

1-14-2022

Engine Wear Fault Diagnosis Based on Supervised Kernel Entropy Component Analysis

Zhichao Zhu

Engineering Research Center of internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Dinghui Wu

Engineering Research Center of internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Yuanchang Yue

Engineering Research Center of internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China;

Follow this and additional works at: <https://dc-china-simulation.researchcommons.org/journal>



Part of the Artificial Intelligence and Robotics Commons, Computer Engineering Commons, Numerical Analysis and Scientific Computing Commons, Operations Research, Systems Engineering and Industrial Engineering Commons, and the Systems Science Commons

This Paper is brought to you for free and open access by Journal of System Simulation. It has been accepted for inclusion in Journal of System Simulation by an authorized editor of Journal of System Simulation.

Engine Wear Fault Diagnosis Based on Supervised Kernel Entropy Component Analysis

Abstract

Abstract: Focus on the influence of environment on engine operation, which leads to a large amount of redundant information and nonlinear structure in oil spectral data that affects the engine fault diagnosis results, the feature extraction method of SKECA (supervised kernel entropy component analysis) is proposed. *A supervised learning algorithm is adopted on the basis of Kernel Entropy Component Analysis, which extracts the inherent geometric features of oil spectrum data to make the extracted fault features include the discriminative information.* GA (genetic algorithm) is used to find parameters to optimize the results of feature extraction, and SVM (support vector machine) is used to classify the fault features. Simulation results show that SKECA can effectively improve the accuracy of engine fault diagnosis.

Keywords

spectrum, fault diagnosis, feature extraction, kernel entropy component analysis

Recommended Citation

Zhu Zhichao, Wu Dinghui, Yue Yuanchang. Engine Wear Fault Diagnosis Based on Supervised Kernel Entropy Component Analysis[J]. Journal of System Simulation, 2022, 34(1): 45-52.

基于监督核熵成分分析的发动机磨损故障诊断

祝志超, 吴定会, 岳远昌

(江南大学 物联网应用技术教育部工程研究中心, 江苏 无锡 214122)

摘要: 针对发动机受工作环境影响, 导致油液光谱数据存在大量冗余信息且具有非线性结构, 从而影响发动机故障诊断结果的问题, 提出监督核熵成分分析(supervised kernel entropy component analysis, SKECA)的特征提取方法; 该方法在核熵成分分析基础上引入监督学习算法, 提取油液光谱数据的内在几何特征, 使提取后的故障特征中包含判别信息, 并利用遗传算法(genetic algorithm, GA)寻找参数来优化特征提取的结果, 采用支持向量机对故障特征进行分类。结果表明: 采用SKECA进行特征提取能够有效提高发动机故障诊断精度。

关键词: 光谱; 故障诊断; 特征提取; 核熵成分分析

中图分类号: TP391.9 文献标志码: A 文章编号: 1004-731X(2022)01-0045-08

DOI: 10.16182/j.issn1004731x.joss.20-0623

Engine Wear Fault Diagnosis Based on Supervised Kernel Entropy Component Analysis

Zhu Zhichao, Wu Dinghui, Yue Yuanchang

(Engineering Research Center of internet of Things Technology Applications Ministry of Education, Jiangnan University, Wuxi 214122, China)

Abstract: Focus on the influence of environment on engine operation, which leads to a large amount of redundant information and nonlinear structure in oil spectral data that affects the engine fault diagnosis results, the feature extraction method of SKECA (supervised kernel entropy component analysis) is proposed. A supervised learning algorithm is adopted on the basis of Kernel Entropy Component Analysis, which extracts the inherent geometric features of oil spectrum data to make the extracted fault features include the discriminative information. GA (genetic algorithm) is used to find parameters to optimize the results of feature extraction, and SVM (support vector machine) is used to classify the fault features. Simulation results show that SKECA can effectively improve the accuracy of engine fault diagnosis.

Keywords: spectrum; fault diagnosis; feature extraction; kernel entropy component analysis

引言

光谱分析是目前常用的一种油液分析方法, 通过对发动机油液中的磨损元素进行检测和分析, 能够有效识别发动机磨损状态^[1]。但发动机磨损机理复杂, 光谱数据具有非线性结构且包含大量的冗余信息, 导致诊断精度受到影响, 因此提取光谱中有效的特征信息成为发动机故障诊断的关键^[2]。

光谱数据往往表现出包含大量冗余信息的非

线性特征, 因此采用非线性方法提取光谱特征能有效提升故障诊断精度。非线性方法中, 核线性判别分析(kernel linear discriminant analysis, KLDA)^[3]及核主成分分析(kernel principal components analysis, KPCA)^[4]应用广泛, 此类方法通过核函数将原始数据映射到核空间, 然后将核空间中的数据向低维空间投影, 从而实现非线性特征提取, 但是 KLDA在样本不服从高斯分布时效果较差, KPCA只保留样本协方差矩阵的部分特征值, 可能会丢失原始数

收稿日期: 2020-08-24

修回日期: 2020-11-24

基金项目: 国家重点研发计划(2020YFB1711102); 国家自然科学基金(61572237)

第一作者: 祝志超(1995-), 男, 硕士生, 研究方向为智能故障诊断。E-mail: 549087769@qq.com

据中重要的特征信息^[5]。流形学习是一种几何思想驱动的非线性特征提取方法^[6]，文献[7]采用流形学习的算法对航空发动机进行故障特征提取，获得了较高的诊断精度，但此类方法比较依赖于样本数据的几何结构。核熵成分分析(kernel entropy component analysis, KECA)^[8]是一种基于信息熵理论的特征提取方法，文献[9]提出一种基于核熵成分分析的故障诊断模型，有效提取了风机轴承的非线性特征，文献[10]采用 KECA 提取制冷系统中的非线性特征，并采用改进灰狼算法优化核密度参数。KECA 是一种无监督特征提取方法，可能会丢失重要的判别信息，从而降低故障诊断精度，而且 KECA 的性能非常依赖核参数，不合适的核参数也会造成特征信息的丢失^[11-12]。

针对以上问题，提出基于监督核熵成分分析(supervised kernel entropy component analysis, SKECA)的故障特征提取方法，并采用支持向量机对故障特征进行分类。通过相似矩阵和离散矩阵将监督信息融入到核熵成分分析的核矩阵中，使提取后的故障特征中包含判别信息，并采用遗传算法(genetic algorithm, GA)对 SKECA 参数进行优化，得到样本集的最佳投影特征，然后将投影特征输入到支持向量机(Support Vector Machine, SVM)线性分类器进行分类，实现发动机磨损故障诊断。

1 SKECA 特征提取方法

1.1 核熵成分分析(KECA)原理

KECA 基于样本瑞利熵实现特征提取。给定训练集样本 $\mathbf{X} = [x_1, x_2, \dots, x_N] \in R^M$ ，假设 $p(x)$ 为样本的概率密度函数，则样本的瑞利二次熵定义为^[13]

$$H(p) = -\lg\left(\int p^2(x)dx\right) \quad (1)$$

由于对数函数的单调性，只需要考虑式(2)所表示的函数^[8]：

$$V(p) = \int p^2(x)dx \quad (2)$$

样本概率密度 $p(x)$ 可以采用 Parzen 窗进行估计^[14]：

$$\hat{p}(x) = \frac{1}{N} \sum_{x_i \in X} K_\sigma(x, x_i) \quad (3)$$

式中： $\hat{p}(x)$ 为概率密度函数 $p(x)$ 的估计； $K_\sigma(x, x_i)$ 为 Parzen 窗函数(或称为核函数)； x_i 为窗函数的中心； σ 为窗函数的带宽。

将式(3)代入式(2)：

$$\hat{V}(p) = \int \hat{p}^2(x)dx = \frac{1}{N^2} \sum_{i=1}^N \sum_{j=1}^N K_{\sqrt{2}\sigma}(x_i, x_j) = \frac{1}{N^2} \mathbf{I}^T \mathbf{K} \mathbf{I} \quad (4)$$

式中： $\hat{V}(p)$ 为 $V(p)$ 的估计； \mathbf{K} 为 $N \times N$ 维矩阵， $\mathbf{K}_{ij} = K_{\sqrt{2}\sigma}(x_i, x_j)$ ； \mathbf{I} 为元素全为 1 的 $N \times 1$ 维列向量。

对核矩阵作特征分解：

$$\mathbf{K} = \mathbf{E} \mathbf{D} \mathbf{E}^T \quad (5)$$

式中： $\mathbf{D} = \text{diag}(\lambda_1, \lambda_2, \dots, \lambda_N)$ ，即核矩阵的特征值构成的对角矩阵； $\mathbf{E} = [\mathbf{e}_1, \mathbf{e}_2, \dots, \mathbf{e}_N]$ ，即特征值对应的特征列向量组成的特征矩阵。

将式(5)代入式(4)对其做进一步简化：

$$\hat{V}(p) = \frac{1}{N^2} \sum_{i=1}^N (\sqrt{\lambda_i} \mathbf{e}_i^T \mathbf{I})^2 \quad (6)$$

由式(6)可知，样本的瑞利二次熵大小取决于 N 个熵分量之和，将熵值由大到小进行排列，选取前 k ($k < M$) 个熵分量^[8]作为投影特征：

$$\Phi_{\text{keca}} = \mathbf{D}_k^{1/2} \mathbf{E}_k^T \quad (7)$$

式中： Φ_{keca} 为样本数据的投影特征； \mathbf{D}_k 为对熵排序后前 k 个特征值组成的对角矩阵； \mathbf{E}_k 为相应的特征向量矩阵。

对于测试集中的样本数据，将其投影到低维特征空间中，得到测试集数据经过特征提取之后的特征表达式：

$$\Phi'_{\text{keca}} = \mathbf{D}_k^{-1/2} \mathbf{E}_k^T \mathbf{K}' \quad (8)$$

式中： Φ'_{keca} 为测试集数据的投影特征； $\mathbf{K}' = K_{\sqrt{2}\sigma}(\mathbf{X}_t, \mathbf{X})$ ，其中 \mathbf{X}_t 为测试集样本集合， \mathbf{X} 为训练集样本集合， \mathbf{K}' 为内积矩阵。

1.2 监督核熵成分分析(SKECA)

KECA 是一种无监督特征提取方法，在特征提取过程中可能会丢失原始数据重要的判别信息，从而影响诊断效果。本文提出的 SKECA 在 KECA 基

础上引入监督学习的方法, 将无监督样本特征转变为有监督样本特征, 然后对 KECA 的核矩阵进行重构, 实现有监督的特征提取。

局部保留投影^[15] (locality preserving projections, LPP)算法保留原始空间中的局部近邻结构, 使原始空间中距离相近的样本在投影空间中依然相近^[16]。本文在 LPP 基础上引入类信息, 并建立以下目标函数:

$$\min \sum_{i,j} \|\varphi(x_i) - \varphi(x_j)\|^2 U_{ij} \quad (9)$$

$$\text{其中, } U_{ij} = \begin{cases} \sqrt{\exp(-\|x_i - x_j\|^2 / r_1)}, & x_i \text{ 和 } x_j \text{ 同类} \\ 0, & x_i \text{ 和 } x_j \text{ 不同类} \end{cases}$$

式中: $x_i \in R^m$ 为原始空间中的第 i 个样本; $\varphi(x_i) = P^T x_i$, $x_i \in R^n (n \ll m)$, 为 x_i 的投影; P 为 $n \times m$ 维投影矩阵; U_{ij} 为根据原始空间中 x_i 和 x_j 之间的距离 $\|x_i - x_j\|^2$ 构造的权重系数, 反映 x_i 和 x_j 的相似程度, 若 x_i 和 x_j 属于同类样本, 且当 x_i 和 x_j 之间的距离较小时, U_{ij} 的值较大, 从而对 $\|\varphi(x_i) - \varphi(x_j)\|^2$ 的约束加强, 而当 x_i 和 x_j 之间的距离较大时, U_{ij} 的值较小, 从而对 $\|\varphi(x_i) - \varphi(x_j)\|^2$ 的约束减弱, 当 x_i 和 x_j 非同类样本时, U_{ij} 取值为 0; r_1 为相似参数, 其作用是防止当 x_i 和 x_j 的欧氏距离较大时相似程度变化太大。

根据文献[13]对式(9)作推导:

$$\begin{aligned} & \sum_{i,j} \|\varphi(x_i) - \varphi(x_j)\|^2 U_{ij} = \\ & 2 \sum_i \sum_j U_{ij} \varphi^T(x_i) \varphi(x_i) - 2 \sum_{i,j} U_{ij} \varphi^T(x_i) \varphi(x_j) = \\ & 2 \sum_i H_{ii} \varphi^T(x_i) \varphi(x_i) - 2 \sum_{i,j} U_{ij} \varphi^T(x_i) \varphi(x_j) = \\ & 2 \text{tr}(P^T X(H-U)X^T P) = 2 \text{tr}(P^T X L_1 X^T P) \quad (10) \end{aligned}$$

式中: $X = [x_1, x_2, \dots, x_N]$, $U = [U_{ij}]_{N \times N}$, 且 U 为实对称矩阵; $L_1 = H - U$, H 为对角矩阵, 对角线元素 $H_{ii} = \sum_j U_{ij}$ 。

因此, 可将式(9)替换为

$$\min \text{tr}(P^T X L_1 X^T P) \quad (11)$$

对于不同类但是彼此相邻的样本, 希望它们在投影空间尽可能远离, 可以构建目标函数:

$$\max \sum_{i,j} \|\varphi(x_i) - \varphi(x_j)\|^2 V_{ij} \quad (12)$$

其中,

$$V_{ij} = \begin{cases} \sqrt{\exp(\|x_i - x_j\|^2 / r_2) - \beta}, & x_i \text{ 和 } x_j \text{ 不同类且近邻} \\ 0, & \text{其他} \end{cases}$$

式中: V_{ij} 是根据原始空间中 x_i 和 x_j 之间的距离构造的权重系数, 反映 x_i 和 x_j 的分离程度; r_2 为离散参数, 防止当 x_i 和 x_j 的欧氏距离较大时离散度变化太大; β 为常数。

同理, 式(12)可以变换为

$$\max \text{tr}(P^T X L_2 X^T P) \quad (13)$$

式中: $V = [V_{ij}]_{N \times N}$, $L_2 = G - V$, G 为对角矩阵, 对角线元素 $G_{ii} = \sum_j V_{ij}$ 。

合并式(11)和式(13), 目标函数变为

$$\min \text{tr}(P^T X L X^T P) \quad (14)$$

式中, $L = L_1 - L_2$ 。为避免式(14)出现零解, 加入约束条件: $P^T X H X^T P = I$, 将优化目标转变为约束问题:

$$\begin{aligned} & \min \text{tr}(P^T X L X^T P) \\ & \text{s.t. } P^T X H X^T P = I \end{aligned} \quad (15)$$

采用拉格朗日乘子法求解极小值优化问题:

$$X L X^T P = \lambda X H X^T P \quad (16)$$

对式(16)进行广义特征值分解, 可得到投影矩阵, λ 为特征值。

通过投影矩阵 P 求取有监督的样本特征 $\varphi(X) = P^T X$, 然后根据式(4)将 $\varphi(X)$ 映射到核空间, 得到相应的监督核矩阵 K_s , 并对其特征分解, 可以将样本瑞利二次熵表示为式(6)的形式, 其中包含 n 个熵分量, 选取前 k 个贡献值大的熵分量, 根据式(7)得到最终的投影特征 Φ_{keca} 。

1.3 SKECA 参数优化

在 SKECA 算法中, 式(3)中的核参数 σ 、式(9)中的相似参数 r_1 , 及式(12)中的离散参数 r_2 都能影响样本的投影特征, 因此 SKECA 参数优化对于特征提取效果十分重要。遗传算法是将自然选择规律

和生物遗传机理应用到数学领域中的一种优化方法,通过遗传算子实现种群的筛选和优化,从而寻找目标函数的全局最优解^[17]。本文在 SKECA 的基础上,通过遗传算法对 SKECA 参数进行寻优。遗传算法优化 SKECA 参数的主要过程:

(1) 个体编码:定义个体为一组参数 $[\sigma, r_1, r_2]$,并采用二进制编码方法对其进行编码。

(2) 种群初始化:随机产生一个包含 n 个个体的种群,参数范围设置为 $\sigma = [1, 10]$, $r_1, r_2 \in [0, 5]$ 。

(3) 适应度计算:计算每个个体的适应度,根据适应度值对下一代个体进行选择。特征提取的目的在于消除冗余和干扰信息,用尽量少的特征来描述原始特征信息,提高分类准确率,因此本文适应度函数将由样本的分类准确率 A 和核熵占比两部分组成:

$$f = A + \alpha \sum_{i=1}^k [E(i) / \sum_{j=1}^N E(j)] \quad (17)$$

式中: $E(i)$ 为对熵值进行排序后的第 i 个核熵分量; α 为 $[0, 1]$ 之间的常数, α 反映核熵占比相对于分类准确率的重要程度。

(4) 遗传算子:通过交叉、变异、选择等操作产生新染色体,优化和更新种群。交叉概率范围 $[0, 1]$,变异概率范围 $[0, 0.1]$,选择的概率为:

$$p_m = f(c_m) / \sum_{m=1}^{N_p} f(c_m) \quad (18)$$

式中: N_p 为种群个体总数, $f(c_m)$ 为第 m 个个体的适应度值。

(5) 终止条件:当适应度值不再发生变化或迭代次数达到最大值。

综合以上,可以得到 SKECA 进行特征提取的原理图,如图 1 所示。

2 基于 SKECA 的故障诊断

基于油液光谱数据进行发动机故障诊断,是根据油液中检测到的磨损元素的成分以及含量,识别发动机是正常磨损、警戒磨损还是严重磨损^[18]。本文将光谱数据中各元素的浓度作为特征指标,采用 SKECA 方法进行发动机的故障特征提取,该方法

能够充分保留原始数据的特征信息,并采用监督学习的方式将其映射到低维特征空间,实现非线性特征提取,最后将提取的特征输入到线性分类器,实现发动机的磨损故障诊断。

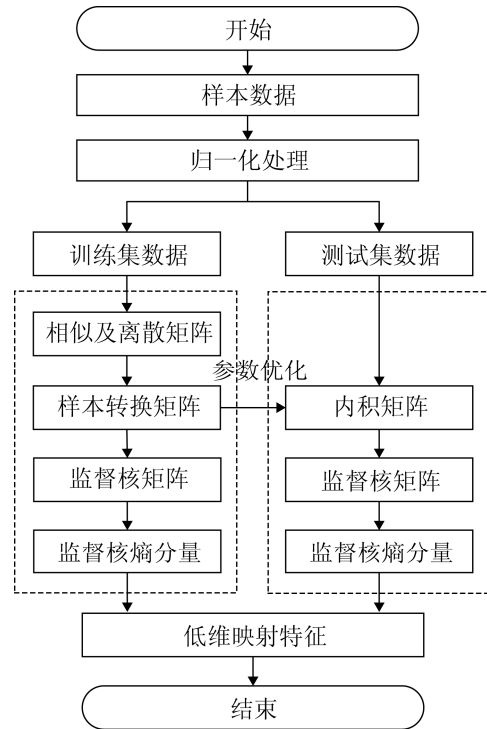


图 1 SKECA 特征提取原理图

Fig. 1 SKECA feature extraction schematic diagram

基于 SKECA 的故障诊断的具体步骤:

(1) 利用原子发射光谱仪采集发动机不同故障状态下的光谱数据。并将采集到的样本整合到一个数据集中,记为: $T = [q(1), q(2), \dots, q(m)]$, $q(i), i = 1, 2, \dots, m$ 为第 i 个特征组成的特征向量; m 为样本特征数。

(2) 将原始特征进行归一化处理。

$$\hat{q}(i) = (q(i) - q(i)_{\min}) / (q(i)_{\max} - q(i)_{\min}) \quad (19)$$

式中: $\hat{q}(i)$ 为归一化后的第 i 个特征向量; $q(i)_{\min}$ 为 $N \times 1$ 列向量,其所有元素都是 $q(i)$ 的最小值; $q(i)_{\max}$ 为 $N \times 1$ 列向量,其所有元素都是 $q(i)$ 中的最大值。

(3) 采用 SKECA 对归一化之后的特征进行特征提取,并采用 GA 优化 SKECA 参数,得到约简后的特征 $T' = [q'(1), q'(2), \dots, q'(k)]$, k 为约简后的特

征维数, 将样本故障特征 T 及标签输入到支持向量机线性分类器进行训练, 得到相应的故障分类模型。

(4) 对于测试集的样本, 按照式(8)将其向低维特征空间进行投影, 然后根据训练好的故障分类模型进行故障诊断。

3 实验仿真

3.1 实验数据

本文的实验数据来自车辆发动机的滑油光谱跟踪监测数据。根据发动机所处的不同磨损阶段, 将磨损故障分为正常磨损、警戒磨损和严重磨损 3 种。利用原子发射光谱仪分别在 3 种故障状态下对油液中的磨损元素进行检测, 并选取与发动机磨损密切相关的 8 种元素浓度作为特征指标, 即光谱数据中的 Fe, Cr, Pb, Cu, Al, Si, Na, Mg 元素浓度, 不同元素浓度对应不同的故障状态。

为了验证该方法的有效性, 本文采用 3 种故障状态下检测的 113 组油液光谱数据作为实验样本, 其中正常磨损数据 40 组, 警戒磨损数据 35 组, 严重磨损数据 38 组。用 25 组正常磨损、20 组警戒磨损、23 组异常磨损数据作为训练集, 其余样本数据作为测试集用于检测故障诊断精度, 如表 1 所示。


表 1 样本数据集
Table 1 Sample data set

数据集	样本数量 (训练集/测试集)	故障类型	标签
T	25/15	正常磨损	1
	20/15	警戒磨损	2
	23/15	严重磨损	3


3.2 特征提取

在对油液光谱数据进行特征提取之前, 首先对光谱数据进行归一化处理, 然后用 SKECA 方法分别提取训练集和测试集中的故障特征, 将遗传算法中的 α 设置为 0.1, 迭代次数设置为 100, 交叉概率设置为 0.6, 变异概率设置 0.01。SKECA 保留前 k 个累积贡献率达到 95% 的特征向量作为投影主元, 并选取前 2 个主元进行可视化。为了验证


SKECA 的特征提取性能, 分别采用 3 种方法对相同的数据集进行特征提取并作出 2 维特征可视化图像, 如图 2~3 所示。



(a) KPCA



(b) KECA



(c) SKECA

图 2 训练集特征提取之后的特征可视化图
Fig. 2 Feature visualization of training set after feature extraction

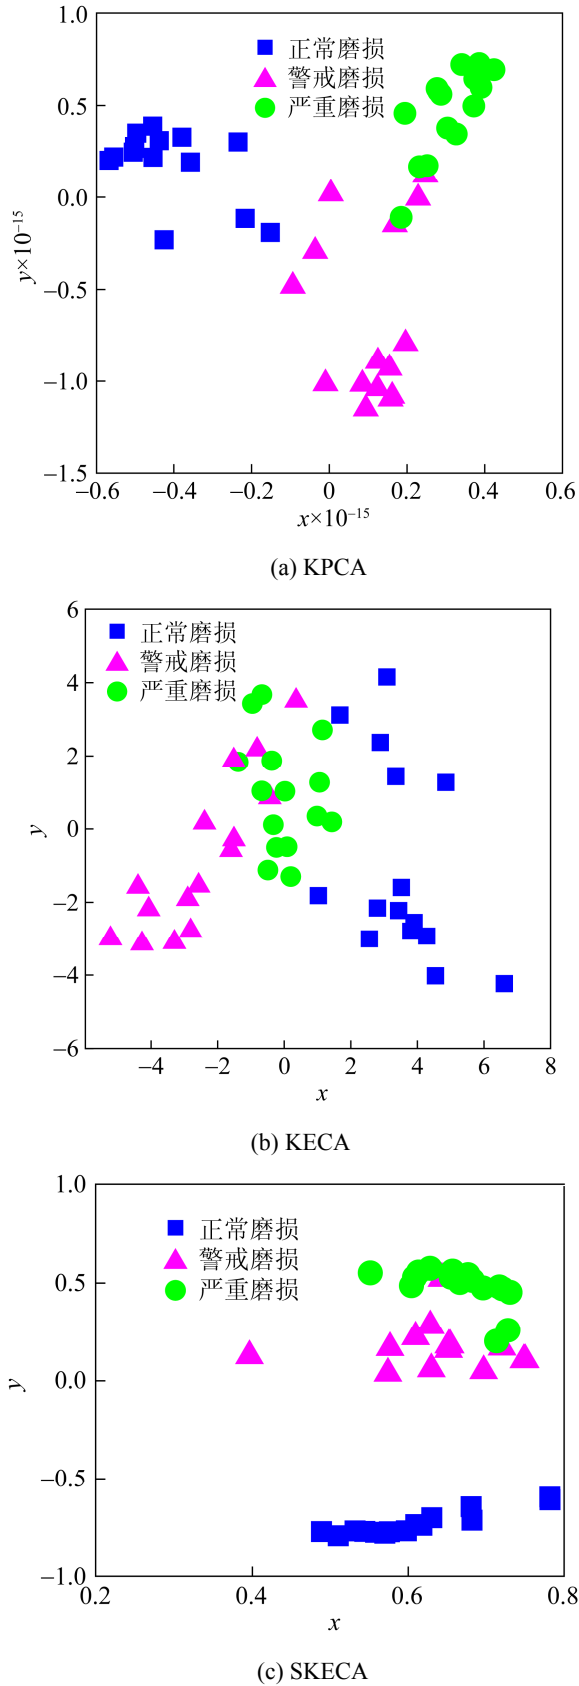


图3 测试集特征提取之后的特征可视化图

Fig. 3 Feature visualization of test set after feature extraction

通过特征可视化图对各种方法的性能进行比较,其直观的评判标准为能否区分不同类样本点的特征有效。图2训练集样本采用KPCA和KECA进行处理之后,不同类的样本点没有产生明显的边界,且部分不同类样本点之间发生重叠,导致其特征区分度不高,而采用SKECA处理过后,不同类样本点明显分离,因此其特征区分度较高;图3测试集样本采用3种方法处理之后不同样本点都产生了相互重叠的现象,但是相比前2种方法,采用SKECA方法处理之后的特征可视化图中只有少数警戒磨损和严重磨损的样本点重叠,因此其特征提取能力较强,原因是SKECA引入监督学习的方法,使同类型的样本点距离更近,不同类样本点的距离更远。

3.3 故障诊断

支持向量机是一种被广泛应用于模式识别的分类器,其结构简单且具有较好的分类性能,因此本实验采用支持向量机作为故障诊断的分类模型。诊断过程分为2步:①采用训练集特征提取后的特征数据对支持向量机分类模型进行训练;②将测试集特征数据输入到该分类模型中,得到对应的发动机故障状态。本文实验分别采用PCA, KPCA, KECA, SKECA特征提取数据进行发动机磨损故障诊断。表2为4种不同特征提取方法下测试集的诊断精度,图4为4种不同特征提取方法下每类故障的诊断精度。

表2 测试集诊断精度

Table 2 Diagnostic accuracy of test set	
特征提取方法	诊断精度/%
PCA	86.7
KPCA	88.9
KECA	86.7
SKECA	93.3

由表2可见, SKECA方法与其他3种方法相比诊断精度得到明显提升,达到了93.3%,图4中正常磨损状态下, SKECA的诊断精度达到了100%,其他方法的诊断精度为93.3%;警戒磨损状

态下, SKECA 的诊断精度, 达到 93.3%, 高于其他方法诊断精度; 严重磨损状态下, SKECA 的诊断精度达到 86.7%。因此, SKECA 的故障诊断精度最高, 原因是 SKECA 将样本类信息融入到投影特征内, 使不同类别样本区分度更高, 从而提升了分类模型的诊断精度。

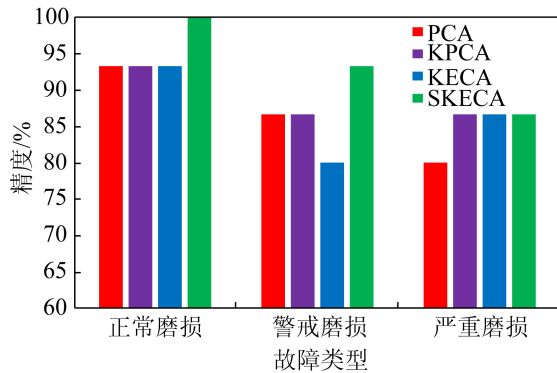


图 4 故障诊断精度

Fig. 4 Diagnostic accuracy of each type of fault

4 结论

本文提出了一种基于监督核熵成分分析的发动机故障诊断方法, 该方法能够有效地提取油液光谱中的故障特征, 在特征提取中充分利用样本类别信息, 提升不同类样本之间的特征区分度, 同时采用遗传算法对算法中的参数进行优化, 最后将提取后的特征输入到 SVM 分类模型中完成发动机的磨损故障诊断。结果表明, 采用 SKECA 进行特征提取下能够有效提升发动机的故障诊断精度。

参考文献:

- [1] 张全德, 陈果, 郑宏光, 等. 一种基于油液分析数据挖掘的航空发动机磨损故障诊断知识获取方法[J]. 润滑与密封, 2019, 44(3): 128-134.
Zhang Quande, Chen Guo, Zheng Hongguang, et al. A Knowledge Acquisition Method of Aero Engine Wear Fault Diagnosis Based on Oil Analysis Data Mining[J]. Lubrication Engineering, 2019, 44(3): 128-134.
- [2] 李婧, 田洪祥, 刘韬, 等. 因子分析法在船舶柴油机润滑油发射光谱数据挖掘中的应用[J]. 润滑与密封, 2019, 44(7): 107-111.
Li Jing, Tian Hongxiang, Liu Tao, et al. Application of Factor Analysis for Mining the AE Spectrum Data of

- Marine Diesel Engine Oil[J]. Lubrication Engineering, 2019, 44(7): 107-111.
- [3] Wang G, Jiao J, Yin S. Efficient Nonlinear Fault Diagnosis Based on Kernel Sample Equivalent Replacement[J]. IEEE Transactions on Industrial Informatics (S1551-3203), 2019, 15(5): 2682-2690.
- [4] Xiao Y Q, Feng L G. A Novel Neural-network Approach of Analog Fault Diagnosis Based on Kernel Discriminant Analysis and Particle Swarm Optimization[J]. Applied Soft Computing (S1568-4946), 2012, 12(2): 904-920.
- [5] Zhou H D, Shi T L, Liao G L, et al. Weighted Kernel Entropy Component Analysis for Fault Diagnosis of Rolling Bearings[J]. Sensors (S1424-8220), 2017, 17(3): 625.
- [6] 孙明明. 流形学习理论与算法研究[D]. 南京: 南京理工大学, 2007.
Sun Mingming. Study on Theories and Algorithms in Manifold Learning[D]. Nanjing: Nanjing University of Science and Technology, 2007.
- [7] 张赞, 林学森, 王琳, 等. 采用监督局部切空间排列算法的航空发动机磨损故障诊断[J]. 西安交通大学学报, 2020, 54(4): 179-185.
Zhang Yun, Lin Xuesen, Wang Lin, et al. Aero-Engine Wear Fault Diagnosis with Super-Vised Locally Tangent Space Alignment[J]. Journal of Xi'an Jiaotong University, 2020, 54(4): 179-185.
- [8] Jenssen R. Kernel Entropy Component Analysis[J]. IEEE Transactions on Pattern Analysis and Machine Intelligence (S0162-8828), 2010, 32(5): 847-860.
- [9] 齐咏生, 张二宁, 高胜利, 等. 基于 EEMD-KECA 的风电机组滚动轴承故障诊断[J]. 太阳能学报, 2017, 38(7): 1943-1951.
Qi Yongsheng, Zhang Erning, Gao Shengli, et al. Wind Turbine Rolling Bearings Fault Diagnosis Based on EEMD-KECA[J]. Acta Energaie Solaris Sinica, 2017, 38(7): 1943-1951.
- [10] 余绍斌, 丁强, 江爱朋, 等. 基于 KECA-IGKDE 的离心式冷水机组故障检测[J]. 测控技术, 2019, 38(11): 68-72, 80.
Yu Shaobin, Ding Qiang, Jiang Aipeng, et al. Centrifugal Chiller Fault Detection Based on KECA-IGKDE Method [J]. Measurement & Control Technology, 2019, 38(11): 68-72, 80.
- [11] 周宏娣. 基于核熵成分分析的滚动轴承状态识别方法研究[D]. 武汉: 华中科技大学, 2017.
Zhou Hongdi. Research on Condition Recognition Methods of Rolling Bearings Based on Kernel Entropy Component Analysis[D]. Wuhan: Huazhong University of

- Science and Technology, 2017.
- [12] Izquierdo-Verdiguier E, Laparra V, Jenssen R, et al. Camps-Valls. Optimized Kernel Entropy Components[J]. IEEE Transactions on Neural Networks and Learning Systems (S2162-237X), 2017, 28(6): 1466-1472.
- [13] Renyi A. On measures of entropy and information[C]// 4th Berkeley Symposium on Mathematical Statistics and Probability. California, USA: University of California Press, 1961: 547-561.
- [14] Jenssen R. Information Theoretic Learning and Kernel Methods[M]. Information Theory and Statistical Learning. Boston, MA: Springer, 2009: 209-230.
- [15] He X, Niyogi P. Locality preserving projections[C]// Advances in Neural Information Processing Systems. Vancouver, Canada: Neural Information Processing Systems Foundation, 2003: 585-591.
- [16] 韩敏, 李宇, 韩冰. 基于改进结构保持数据降维方法的故障诊断研究[J/OL]. 自动化学报[2020-08-13]. <https://doi.org/10.16383/j.aas.c180138>.
- [17] Han Min, Li Yu, Han Bing. Research on Fault Diagnosis of Data Dimension Reduction Based on Improved Structure Preserving Algorithm[J/OL]. Acta Automatica Sinica[2020-08-13]. <https://doi.org/10.16383/j.aas.c180138>.
- [17] 王绵斌, 安磊, 李芬花, 等. 基于遗传算法的耦合隐马尔科夫模型的故障诊断方法[J]. 机械设计与制造, 2018(12): 195-198.
- [17] Wang Mianbin, An Lei, Li Fenhua, et al. Fault Diagnosis Method Based on GA-CHMM[J]. Machinery Design & Manufacture, 2018(12): 195-198.
- [18] 刘学坤. 基于支持向量机和油液检测的船舶发动机故障诊断研究[D]. 大连: 大连海事大学, 2013.
- [18] Liu Xuekun. The Research of Marine Diesel Engine Fault Diagnosis Based on SVM and Oil Monitoring[D]. Dalian: Dalian Maritime University, 2013.