

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

张赞¹, 林学森¹, 王琳¹, 陈应付², 李朋¹

(1. 海军航空大学航空基础学院, 264001, 山东烟台; 2. 中国人民解放军 77120 部队, 610000, 成都)

摘要: 为解决传统特征提取技术难以处理具有非线性结构的复杂故障数据、影响故障诊断准确性的问题,将非线性维数约简技术——局部切空间排列引入航空发动机润滑油光谱数据特征提取中,提出了一种基于监督局部切空间排列的发动机磨损故障诊断方法。该方法对非线性分布故障流形数据的内在几何特征进行捕捉,并将数据向低维故障特征空间进行非线性映射,完成故障特征的提取,最后在故障特征空间里构造分类器,完成磨损故障的识别诊断。采用某型发动机磨损故障润滑油光谱数据开展实验,结果表明:与传统主元分析、线性鉴别分析特征提取方法相比,该方法能够更有效地提取出嵌入于故障数据中的非线性特征,提高了故障分类的准确率,并且只需采用简单的线性分类器就能具有很好的故障诊断性能。

关键词: 局部切空间排列;非线性特征提取;航空发动机;磨损故障诊断

中图分类号: V233.7 **文献标志码:** A

DOI: 10.7652/xjtuxb202004022 **文章编号:** 0253-987X(2020)04-0179-07



OSID 码

Aero-Engine Wear Fault Diagnosis with Supervised Locally Tangent Space Alignment

ZHANG Yun¹, LIN Xuesen¹, WANG Lin¹, CHEN Yingfu², LI Peng¹

(1. Aeronautical Basic Institute, Naval Aeronautical University, Yantai, Shangdong 264001, China;

2. 77120 Unit of PLA, Chengdu 610000, China)

Abstract: To solve the problem that the traditional feature extraction technique is hard to deal with the complex fault data containing nonlinear structure, an aero-engine fault diagnosis method based on supervised locally tangent space alignment is proposed by introducing the non-linear dimensionality reduction method named locally tangent space alignment algorithm. The method learns the intrinsic geometric features of fault manifold data, and non-linearly maps them into a low-dimensional fault feature space to achieve fault feature extraction. The wear fault recognition and diagnosis are carried out in the fault feature space by constructing classifier. The oil spectra data of engine wear fault are used for experiment. Compared with the conventional feature extraction approaches such as PCA and LDA, the proposed approach can effectively extract the nonlinear features embedded in the fault data to improve the fault classification accuracy and provide good fault diagnosis performance with a simple linear classifier.

Keywords: locally tangent space alignment; nonlinear feature extraction; aero-engine; wear fault diagnosis

航空发动机在运行过程中,由于各个摩擦副的相互作用,会产生许多金属磨粒进入润滑油中,这些悬浮于滑油中的金属磨粒的成分及含量蕴含着发动机磨损状态的重要信息。滑油光谱分析是监测与诊断发动机磨损故障的重要手段,如何从这些磨粒的光谱信息中挖掘出对磨损故障识别最有效的故障特征,是提高发动机油润部件磨损故障诊断准确性的关键因素^[1-3]。机器学习领域中经典的特征提取技术有主元分析(PCA)^[4-5]和线性鉴别分析(LDA)法^[6]等,它们将数据映射到一个更低维的特征空间,使得不同模式的数据能很好地被区分开。然而,这些方法要求数据服从线性分布,难以处理具有非线性结构的复杂数据。

很多采样数据并不是全局线性的,通常遵循一定形式的非线性分布规律,采样数据点相互影响,从而形成在不同外部环境作用下同一类模式的采样数据呈现出多种分布形态^[7]。滑油光谱监测数据在很大程度上受机械系统负载变化、磨损故障严重程度、不同运行工况、润滑状况等因素的影响,这些因素共同变化所引起的故障数据变化并不是由每一个因素变化所引起的数据变化的简单线性叠加,而是呈现出多因素共同影响下的高度非线性相关。从数据分布的几何空间上看,这样的故障数据在特征空间中具有较强的非线性几何结构。

基于核函数思想的一些非线性特征提取技术比如核主元分析(KPCA)^[8]和广义线性鉴别分析(GLDA)^[9]用于研究非线性分布数据,主要采用核映射方法将非线性分布的数据向核空间进行投影,从而使数据线性可分。但是,这些核方法的性能非常依赖于核函数的正确选择,都没有考虑数据的内部几何结构,采用有限几种核函数如多项式或高斯核函数进行映射时,往往会破坏数据的低维几何结构^[10]。此外,一些神经网络型非线性特征提取方法涉及迭代求解陷入局部极值的缺陷^[11]。局部切空间排列(LTSA)算法^[12]是近年来广受学者关注的流形学习理论中具有代表性的一个算法。作为一种几何思想驱动的非线性维数约简方法,它可以发现非线性流形数据分布的内在几何结构,提取出隐藏在高维非线性数据中的特征信息,在数据挖掘、图像处理、旋转机械故障诊断等领域都得到成功应用^[13-20]。它的优点在于:能够保留数据的局部几何特征;无需进行迭代求解,能够保证全局最优解,避免出现陷入局部最优的问题。

本文将非线性维数约简技术——局部切空间排

列引入航空发动机滑油光谱数据特征提取中,提出了一种基于监督局部切空间排列流形学习算法的发动机磨损故障诊断新方法,以解决发动机油润部件磨损非线性故障特征提取与识别问题。实验结果表明,本文方法克服了传统的特征提取方法的不足,显著提高了发动机磨损故障诊断准确性。

1 磨损故障诊断方法

1.1 局部切空间排列算法

对于数据集 $\mathbf{X} = \{\mathbf{x}_1, \mathbf{x}_2, \dots, \mathbf{x}_n\}$, $\mathbf{x}_i \in \mathbf{R}^m$, 流形学习的目的就是要寻找到蕴藏在数据样本集中的 d 维($m > d$)非线性主流形。LTSA 的思路为:首先为每个数据点找到它的近邻点,然后用近邻数据点的 d 维切空间坐标对数据局部线性几何结构进行近似表征,最后采用矩阵变换将每个数据点的近邻域的切空间局部坐标转换到统一的全局 d 维坐标上,获得一个 d 维(更低维)坐标表示的非线性流形,即完成数据的非线性降维(特征提取)。将 LTSA 算法归纳总结成下述步骤^[12]。

(1)局部邻域构造。LTSA 算法的第 1 步就是在高维空间为每个数据点 $\mathbf{x}_i \in \mathbf{X}$ 找到它的近邻点。本文采用 K -NN 标准进行近邻搜索。对每个数据点 $\mathbf{x}_i$, $i=1, 2, \dots, n$, 用欧氏距离确定其 k_i 个邻近点组成的邻域 $\mathbf{X}_i = [\mathbf{x}_{i_1}, \mathbf{x}_{i_2}, \dots, \mathbf{x}_{i_{k_i}}]$ 。图 1 为局部邻域选择示意图,与 $\mathbf{x}_i$ 相连的 5 个数据点是其近邻点。




图1 局部邻域选择示意图

(2)局部线性拟合。在 $\mathbf{x}_i$ 的邻域内选择一组正交基 $\mathbf{Q}_i$ 构成 $\mathbf{x}_i$ 的 d 维切空间;计算邻域中每个点 $\mathbf{x}_{i_j}$ ($j=1, 2, \dots, k_i$) 到切空间上的正交投影 $\boldsymbol{\theta}_j^{(i)} = \mathbf{Q}_i^T(\mathbf{x}_{i_j} - \bar{\mathbf{x}}_i)$, 其中 $\bar{\mathbf{x}}_i$ 为邻域数据的均值, $\mathbf{Q}_i$ 通常取为 $\mathbf{X}_i$ 的前 d 个最大的左奇异矢量。数据点 $\mathbf{x}_i$ 的邻域数据在切空间的投影所构成的局部坐标 $\boldsymbol{\theta}_i = [\boldsymbol{\theta}_1^{(i)}, \boldsymbol{\theta}_2^{(i)}, \dots, \boldsymbol{\theta}_{k_i}^{(i)}]$ 描述了 $\mathbf{x}_i$ 邻域内最主要的几何结构信息。图 2 为二维坐标下的局部切空间示意图。

(3)将局部坐标转换为全局坐标。将每个数据点邻域中的局部坐标转换到统一的全局坐标系,使其对数据集 $\mathbf{X}$ 的非线性主流形能更好地表示。转换过程需要符合两个条件即:每个邻域局部坐标转换都要保证误差平方和最小;转换后的全局坐标要尽量保持住每个数据点局部邻域几何关系。




图2 二维坐标下的局部切空间示意图

将数据点 $\mathbf{x}_i$ 邻域数据局部坐标 $\boldsymbol{\theta}_i$ 进行转换,获得全局坐标 $\mathbf{T}_i = [t_{i1}, t_{i2}, \dots, t_{ik_i}]$,对应的下标集合 $\{i_1, i_2, \dots, i_{k_i}\}$ 由数据点 $\mathbf{x}_i$ 的邻域来确定,则邻域数据的转换误差为

$$\mathbf{E}_i = \mathbf{T}_i \left(\mathbf{I} - \frac{1}{k} \mathbf{e} \mathbf{e}^T \right) - \mathbf{L}_i \mathbf{T}_i \quad (1)$$

式中: $\mathbf{L}_i$ 为转换矩阵; $\mathbf{e}$ 为全 1 矢量。使式(1)取最小值,则有

$$\mathbf{L}_i = \mathbf{T}_i \left(\mathbf{I} - \frac{1}{k} \mathbf{e} \mathbf{e}^T \right) \mathbf{T}_i^+ = \mathbf{T}_i \mathbf{T}_i^+ \quad (2)$$

式中: $\mathbf{T}_i^+$ 为 $\mathbf{T}_i$ 的广义 Moore-Penrose 逆。进一步,邻域数据转换误差能表示成

$$\mathbf{E}_i = \mathbf{T}_i \left(\mathbf{I} - \frac{1}{k} \mathbf{e} \mathbf{e}^T \right) (\mathbf{I} - \mathbf{T}_i^+ \mathbf{T}_i) \equiv \mathbf{T} \mathbf{W}_i \quad (3)$$

设 $\mathbf{T} = [\mathbf{T}_1, \mathbf{T}_2, \dots, \mathbf{T}_N] \in \mathbf{R}^{d \times N}$ 是每个数据的全局坐标表示,令 $\mathbf{U}_i$ 是选择矩阵,即 $\mathbf{T} \mathbf{U}_i = \mathbf{T}_i$ 。那么所有邻域数据的坐标转换误差总和为

$$\sum_{i=1}^N \|\mathbf{E}_i\|_F^2 = \|\mathbf{T} \mathbf{U} \mathbf{W}\|_F^2 \quad (4)$$

式中: $\mathbf{U} = [\mathbf{U}_1, \dots, \mathbf{U}_N]$; $\mathbf{W} = \text{diag}(\mathbf{W}_1, \dots, \mathbf{W}_N)$; $\|\cdot\|_F$ 表示 Frobenius 范数的平方。令

$$\mathbf{B} = \mathbf{U} \mathbf{W} \mathbf{W}^T \mathbf{U}^T \quad (5)$$

并引入约束 $\mathbf{T} \mathbf{T}^T = \mathbf{I}_d \in \mathbf{R}^{d \times d}$, 求解出使式(4)取最小值的最佳 $\mathbf{T}^*$ 值。由于全 1 矢量 $\mathbf{e}$ 是矩阵 $\mathbf{B}$ 的零特征值对应的特征矢量,所以取矩阵 $\mathbf{B}$ 的第 2 到第 $(d+1)$ 个最小的特征值对应的特征矢量所组成的矩阵就是所求的 $\mathbf{T}^*$ 。 $\mathbf{T}^*$ 即为描述了高维数据集 $\mathbf{X}$ 中非线性主流形的正交低维全局坐标映射。

为了形象说明 LTSA 的降维效果,分别采用 PCA 和 LTSA 算法将 S 型曲线分布数据从三维空

间向二维平面非线性映射,得到如图 3 所示的降维结果。从图中可以看出,线性方法 PCA 映射的数据点存在不同颜色的部分数据点混合在一起,这说明 S 曲线上不同的区域被映射至重叠的区域,降维效果并不好。LTSA 算法映射的数据颜色的变化情况与 S 曲线一致,说明 LTSA 算法在降维过程中能够有效地保留住数据局部几何结构,从而准确地展开了 S 型数据的内蕴二维非线性流形。




图3 三维 S 曲线数据向二维空间的映射结果

1.2 监督局部切空间排列算法

在故障诊断中,数据集来源于多个故障模式类别,并且类别标签是已知的。作为无监督的学习方法,LTSA 算法是针对单一数据集的,并且忽略了数据类别这一先验信息。为了增强其对包含多故障模式的数据处理能力,监督 LTSA 算法 (Supervised LTSA, SLTSA) 被提出来^[21],目标是充分利用数据类别信息,以提高故障分类性能。

LTSA 算法在第一步时采用欧氏距离计算出每个数据的近邻点,而 SLTSA 则是充分考虑数据点的类别标签这一信息,定义了一个修正的距离测度来确定近邻点的选取,其余步骤与 LTSA 算法相同。假设 L_i 和 L_j 分别是数据点 $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 的类别标签,则包含类别信息的修正距离定义如下

$$S'(\mathbf{x}_i, \mathbf{x}_j) = \begin{cases} 1 - \exp[-S(\mathbf{x}_i, \mathbf{x}_j)/\bar{S}], & L_i = L_j \\ \exp[S(\mathbf{x}_i, \mathbf{x}_j)/\bar{S}] - \lambda, & L_i \neq L_j \end{cases} \quad (6)$$

式中: $L_i = L_j$ 表示数据点 $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 属于同一类; $L_i \neq L_j$ 表示数据点 $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 分别属于不同的类; $S(\mathbf{x}_i, \mathbf{x}_j)$ 是未考虑类别信息的 $\mathbf{x}_i$ 和 $\mathbf{x}_j$ 的欧氏距离; $\bar{S}$ 是所有数据点之间的平均欧氏距离;参数 λ 用于控制包含类别信息量的大小,可称之为监督参数。

图 4 显示了 $S'(\mathbf{x}_i, \mathbf{x}_j)$ 关于 $S(\mathbf{x}_i, \mathbf{x}_j)/\bar{S}$ 的函数曲线关系,可以看出,当取相同的欧氏距离时,对应的类间距离要大于类内距离,这一性质适合于分类。当 $\lambda=0$ 时,不同类别的数据点的距离 $S'(\mathbf{x}_i, \mathbf{x}_j)$ 满足 $S'(\mathbf{x}_i, \mathbf{x}_j) \geq 1$,反之同一类别的数据点的距离满

足 $S'(x_i, x_j) < 1$ 。因此,类间距离总是大于类内距离,这一性质也有利于分类。当 $\lambda = 0$, SLTSA 属于完全监督的 LTSA,然而完全监督的 LTSA 容易导致“过学习”问题,使得对新数据点的泛化能力变差。因此,采用 $0 < \lambda \leq 1$ 进行松弛,使得在一定的概率上类内距离能够大于类间距离。




图4 $S'(x_i, x_j)$ 关于 $S(x_i, x_j)/\bar{S}$ 的函数曲线

1.3 基于 SLTSA 的磨损故障诊断方法

SLTSA 在特征提取过程中既考虑了类别信息又能保留住数据的局部近邻结构,具备良好的监督学习能力和非线性属性,能够有效处理包含多故障种类的非线性故障数据。因此,本文引入 SLTSA 流形学习算法,提出一种基于监督局部切空间排列流形学习的发动机磨损故障诊断方法。该方法对非线性分布故障流形数据的内在几何特征进行捕捉,并将数据向低维故障特征空间进行非线性映射,完成故障特征的提取,最后在故障特征空间里构造分类器完成故障的识别诊断。由于 SLTSA 并没有给出从高维采样空间到低维特征空间的显式映射关系,而这一映射关系对于把 SLTSA 应用于故障诊断是十分必要的,缺少这一映射关系将难以处理新故障样本。因此,本文采用文献[12]提出的局部多项式回归算法完成新增样本的泛化映射。

基于局部切空间排列算法的磨损故障诊断方法流程见图5,步骤如下。

第1步,对润滑油光谱训练数据样本 $x_i = [x_i(1), x_i(2), \dots, x_i(m)]$ 进行去均值化和方差归一化处理,其中 m 是光谱元素个数, $i = 1, 2, \dots, n$, n 为数据样本数。

第2步,构建采样数据空间 $\mathbf{R}^m$, 则 $x_1, x_2, \dots, x_n$ 对应于空间中的 n 个数据点。采用监督局部切空间排列算法学习这 n 个数据点的非线性特征,并向更低维的故障特征空间进行非线性映射,提取出磨损故障特征。

第3步,在低维故障特征空间中利用提取出来的非线性故障特征数据构造故障分类器,以实现磨损故障的分类识别。

第4步,利用局部多项式回归方法,将待诊断故障数据点从高维采样数据空间投影到低维故障特征空间,再利用分类器鉴别其所属的故障种类。




图5 发动机磨损故障诊断方法流程

2 实验分析

2.1 实验设置

实验中,采用3种分类器(最小距离分类器、K-近邻分类器、支持向量机分类器)在降维特征空间里进行故障分类。采用故障分类正确率 A_c 评定这些分类器的分类结果

$$A_c = n_c / N_t \quad (7)$$

式中: N_t 是故障测试样本总数量; n_c 是被正确分类的故障测试样本数量。 A_c 越大表明分类结果越好。

对于 SLTSA 故障诊断方法,涉及到降维维数 d 、近邻数 k 和监督参数 λ 这3个参数的选择。采用文献[22]提出的局部协方差特征分解法来确定 d ; 采用10步交叉验证的方法来确定参数 k 和 λ , 即在参数的一定取值范围内,选取能够提供最佳分类性能结果的参数作为最优参数。以步长1从4到40选择近邻数 k , 并以步长0.05从0到1选择监督参数 λ , 对于选定的参数组 (k, λ) 进行10次交叉验证。

2.2 发动机磨损故障诊断实验

采用实际发生的某型航空发动机磨损故障数据对本文方法性能进行检验分析。通过统计部队装备使用过程中出现的发动机磨损故障情况和故障发动机返厂检修情况,选取故障发生率较高的3类磨损故障模式,包括低压压气机轴承磨损、高(低)压涡轮轴承磨损和润滑油泵齿轮磨损,为方便起见,分别用 C1、C2、C3 表示,见表1。每类故障模式都对应9个故障征兆,即润滑油光谱分析的9种元素 Fe、Cr、Ni、Al、Mo、Mg、Cu、Mn、Sn 的含量。3类故障对应的9种元素平均质量分数见图6。

表 1 某航空发动机 3 类故障模式具体信息

磨损部位	磨损部位主要化学成分	故障模式名称及代号
低压压气机轴承	Fe、Cr、Ni、Mo、Mn、Cu	低压压气机轴承磨损 C1
高(低)压涡轮轴承	Fe、Cr、Ni、Mo、Mn	高(低)压涡轮轴承磨损 C2
滑油泵齿轮	Fe、Ni、Mn、Al、Mg	滑油泵齿轮磨损 C3






图 6 3 类故障对应的 9 种元素平均浓度(质量分数)

为每类故障随机挑选 30 组数据样本作为训练样本集,并随机挑选 10 组数据样本用于测试。每组数据样本由 9 个元素浓度组成,构成了 9 维的原始采样数据空间。为了降低数据样本挑选的随机性对实验结果的影响,下述的每项实验都重复进行 10 次,每 1 次均随机选取样本,最后将 10 次的实验值取平均,作为最终的诊断结果,即用平均故障分类正确率来衡量故障诊断性能。

在第 1 个实验中,将 SLTSA 与 LDA(两者都为有监督的特征提取方法)进行性能比较。训练数据为每类 30 个样本。SLTSA 中的近邻参数 k 设定为 8,监督参数 λ 为 0.80。为了直观显示分类效果,图 7a、图 8a 分别给出了使用 LDA 和 SLTSA 将训练




(a)LDA 训练数据映射结果




(b)LDA 测试数据映射结果

图 7 采用 LDA 将训练数据映射至二维空间结果以及测试数据映射结果

数据映射到二维空间的结果,图 7b、图 8b 显示了测试数据的映射结果。采用简单的最小距离分类器对 SLTSA 映射数据的故障诊断结果很好(平均故障分类正确率为 94.45%),而对 LDA 映射数据的平均故障分类正确率为 87.78%。这表明,与 LDA 特征提取技术相比,SLTSA 能够更好地以有监督的方式来完成蕴含在采样数据中非线性故障特征的提取。



(a)SLTSA 训练数据映射结果



(b)SLTSA 测试数据映射结果

图 8 采用 SLTSA 将训练数据映射至二维空间结果以及测试数据映射结果

在第 2 个实验中,将 SLTSA 与无监督的特征提取方法 PCA 进行性能比较。 K -近邻分类器被用于降维空间的故障分类,训练数据为每类 30 个样本。图 9 显示了测试数据的平均分类正确率随降维维数 d 的变化关系(SLTSA 的参数 k 和 λ 分别设为 8 和 0.80)。从表 2 可以看出,SLTSA 在维数 $d=2$ 时达到最好的分类准确率 94.45%,PCA 在较高的维数 $d=5$ 时才获得最佳分类准确率 88.64%,并且当映射到很低的维数时,SLTSA 的性能远远优于 PCA。这是因为当 d 过小时,PCA 映射数据会导致信息丢失太多,使得数据被映射至互相重叠。与 PCA 相比,由于 SLTSA 具有监督学习机制和非线性数据映射能力,能够映射得到一个维数更低的降维空间,这意味着更低维空间里的故障分类器算法复杂度能够降低,显著缩短分类器训练时间,而且还能实现在三维空间以内的故障分类可视化。

表 2 最佳分类正确率的平均值和降维维数

特征提取方法	降维维数 d	分类正确率平均值及方差/%
PCA	5	88.64±1.24
LDA	2	87.78±1.32
SLTSA	2	94.45±0.62




图 9 平均分类正确率随降维维数的变化关系

在第 3 个实验中,采用分类器分别对 SLTSA 映射后的数据和原始数据进行故障分类性能对比。这里采用 3 种分类器,分别为最小距离分类器、带有 RBF 核的支持向量机(SVM)以及 K -近邻分类器(K -NN),实验结果见表 3,很明显 SLTSA 适合于分类前的特征提取步骤。对于每个分类器而言,对 SLTSA 映射数据的分类性能都比原始数据的分类性能好,特别是采用最小距离分类器直接对原始数据的分类效果较差(分类正确率为 89.68%)。SLTSA 和最小距离分类器的结合能够表现出非常好的性能(分类正确率达到了 93.36%,甚至高出了 SVM 对原始数据的分类正确率)。这是因为 SLT-

SA 本身对数据进行了非线性映射,使得简单的线性分类器(如最小距离分类器)能很好的处理映射后的数据。

表 3 不同分类器对原始数据和 SLTSA 映射后数据的平均分类正确率

数据类型	平均分类正确率/%		
	最小距离分类器	K-近邻分类器	支持向量机
原始数据	89.68	93.48 ($K=3$)	92.68 ($\sigma=10$)
SLTSA 映射后的数据 ($k=8, d=2, \lambda=0.8$)	93.36	94.45 ($K=2$)	95.12 ($\sigma=6$)

注: K 为近邻分类器选取的近邻点数; σ 为支持向量机的核参数。

3 结 论

本文提出了一种基于监督局部切空间排列算法的发动机磨损故障诊断方法,能够解决对非线性光谱监测数据的故障特征提取与识别问题。实验结果表明,本文方法能够更有效地提取出嵌入于故障数据中的非线性特征,显著提高了故障分类的准确性,优于一些传统的模式识别方法如 PCA、LDA 等。与 LDA 相比,SLTSA 能够更好地以有监督的方式提取蕴含在采样数据中非线性故障特征。与 PCA 相比,SLTSA 具备带监督式的数据学习能力和强大的非线性数据映射能力,能够比 PCA 提供一个更低的降维空间,降低分类器算法复杂度,缩短分类器训练时间。将一些分类器对 SLTSA 映射后的数据进行分类实验,结果表明,由于 SLTSA 的非线性映射能力,使得采用 SLTSA 结合简单的线性分类器(如最小距离分类器)就能具有非常好的故障诊断性能。

参考文献:

[1] 郑波,高峰. 基于 IPSO-SVR 的航空发动机磨损预测研究 [J]. 润滑与密封, 2014, 39(11): 81-87.
ZHENG Bo, GAO Feng. Research on the prediction of aeroengine wear based on the IPSO-SVR [J]. Lubrication Engineering, 2014, 39(11): 81-87.
[2] 葛科宇,陈果. 基于 Weka 平台知识获取的航空发动机磨损故障诊断专家系统 [J]. 机械科学与技术, 2011, 30(11): 1955-1959.
GE Keyu, CHEN Guo. Knowledge acquisition of aero-engine wear fault diagnosis expert system based on Weka platform [J]. Mechanical Science and Technology for Aerospace Engineering, 2011, 30(11): 1955-

- 1959.
- [3] 陈果, 宋兰琪, 陈立波. 基于神经网络规则提取的航空发动机磨损故障诊断知识获取 [J]. 航空动力学报, 2008, 23(12): 2170-2176.
CHEN Guo, SONG Lanqi, CHEN Libo. Knowledge acquisition for aero-engine wear fault diagnosis based on rule extraction from neural networks [J]. Journal of Aerospace Power, 2008, 23(12): 2170-2176.
 - [4] SUN W X, CHEN J, LI J Q. Decision tree and PCA-based fault diagnosis of rotating machinery [J]. Mechanical Systems and Signal Processing, 2007, 21(3): 1300-1317.
 - [5] 杨帆, 胡金海, 陈卫, 等. 主元分析方法在航空发动机故障检测与诊断中的应用 [J]. 机械科学与技术, 2008, 27(3): 330-333.
YANG Fan, HU Jinhai, CHEN Wei, et al. Application of principal component analysis to fault detection and diagnosis of aeroengines [J]. Mechanical Science and Technology for Aerospace Engineering, 2008, 27(3): 330-333.
 - [6] CHIANG L H, KOTANCHEK M E. Fault diagnosis based on fisher discriminant analysis and support vector machines [J]. Computers and Chemical Engineering, 2004, 28(8): 1389-1401.
 - [7] SEUNG H S, LEE D D. The manifold ways of perception [J]. Science, 2000, 290: 2268-2269.
 - [8] SCHOLKOPF B, SMOLA A, MULLER K R. Non-linear component analysis as a kernel eigenvalue problem [J]. Neural Computation, 1998, 10(5): 1299-1319.
 - [9] SHI K, LIU S, ZHANG H, et al. Kernel local linear discriminate method for dimensionality reduction and its application in machinery fault diagnosis [J]. Shock and Vibration, 2014, 2014: 283750.
 - [10] MIKA S, RATSCH G, WESTON J, et al. Constructing descriptive and discriminative nonlinear features; Rayleigh coefficients in kernel feature spaces [J]. IEEE Transactions on Pattern Analysis and Machine Intelligence, 2003, 25(5): 623-628.
 - [11] LOWE D, TIPPING M E. Neuroscale: novel topographic feature extraction using RBF networks [M]// Advances in Neural Information Processing Systems. Cambridge, MA, USA: MIT Press, 1997: 543-549.
 - [12] ZHANG Zhengyue, ZHA Hongyuan. Principal manifolds and nonlinear dimension reduction via local tangent space alignment [J]. Journal of Shanghai University, 2002, 8(4): 406-424.
 - [13] TAN C, JI G. A manifold learning algorithm based on incremental tangent space alignment [C]// International Conference on Cloud Computing and Security. Berlin, Germany: Springer, 2016: 541-552.
 - [14] KULESHOV A, BERNSTEIN A. Manifold learning in data mining tasks [C]// International Workshop on Machine Learning & Data Mining in Pattern Recognition. Berlin, Germany: Springer, 2014: 119-133.
 - [15] WANG J, SUN X L, DU J. Local tangent space alignment via nuclear norm regularization for incomplete data [J]. Neurocomputing, 2017, 273: 141-151.
 - [16] DANG C, RADHA H. Fast single image super-resolution via tangent space learning of high resolution patch manifold [J]. IEEE Transactions on Computational Imaging, 2017, 3(4): 605-616.
 - [17] SU Z, TANG B, LIU Z, et al. Multi-fault diagnosis for rotating machinery based on orthogonal supervised linear local tangent space alignment and least square support vector machine [J]. Neurocomputing, 2015, 157: 208-222.
 - [18] DONG S, CHEN L, TANG B, et al. Rotating machine fault diagnosis based on optimal morphological filter and local tangent space alignment [J]. Shock and Vibration, 2015, 2015: 8935041.
 - [19] ZHANG S M, MA Z M, TAN H L. On the equivalence of HLLE and LTSA [J]. IEEE Transactions on Cybernetics, 2018, 48(2): 748-753.
 - [20] 余博, 田福庆, 梁伟阁, 等. 增量式监督局部切空间排列算法及齿轮箱故障诊断实验验证 [J]. 振动与冲击, 2018, 37(13): 105-110.
SHE Bo, TIAN Fuqing, LIANG Weige, et al. Test verification for gearbox fault diagnosis based on incremental supervised local tangent space alignment algorithm [J]. Journal of Vibration and Shock, 2018, 37(13): 105-110.
 - [21] ZHANG Y, LI B, WANG W, et al. Supervised locally tangent space alignment for machine fault diagnosis [J]. Journal of Mechanical Science & Technology, 2014, 28(8): 2971-2977.
 - [22] RIDDER D D, DUIN R P W. Locally linear embedding for classification: technical report PH-2002-01 [R]. Delft, The Netherlands: Delft University of Technology, 2002.

(编辑 杜秀杰)