

# 一种基于主成分分析与支持向量机的风电齿轮箱故障诊断方法

黄宇斐,石新发,贺石中,周娜

(广州机械科学研究院有限公司,广东广州 510000)

**摘要:**为解决风电齿轮箱状态监测数据样本量较少,特征指标间存在相互干扰且具有非线性难以分类等问题,本文提出了一种基于主成分分析结合支持向量机的风电齿轮箱故障诊断方法。首先,采用主成分分析法(PCA)对原始数据进行降维,做出第1,2主成分二维图及前3个主成分三维图,表明PCA对监测状态数据具有一定的分类效果。其次,提取累计贡献率80%以上的前5个主成分作为数据集。最后,采用支持向量机(SVM)比较4种不同核函数的诊断准确度,并加入噪声验证。分析结果表明:径向基核函数构建的支持向量机总体分类精度达到97%,准确率最高;在含噪的情况下,线性核函数与径向基核函数分类精度达到94%;与MLP神经网络进行对比发现,支持向量机更适应小样本分析且测试精度较高。实例分析表明,主成分分析结合支持向量机有较好的分类效果,适用于风电齿轮箱故障诊断的工程应用。

**关键词:**风电齿轮箱;故障诊断;主成分分析;支持向量机

中图分类号:TK221

文献标识码:A

DOI:10.16146/j.cnki.rndlge.2022.10.022

[引用本文格式]黄宇斐,石新发,贺石中,等.一种基于主成分分析与支持向量机的风电齿轮箱故障诊断方法[J].热能动力工程,2022,37(10):175-181. HUANG Yu-fei, SHI Xin-fa, HE Shi-zhong, et al. A fault diagnosis method of wind turbine gearbox based on PCA and SVM[J]. Journal of Engineering for Thermal Energy and Power, 2022, 37(10):175-181.

## A Fault Diagnosis Method of Wind Turbine Gearbox based on PCA and SVM

HUANG Yu-fei, SHI Xin-fa, HE Shi-zhong, ZHOU Na

(Guangzhou Mechanical Engineering Research Institute Co. Ltd., Guangzhou, China, Post Code:510000)

**Abstract:** In order to solve many difficulties in the process of data analysis of wind turbine gearbox condition monitoring, such as small sample size, mutual interference and nonlinearity difficult to classify between characteristic indexes, this paper proposed a fault diagnosis method of wind turbine gearbox based on principal component analysis (PCA) and support vector machine (SVM). Firstly, PCA was used to reduce the dimension of the original data. The first and the second principal components were made in two dimensional maps and the first three principal components were made in the three dimensional maps, indicating that PCA had a certain classification effect on the monitoring condition data. Secondly, the first five principal components with cumulative contribution rate of more than 80% were extracted as new data sets. Finally, SVM was used to compare the diagnostic accuracy of four different kernel functions, and

收稿日期:2021-10-21; 修订日期:2021-12-15

基金项目:广东省科技计划项目(2020B1212070022);广州机械科学研究院有限公司博士后专项(17300065)

**Fund-supported Project:** Guangdong Provincial Science and Technology Project(2020B1212070022); Post-doctoral Program of Guangzhou Mechanical Engineering Research Institute, Co., Ltd (17300065)

作者简介:黄宇斐(1992-),女,广东广州人,广州机械科学研究院有限公司工程师。

通讯作者:贺石中(1963-),男,江西九江人,广州机械科学研究院有限公司教授级高级工程师。

then added noise to verify. The analysis results show that the overall classification accuracy of radial basic function (RBF) kernel function based on SVM is 97%, which is the highest. In the case of noise, the classification accuracy of linear kernel function and RBF kernel function is 94%. Comparing with MLP neural network, it is shown that the SVM is more suitable for small sample size analysis and has higher test accuracy. The example analysis shows that PCA combined with SVM has a better classification effect and is suitable for engineering application of fault diagnosis of wind turbine gearbox.

**Key words:** wind turbine gearbox, fault diagnosis, PCA, SVM

## 引 言

齿轮箱是连接发电机与风轮工作的纽带,是风电发电机组的核心部件<sup>[1]</sup>。由于风电机组齿轮箱内部结构和受力情况极为复杂,且是在变工况、变载荷的情况下运行,加之齿轮箱高速运行的齿轮和轴承润滑环境较差,更增加了齿轮箱故障发生的频率<sup>[2]</sup>。据统计,在风电设备的所有故障中,由齿轮箱引发的传动系统故障占据了主要的部分,针对该类型故障诊断的研究也成为当前研究的热点问题<sup>[3]</sup>。

风电齿轮箱常见的故障主要分为齿轮轮齿磨损及断齿、滚动轴承磨损、油封故障导致污染以及其他故障类型,传统的故障诊断方法,如振动和噪声检测法、机器性能参数检测法和磨损残余物检测法等,对故障评价功能较为薄弱<sup>[1]</sup>。近十年来,研究者已经相继提出了多种基于数学建模的方法进行齿轮箱的故障诊断和状态预测,如聚类分析法<sup>[4-5]</sup>、人工神经网络法<sup>[6-8]</sup>和贝叶斯网络<sup>[9]</sup>等,这些方法在工程实践中取得了较好的效果,尤其对于数据样本量巨大的故障特征问题有较好的分析能力。但在非线性、小样本的问题中,支持向量机(support vector machines, SVM)因在样本训练以及泛化能力方面表现出色而被广泛关注<sup>[10]</sup>。同时,对于 SVM 等分类器方法,采用主成分分析法(Principal Component Analysis, PCA)对原始数据进行降维分析,获取一组简洁不冗余的信息作为输入变量,能提高分类器的效率及准确性。因此,在获取大量可从不同角度表征设备状态的特征信息后,需要对信息进行有效处理才能使 SVM 模型更加高效<sup>[11]</sup>。

本文提出一种基于 PCA 和 SVM 的风电齿轮箱故障诊断方法,利用 PCA 对提取的指标进行降维处

理得到敏感特征,再利用 SVM 进行训练和测试,实现故障分类诊断。通过风电设备的系统润滑剂磨损状态正常、油品劣化和系统异常磨损等润滑状态评价,最终实现对风电机组齿轮箱可靠性的准确稳定预测。

## 1 基于 PCA 的敏感特征选择

PCA 是典型的针对模式分类的特征提取工具,在不减少原始数据所包含内在信息的前提下,将原始高维空间中的样本投影到一个低维特征空间,降低数据复杂程度<sup>[12-14]</sup>。首先将原变量标准化,消除量纲影响,得到标准化矩阵  $X^*$ ,计算  $X^*$  的协方差矩阵  $F = \text{Cov}(X^*)$ ;通过特征方程  $|\lambda_i E - F| = 0$ ,求得矩阵  $F$  的特征值  $\lambda_i (\lambda_1, \lambda_2, \lambda_3, \dots, \lambda_n, \lambda_1 \geq \lambda_2 \geq \lambda_3 \geq \dots \geq \lambda_n)$  和相应的正交单位化特征向量  $u_i$ 。

计算主成分得分的表达式为:

$$Y_i = u_i X_i^* \quad (1)$$

前  $k$  个主成分累计贡献率  $Q_k$  为:

$$Q_k = \frac{\sum_{i=1}^k \lambda_i}{\sum_{i=1}^n \lambda_i}, \text{ 其中 } k \leq n \quad (2)$$

累计贡献率越高,表明前  $k$  个主成分综合原变量的能力越好。一般选取能代表原始数据 80% 以上信息的前几位特征<sup>[15]</sup>作为输入变量。

## 2 基于 SVM 的故障诊断

基于 SVM 的故障诊断问题可作为样本分类问题,即通过训练样本将数据空间划分为不同的分类区域,每个区域对应一种运行状态,然后将测试数据进行投影,确定其所属区域,推断测试数据对应的运行状态<sup>[16]</sup>。SVM 是一个凸二次优化问题<sup>[17-18]</sup>,将 PCA 降维后抽取贡献率较高的前几列主成分作为

输入数据样本集  $\{x_i, y_i \mid i = 1, \cdots, k\}$  (其中  $x_i$  为输入值,  $y_i$  为输出值)<sup>[19]</sup>, 寻找一个最优分类超平面, 对应的分类面方程为:

$$wx + b = 0$$

(3)

式中:  $w$ —权重系数,  $b$ —偏置值。

当数据集线性不可分的时候, 引入松弛因子  $\xi$ , 满足  $y_i[(w \cdot x_i) + b] \geq 1 - \xi_i (i = 1, \cdots, n)$ , 同时加入惩罚项  $C \sum_{i=1}^n \xi_i$ , 得到目标函数  $\psi(w, \xi) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \xi_i$ , 将寻求最优分类超平面转化成凸二次规划寻优问题, 其中  $a = (a_1, a_2, \cdots, a_n)$ :

$$\begin{cases} \max \sum_{i=1}^n a_i - \frac{1}{2} \sum_{i=1}^n \sum_{j=1}^n a_i a_j y_i y_j (x_i \cdot x_j) \\ \text{s. t } 0 \leq a_i \leq C \\ \sum_{i=1}^n a_i a_j = 0 \end{cases}$$

(4)

式中:  $a$ —拉格朗日乘子系数;  $C$ —惩罚因子。

在最优分类面中采用适当的核函数  $k(x_i, x_j)$  则可以实现某一非线性变换后的线性分类, 核函数只需满足 Mercer 条件, 即能在高维空间上进行点积运算  $K(x_i, x_j) = (\Phi(x_i) \cdot \Phi(x_j))$ , 得到的最优分类函数式为:

$$\begin{aligned} f(x) &= \text{sng} \{ (w^* \cdot x) + b^* \} \\ &= \text{sng} \{ \sum_{i=1}^n \alpha_i^* y_i K(x_i \cdot x) + b^* \} \end{aligned}$$

(5)

式中:  $w^*, \alpha_i^*$ —最优解;  $b^*$ —分类的阈值。

常用的满足 Mercer 条件的核函数有线性核函数、多项式核函数、径向基核函数 (RBF) 和 sigmoid 核函数。选择不同的核函数, 将影响 SVM 的性能, 合适的核函数能减少支持向量的数量, 提高 SVM 的效率。

### 3 实例分析

针对风电齿轮箱进行实验, 本文数据来源于广州机械科学研究院有限公司数据库中某风电场的齿轮箱状态监测数据, 删除其中变量残缺的记录, 共得到 151 个有效实验数据。其中, 系统润滑及磨损状态正常样本 50 个、油品劣化样本 50 个和系统异常磨损样本 51 个。每个样本下选取具有特征性的理化指标包括 40 ℃ 油品运动黏度、酸值、水分、污染度 (NAS 1638 污染度等级标准)、PQ 指数、光谱元素 (Fe, Si, Ca, Zn, P) 共 10 个项目。PQ 指数、元素 Fe 是监测齿轮磨损的重要指标; 油品运动黏度、酸值、金属元素添加剂 Ca, Zn, P 的损耗表征油品的劣化; 水分、污染度、元素 Si 的持续增高表明该油可能受到外界污染<sup>[2]</sup>。以上理化指标与机械设备的使用状态密切相连, 使用主成分分析从原始特征错综复杂的关系中提取主要成分, 能够揭示特征之间的内在关系。

将 3 类监测状态样本数据进行标准化处理, 其中部分样本的标准化数据处理结果如表 1 所示。标签 1, 2, 3 分别代表系统润滑及磨损状态正常、油品劣化和系统异常磨损。

表 1 齿轮油检测项目部分数据标准化分析结果

Tab. 1 The standardized analysis results of gear oil test item partial data

| 油样<br>标签 | 运动黏度/<br>mm <sup>2</sup> · s <sup>-1</sup> | 酸值/<br>mgKOH · g <sup>-1</sup> | 水分/<br>mg · kg <sup>-1</sup> | NAS<br>等级 | PQ<br>指数 | 光谱元素                         |                              |                              |                              |                             |
|----------|--------------------------------------------|--------------------------------|------------------------------|-----------|----------|------------------------------|------------------------------|------------------------------|------------------------------|-----------------------------|
|          |                                            |                                |                              |           |          | Fe/<br>mg · kg <sup>-1</sup> | Si/<br>mg · kg <sup>-1</sup> | Ca/<br>mg · kg <sup>-1</sup> | Zn/<br>mg · kg <sup>-1</sup> | P/<br>mg · kg <sup>-1</sup> |
| 1        | 0.225                                      | 0.286                          | -1.027                       | -1.107    | -0.363   | -0.955                       | -1.523                       | 0.530                        | 0.072                        | -0.224                      |
| 1        | 0.269                                      | -0.713                         | -0.757                       | -0.553    | -0.363   | -1.045                       | -1.523                       | 0.334                        | 0.072                        | -0.099                      |
| 1        | 0.030                                      | -0.713                         | -0.892                       | 0.000     | -0.363   | -0.866                       | -1.523                       | 0.041                        | 0.018                        | 0.238                       |
| 2        | 0.218                                      | 0.661                          | -1.113                       | 0.553     | -0.363   | 0.295                        | 0.611                        | -0.740                       | -0.306                       | -0.295                      |
| 2        | 0.146                                      | -0.089                         | -0.095                       | 0.553     | -0.363   | 0.652                        | 0.611                        | -0.544                       | -0.306                       | -0.330                      |
| 2        | 0.374                                      | -0.338                         | 0.298                        | 1.107     | -0.363   | 0.474                        | 0.611                        | 0.041                        | -0.144                       | -0.295                      |
| 3        | 0.244                                      | -1.088                         | -0.647                       | 0.553     | -0.276   | 0.384                        | 0.611                        | -1.521                       | -0.144                       | 3.224                       |
| 3        | -0.325                                     | -0.089                         | -0.843                       | 1.660     | 1.091    | 0.742                        | 1.679                        | -0.642                       | 0.072                        | -0.455                      |
| 3        | -0.173                                     | -0.213                         | -0.451                       | -1.107    | 0.736    | 1.367                        | 0.611                        | -0.349                       | -0.144                       | -0.099                      |

3.1 主成分分析结果

齿轮油检测项目主成分分析结果如表 2 所示。由表 2 可知,PCA 处理后的前 5 个主成分累计贡献率大于 80%,说明前 5 个主成分能较好地携带十维

原始数据的分析信息。表 3 为齿轮油检测项目部分数据主成分得分表,由表 3 可知部分样本的前 5 个主成分得分情况。

表 2 齿轮油检测项目主成分分析结果  
Tab.2 Principal component analysis results of gear oil test item

| 监测特征                                  | 特征向量    |         |         |         |         | 主成分 | 特征值   | 累计贡献率/% |
|---------------------------------------|---------|---------|---------|---------|---------|-----|-------|---------|
|                                       | 第 1 主成分 | 第 2 主成分 | 第 3 主成分 | 第 4 主成分 | 第 5 主成分 |     |       |         |
| 运动黏度/mm <sup>2</sup> ·s <sup>-1</sup> | -0.522  | 0.005   | 0.034   | -0.068  | 0.095   | 1   | 2.954 | 29.539  |
| 酸值/mgKOH·g <sup>-1</sup>              | 0.050   | 0.026   | 0.839   | -0.221  | -0.266  | 2   | 2.410 | 53.638  |
| 水分/mg·kg <sup>-1</sup>                | 0.201   | -0.269  | 0.360   | 0.191   | 0.735   | 3   | 1.086 | 64.499  |
| NAS 等级                                | 0.167   | 0.395   | -0.054  | -0.117  | 0.522   | 4   | 0.948 | 73.983  |
| PQ 指数                                 | 0.015   | 0.312   | 0.204   | 0.766   | -0.222  | 5   | 0.783 | 81.808  |
| Fe/mg·kg <sup>-1</sup>                | 0.118   | 0.541   | 0.089   | -0.070  | 0.071   | 6   | 0.600 | 87.812  |
| Si/mg·kg <sup>-1</sup>                | 0.154   | 0.543   | -0.105  | 0.004   | -0.014  | 7   | 0.555 | 93.362  |
| Ca/mg·kg <sup>-1</sup>                | 0.392   | -0.261  | -0.142  | 0.321   | -0.091  | 8   | 0.331 | 96.668  |
| Zn/mg·kg <sup>-1</sup>                | 0.543   | -0.132  | -0.039  | 0.022   | -0.130  | 9   | 0.236 | 99.028  |
| P/mg·kg <sup>-1</sup>                 | 0.413   | 0.028   | -0.020  | -0.450  | -0.167  | 10  | 0.097 | 100.000 |

表 3 齿轮油检测项目部分数据主成分得分表

Tab.3 The principal component score table of gear oil test item partial data

| 油样<br>标签 | 第 1 主<br>成分 | 第 2 主<br>成分 | 第 3 主<br>成分 | 第 4 主<br>成分 | 第 5 主<br>成分 |
|----------|-------------|-------------|-------------|-------------|-------------|
| 1        | -0.694      | -1.762      | -0.135      | -0.091      | -1.374      |
| 1        | -0.655      | -1.636      | -0.887      | 0.001       | -0.626      |
| 1        | -0.449      | -1.193      | -0.921      | -0.333      | -0.469      |
| 2        | -0.667      | 1.141       | 0.142       | -0.846      | -0.435      |
| 2        | -0.357      | 0.988       | -0.118      | -0.427      | 0.520       |
| 2        | -0.006      | 0.825       | -0.315      | -0.189      | 1.092       |
| 3        | 0.572       | 1.326       | -1.096      | -2.141      | -0.174      |
| 3        | 0.235       | 2.677       | -0.270      | 0.477       | 0.152       |
| 3        | -0.185      | 1.085       | -0.022      | 0.502       | -0.875      |

3.2 主成分分析对 3 类监测状态进行聚类

利用 PCA 对提取的特征参数矩阵进行降维处理。图 1 为二维主成分的得分图。从图中看出,二维主成分能对 3 类诊断状态进行初步聚类,其中系统润滑及磨损状态正常与油品劣化样本聚合度较好,存在 4 个数据交叉点;系统异常磨损样本分布较散且与油品劣化样本存在较多线性不可分数据点。

为进一步分析,还得到了前 3 个主成分的三维得分图,如图 2 所示。三维主成分得分图能够较清晰地划分正常样本与油品劣化样本,对油品劣化样本与异常磨损样本则仍然存在线性不可分数据点。综上所述,利用 PCA 主成分分析能对原始监测数据样本中的正常样本与油品劣化样本进行初步分类,为更清晰描述分类结果,将抽取累计贡献率大于 80% 的前 5 个主成分作为数据集,结合支持向量机进一步建立监测状态的分类识别模型。

3.3 利用 SVM 进行监测状态分类

设定训练集与测试集比例为 6:4,随机选取系统润滑及磨损状态正常样本 32 个、油品劣化样本 23 个及系统异常磨损样本 32 个作为训练样本进行训练,剩余的样本数据作为测试样本。通过网格搜索法确定 SVM 中的误差惩罚因子 C = 10,设置 RBF 核参数 g = 0.1,多项式和 Sigmoid 核参数 g = 1。参数 C 和 g 对优化 SVM 性能有重要意义<sup>[20]</sup>。将训练样本得到的 SVM 分类模型对测试集数据进行分类预测,对 SVM 模型进行验证,最终可得到模型对 3 种监测状态的分类精度。

利用 SVM 对 PCA 降维后的样本进行分析,最

终得到的分类精度如表 4 所示。对 4 种核函数进行对比发现,RBF 核函数的分类精度达到 97%,分类精度最好;线性和多项式核函数次之,精度达到 95%。




图 1 二维主成分的样本散点图

Fig. 1 2D sample scatter plot




图 2 三维主成分的样本散点图

Fig. 2 3D sample scatter plot

表 4 3 类监测状态的 SVM 分类精度列表

Tab.4 SVM classification accuracy list for three types of monitoring status

| SVM 类型      | 分类精度/% |     |      |        |
|-------------|--------|-----|------|--------|
|             | 总分类精度  | 正常  | 油品劣化 | 系统异常磨损 |
| 线性核函数       | 95     | 100 | 96   | 89     |
| RBF 核函数     | 97     | 100 | 96   | 94     |
| 多项式核函数      | 95     | 100 | 96   | 89     |
| sigmoid 核函数 | 75     | 89  | 59   | 78     |

为了测试 SVM 分类识别模型的稳定性,在数据集中加入 20% 噪音,得到结果如下表 5 所示。在加入噪音之后,线性核函数与 RBF 核函数分类精度最高,达到 94%,表明 SVM 分类识别模型具有较好的泛化能力。

表 5 加噪音后 3 类监测状态的 SVM 分类精度列表

Tab.5 SVM classification accuracy list for three types of monitoring status after adding noise

| SVM 类型      | 分类精度/% |     |      |        |
|-------------|--------|-----|------|--------|
|             | 总分类精度  | 正常  | 油品劣化 | 系统异常磨损 |
| 线性核函数       | 94     | 93  | 94   | 94     |
| RBF 核函数     | 94     | 100 | 94   | 88     |
| 多项式核函数      | 92     | 93  | 94   | 88     |
| sigmoid 核函数 | 71     | 86  | 100  | 29     |

SVM 和神经网络是模式识别的两种方法,现在都广泛应用于故障诊断领域<sup>[21]</sup>。为分析训练样本数对不同故障诊断方法诊断效果的影响,选用分类精度及稳定性较好的 RBF 核函数、线性核函数和多项式核函数与多层神经网络 (MLP) 在相同样本条件下进行分类结果比较。在本次 MLP 神经网络模型训练中,设置目标误差为 0.01,最大训练周期数量为 100,结果如表 6 所示。设定训练集与测试集比例为 6:4 与 4:6,当训练集占比为 6 时,神经网络的诊断准确率为 94%,SVM 准确率均高于 95%;当训练集占比减少至 4 时,神经网络诊断准确率减少至 74%,而 SVM 准确率仍在 92% 以上。结果表明,神经网络方法依赖大样本量的数据集,而支持向量机能较好解决小样本的分类问题,适合样本量较小的机械设备状态监测数据的诊断分析。

表 6 分类结果比较

Tab.6 Comparison of classification results

| 训练集:测试集 | 诊断方法     | 分类精度/% |
|---------|----------|--------|
| 6:4     | 线性核函数    | 95     |
|         | RBF 核函数  | 97     |
|         | 多项式核函数   | 95     |
|         | MLP 神经网络 | 94     |
| 4:6     | 线性核函数    | 94     |
|         | RBF 核函数  | 92     |
|         | 多项式核函数   | 74     |
|         | MLP 神经网络 | 90     |

4 结 论

(1) PCA 进行数据降维后,采用支持向量机建立故障分类预测模型。比较 4 种核函数的分类精度发现,RBF 核函数构建的支持向量机总体分类精度达到 97%,准确率最高,线性核函数与多项式核函数达到 95%。

(2) 在含噪音的情况下,线性核函数与 RBF 核函数分类精度达到 94%。

(3) 与 MLP 神经网络对比,支持向量机在样本量较少的情况下,仍能得到较好的诊断分类结果。因此,基于主成分分析和支持向量机的分类预测模型应用于风电齿轮箱的故障诊断是可行的。

参考文献:

[1] 胡志红,张秀丽,张向军,等. 风电机组齿轮箱故障评价方法研究现状[J]. 设备管理与维修,2018(2):31-35.  
HU Zhi-hong,ZHANG Xiu-li,ZHANG Xiang-jun,et al. Research status of wind turbine gearbox fault evaluation methods[J]. Plant Maintenance Engineering,2018(2):31-35.

[2] 贺石中,冯 伟. 设备润滑诊断与管理[M]. 北京:中国石化出版社,2017.  
HE Shi-zhong,FENG Wei. Equipment lubrication diagnosis and management[M]. Beijing:China Petrochemical Press,2017.

[3] 严如强,钱宇宁,胡世杰,等. 基于小波域平稳子空间分析的风力发电机齿轮箱故障诊断[J]. 机械工程学报,2014,50(11):9-15.  
YAN Ru-qiang,QIAN Yu-ning,HU Shi-jie,et al. Wind gearbox fault diagnosis based on wavelet domain stationary subspace analy-

sis[J]. Journal of Mechanical Engineering,2014,50(11):9-15.

[4] 李 状,柳亦兵,马志勇,等. 结合 C-均值聚类的自适应共振神经网络在风电机组齿轮箱故障诊断中的应用[J]. 动力工程学报,2015,35(8):47-52,66.  
LI Zhuang,LIU Yi-bing,MA Zhi-yong,et al. Application of ART2 neural network combined with C-means clustering in fault diagnosis of wind turbine gearbox[J]. Journal of Chinese Society of Power Engineering,2015,35(8):47-52,66.

[5] 李 状,柳亦兵,滕 伟,等. 基于粒子群优化 KFCM 的风电齿轮箱故障诊断[J]. 振动、测试与诊断,2017,37(3):484-488.  
LI Zhuang,LIU Yi-bing,TENG Wei,et al. Fault diagnosis of wind turbine gearbox based on KFCM optimized by particle swarm optimization[J]. Journal of Vibration, Measurement & Diagnosis,2017,37(3):484-488.

[6] 王 皓,周 峰. 基于小波包和 BP 神经网络的风机齿轮箱故障诊断[J]. 噪声与振动控制,2015,35(2):154-159.  
WANG Hao,ZHOU Feng. Fault diagnosis of wind turbine gearbox based on wavelet packet and back propagation neural network[J]. Noise and Vibration Control,2015,35(2):154-159.

[7] 林 涛,刘 刚,蔡睿琪,等. 基于轴承温度的风机齿轮箱故障预警研究[J]. 可再生能源,2018,36(12):143-148.  
LIN Tao,LIU Gang,CAI Rui-qi,et al. Research on fault precaution of fan gearbox based on bearing temperature[J]. Renewable Energy Resources,2018,36(12):143-148.

[8] 许敬成,陈长征. BP 神经网络在齿轮箱故障诊断中的应用[J]. 噪声与振动控制,2018,38(Z1):673-677.  
XU Jing-cheng,CHEN Chang-zheng. Application of BP neural network in fault dagnosis of gear boxes[J]. Noise and Vibration Control,2018,38(Z1):673-677.

[9] 张露江,张 利,杨宏伟,等. 基于改进贝叶斯网络的风机齿轮箱自动诊断策略研究[J]. 电力系统保护与控制,2019,47(19):151-157.  
ZHANG Lu-jiang,ZHANG Li,YANG Yao-wei,et al. Research on automatic diagnosis strategy of wind turbine gearbox based on improved Bayesian network[J]. Power System Protection and Control,2019,47(19):151-157.

[10] 张 亮,陈志刚,杨建伟,等. 基于决策树与多元支持向量机的齿轮箱早期故障诊断方法[J]. 计算机测量与控制,2016,24(1):12-15.  
ZHANG Liang,CHEN Zhi-gang,YANG Jian-wei,et al. Early fault diagnosis of gearbox based on multiclass support vector machine and decision tree[J]. Computer Measurement & Control,2016,24(1):12-15.

[11] 古莹奎,潘高平,朱繁沆,等. 基于邻域属性重要度与主成分

- 分析的齿轮箱故障特征约简[J]. 中国机械工程,2016,27(13):1783-1789.
- GU Ying-kui,PAN Gao-ping,ZHU Fan-long, et al. Gearbox fault feature reduction based on neighborhood attribute importance and PCA [J]. China Mechanical Engineering, 2016, 27 ( 13 ): 1783 - 1789.
- [12] 陈 佩. 主成分分析法研究及其在特征提取中的应用[D]. 西安:陕西师范大学,2014.
- CHEN Pei. Principal component analysis and its application in feature extraction[D]. Xi'an: Shaanxi Normal University, 2014.
- [13] 梅长林,范金城. 数据分析方法[M]. 北京:高等教育出版社,2006.
- MEI Chang-lin, FAN Jin-cheng. Data analysis methods[M]. Beijing: Higher Education Press, 2006.
- [14] 韩 璞,张德利,韩晓娟,等. 基于主成分分析法与贝叶斯网络的汽轮机故障诊断方法[J]. 热能动力工程,2008,23(3):244-247.
- HAN Pu, ZHANG De-li, HAN Xiao-juan, et al. Steam turbine fault diagnosis methods based on the main constituent analysis method and Bayesian network [J]. Journal of Engineering for Thermal Energy and Power, 2008, 23(3): 244 - 247.
- [15] 梁 策,田洪祥,李 靖,等. 主成分分析在柴油机润滑油磨粒分析中的应用[J]. 润滑与密封,2019,44(6):120-125.
- LIANG Ce, TIAN Hong-xiang, LI Jing, et al. Application of principle component analysis to wear particle analysis of diesel engine lubricating oils[J]. Lubrication Engineering, 2019, 44(6): 120 - 125.
- [16] GUO M, XIE L, WANG S, et al. Research on an integrated ICA-SVM based framework for fault diagnosis[C]//IEEE International Conference on Systems. IEEE, 2003.
- [17] 刘方园,王水花,张煜东. 支持向量机模型与应用综述[J]. 计算机系统应用,2018,27(4):1-9.
- LIU Fang-yuan, WANG Shui-hua, ZHANG Yu-dong. Overview on models and applications of support vector machine[J]. Computer Systems & Applications, 2018, 27(4): 1 - 9.
- [18] 白 鹏. 支持向量机理论及工程应用实例[M]. 西安:西安电子科技大学出版社,2008.
- BAI Peng. Support vector machine and its application in mixed gas infrared spectrum analysis [M]. Xi'an: Xidian University Press, 2008.
- [19] 周志才,刘东风,石新发. 基于灰信息挖掘的视情维修决策方法研究[J]. 振动与冲击,2016,35(5):55-58.
- ZHOU Zhi-cai, LIU Dong-feng, SHI Xin-fa. Condition-based maintenance decision method based on gray information[J]. Journal of Vibration and Shock, 2016, 35(5): 55 - 58.
- [20] 李 武,胡 冰,王明伟. 基于主成分分析和支持向量机的太赫兹光谱冰片鉴别[J]. 光谱学与光谱分析,2014(12):3235-3240.
- LI Wu, HU Bing, WANG Ming-wei. Discrimination of varieties of borneol using terahertz spectra based on principal component analysis and support vector machine[J]. Spectroscopy and Spectral Analysis, 2014(12): 3235 - 3240.
- [21] 赵海洋,王金东,刘树林,等. 基于神经网络和支持向量机的复合故障诊断技术[J]. 流体机械,2008,36(1):39-42,73.
- ZHAO Hai-yang, WANG Jin-dong, LIU Shu-lin, et al. Compound fault diagnosis technique based on artificial neural network and support vector machine [J]. Fluid Machine, 2008, 36(1): 39 - 42, 73.

(刘 颖 编辑)