.
- [8] 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)
- [9] Hsu C, Lin C J. A comparison of methods for multi-class support vector machines [J]. IEEE Transactions on Neural Networks, 2002, 13(2): 415-425.
- [10] Samanta B, Natar C. Use of particle swarm optimization for machinery fault detection [J]. Engineering Applications of Artificial Intelligence, 2008, 7(6): 1-9.
- [11] 齐子元, 房立清, 张英堂. 特征选择与支持向量机参数同步优化研究 [J]. 振动、测试与诊断, 2010, 30(2): 111-114.
Qi Ziyuan, Fang Liqing, Zhang Yingtang. Synchro optimization of feature selection and parameters of support vector machine [J]. Journal of Vibration, Measurement & Diagnosis, 2010, 30(2): 111-114. (in Chinese)
- [12] Yang Junyang, Zhang Youyun, Zhu Yongsheng. Intelligent fault diagnosis of rolling element bearing based on SVMs and statistical characteristics [C] // International Manufacturing Science and Engineering Conference, Atlanta: [s. n.], 2007.



第一作者简介: 李平, 男, 1986 年 3 月生, 工程师。主要研究方向为机械设备状态监测与故障诊断。

E-mail: pingyun868@163.com