doi:10.11887/j.cn.202006006 http://journal.nudt.edu.cn

参照化流形空间融合学习的敏感特征提取与异常检测方法*

刘 学,孙 翱,李 冬
(中国人民解放军91550部队,辽宁 大连 116023)

摘 要:针对遥测振动信号冲击强、响应周期短、共振频带宽和小样本等特点导致异类模式识别率低的问题,提出基于参照化流形空间融合学习的敏感特征提取与异常检测方法。采用多尺度分析方法将信号正交无遗漏地分解到各尺度带中,提取多尺度特征构造高维特征集;以相同的正常信号样本结合相同类型的异常样本建立专属参照化模型单元,采用线性流形学习获取各参照化模型单元多尺度流形特征差异,增强异常特征的敏感性。融合各参照化模型单元的投影矩阵对原始特征集进行升维再学习,获取低维多尺度敏感流形特征;输入到分类器实现对未知样本状态辨识。实测信号处理结果验证了算法的有效性。

关键词:遥测振动信号;多尺度分析;近邻保持嵌入;流形空间;异常检测
中图分类号:TN911.7 **文献标志码**:A **文章编号**:1001-2486(2020)06-047-09

Sensitive feature extraction and anomaly detection method based on referenced manifold spatial fusion learning

LIU Xue, *SUN Ao*, *LI Dong*
(The PLA Unit 91550, Dalian 116023, China)

Abstract: Aiming at the problem of low recognition rate of heterogeneous patterns caused by the characteristics of small sample size, strong impact, short response period and wide resonance frequency bandwidth of telemetry vibration signals, a method for sensitive feature extraction and anomaly detection of telemetry vibration signal based on referenced manifold spatial fusion learning was proposed. The multi-scale analysis method was used to decompose the signals orthogonally into each in the scale band; the multi-scale feature was extracted to construct the high-dimensional feature set. The same normal signal sample was combined with the same type of abnormal sample to establish the exclusive reference model unit, and the linear manifold learning was used to obtain the multi-scale manifold feature difference of each reference model unit to enhance the sensitivity of anomalous features. The projection matrix of each reference model unit was used to enhance the original feature set and obtain the low-dimensional multi-scale sensitive manifold feature. The input to the classifier was used to realize the state recognition of the unknown sample. The measured signal processing results verified the effectiveness of the algorithm.

Keywords: telemetry vibration signal; multi-scale analysis; neighborhood preserving embedding; manifold spatial; abnormal detection

流形学习作为机器学习领域的研究热点,通过对高维数据局部结构的保持,获取嵌入在高维观测空间中的低维流形,获取高维数据的本质特征,在挖掘数据的本质结构上具有极大的优势。流行学习分为线性和非线性流形学习两大类,最早提出的是非线性流形学习方法,如拉普拉斯特征映射(Laplacian Eigenmap, LE)[1]、局部线性嵌入(Locally Linear Embedding, LLE)[2]、局部切空间排列(Local Tangent Space Alignment, LTSA)[3]以及等距特征映射(Isometric feature Mapping, IsoMap)[4]等。其中:LE通过拉普拉斯Beltrami算子来构造相应空间嵌入目标函数,利用无向有权图对流形空间进行描述;LLE根据数据局部线性关系将流形的局部几何信息从高维空间映射到低维空间;LTSA通过利用每一个数据点的局部切空间同欧式空间的同构关系,得到高维数据到低维切空间的映射关系;IsoMap以测地线距离为基础使得样本数据在保持近邻结构的同时,得到高维数据的低维嵌入。针对非线性流形学习对于新未知样本无法直接进行低维映射的缺点,国内外学者陆续提出上述非线性流形学习方法的线性近似算法,如局部保持投影(Local Preserving Projections, LPP)[5]、近邻保持嵌入(Neighborhood Preserving Embedding, NPE)[6]和线性局部切空间排列(Linear Local Tangent Space Alignment, LLTSA)算法[7],它们不但可以保持数据内在的非

* 收稿日期:2019-04-04
基金项目:国家自然科学基金资助项目(61801482,61703408,61801481)
作者简介:刘学(1983—),男,黑龙江大庆人,高级工程师,博士,E-mail:liuxue002@163.com

线性结构与数据子空间的局部流形结构相似，还可以获得高维敏感特征子集转换为低维空间的显式映射。因此，在信息挖掘领域得到更为广泛的应用。

多尺度分析结合流形学习的故障模式识别方法是状态监测与故障诊断研究领域的研究热点[8-9]，该类方法充分结合多尺度分析方法对隐含在特定尺度上的信号特征信息的探测能力和流形学习方法对数据本质结构的挖掘能力，优势互补，在旋转机械早期监测预警、故障诊断和心脏健康监测等场合得到广泛应用，如王广斌等[10-11]提出基于流形子带的拉普拉斯特征映射方法和基于多尺度子带样本熵的局部保持投影方法，实现对转子复合故障特征的准确检测；Miao 等[12]将近邻保持嵌入算法应用到工业过程监控中，同时提取数据动态的空间和时间结构特征，增强了对过程变化的检测能力；Wang 等[13]提出利用小波包变换与流形学习相结合的轴承故障诊断方法，利用重构小波系数的波形特征集的低维流形表征滚动轴承微弱瞬态信号特征；Chen 等[14]采用流形学习方法对由信号时域、频域以及总体经验模态分解（Ensemble Empirical Mode Decomposition，EEMD）分量多尺度特征的组成高维混合特征集进行敏感流形特征提取，实现旋转机械故障模式进行分类与识别；Miao 等[15]提出采用多尺度特征结合局部线性嵌入算法的非线性故障信号特征提取与诊断方法，利用信号非平稳状态的多尺度特征，对故障类型及损伤程度进行了有效识别；Ding 等[16]采用 LPP 对小波包节点能量进行维数约简，增强了对机械故障类别的辨识效果。

相比于传统的机械监测信号，遥测振动信号由冲击激起的共振的频带较宽，具有响应周期短（脉冲数少）、冲击强等特性，这导致异类模式之间差距较小，难以识别。另外，飞行器试验难度高且成本高昂，试验次数较少导致采集的样本数量较小，如何在小样本条件下实现准确的异常模式识别也是需要解决的关键问题，针对上述问题，提出一种基于参照化流形空间融合学习的遥测振动信号敏感特征提取与异常检测方法，通过建立专属参照化模型单元，采用级联流形学习的模式实现对信号多尺度特征信息的多层挖掘再学习，有效提高了特征信息的敏感性。

1 多尺度特征集构造

飞行器系统状态异常是一个多因素决定的复杂动态过程，因此非平稳状态的多尺度特征才是反映系统运行状态的本质特征，为了全面、准确地对遥测振动信号进行异常检测，采用信号的多尺度特征表征异常信号状态。

1.1 小波包多尺度分解

小波包变换（Wavelet Packet Transform，WPT）具有正交、完整、多分辨率等优点，可将非平稳信号按任意的时频分辨率正交无遗漏地分解到不同的频带范围内，通过一组正交的低通和高通滤波器递归地对信号的低频和高频部分进行多层次划分，将信号的时频成分投影到对应的小波包空间[13]。

$$\begin{cases} d_{j+1}^{2n}(\tau) = \sum_k h(k-2\tau) d_j^n(k) \\ d_{j+1}^{2n+1}(\tau) = \sum_k g(k-2\tau) d_j^n(k) \end{cases} \quad j = 0,1,\cdots,J \tag{1}$$

其中：J 为小波包分解层数，$d_{j+1}^{2n}(\tau)$ 和 $d_{j+1}^{2n+1}(\tau)$ 分别为小波二分树第 $j+1$ 层第 $2n$ 和第 $2n+1$ 个节点的小波系数，$h(k)$ 和 $g(k)$ 分别为正交低通和高通滤波器系数，$d_j^n(k)$ 为小波包第 j 层第 n 节点小波系数。可以通过逆向递归分割求解对 $d_j^n(k)$ 进行重构。

$$d_j^n(k) = \sum_k h(k-2\tau)\bar{d}_{j+1}^{2n}(\tau) + \sum_k g(k-2\tau)\bar{d}_{j+1}^{2n+1}(\tau) \tag{2}$$

由式(2)可知，为了单独获得某一子频带内的信息，可将其他子频带的小波系数置零，对当前子频带单独重构获得相应节点的小波重构系数 $\{C_J^n(t), n=0,1,\cdots,2^J-1\}$。

1.2 多尺度子带样本熵

传统的样本熵只能对信号全局复杂度进行度量，但遥测振动信号反映的系统状态变异往往只在特定尺度上有明显的信息反映，且在多尺度状态信息之间存在内在联系。因此对遥测振动信号进行多尺度分解，提取多尺度信号的子带样本熵，在不同尺度深入信号内部层层挖掘信号的异常特征。多尺度样本熵算法参见文献[8]，依次求取所有小波包节点重构系数的子带样本熵构造高维特征向量。

$$\boldsymbol{SC} = [(\boldsymbol{SC}_J^0)^{\mathrm{T}}, (\boldsymbol{SC}_J^1)^{\mathrm{T}}, \cdots, (\boldsymbol{SC}_J^{2^J-1})^{\mathrm{T}}] \in \mathbf{R}^{\alpha 2^J \times 1} \tag{3}$$

式中，α 为子带因子，从对遥测振动信号的分析过程中发现，某一类型的故障模式会导致振动信号在特定时刻发生间断或限幅，多尺度子带样本熵在表征信号奇异方面，较常用的 Lipschitz 指数更为敏感。

1.3　多尺度能量比值

采用小波包分解子频带单独重构获得相应节点的小波重构系数$\{C_J^n(t),n=0,1,\cdots,2^J-1\}$的能量来度量该节点内特征的变化。

$$E_J^n=\frac{1}{N}\sum_{i=1}^{N}C_j^n(i)\quad n=0,1,\cdots,2^J-1 \tag{4}$$

式中,N 为小波系数数据长度。总能量 $E=\sum_{n=0}^{2^J-1}E_J^n$。对各节点能量进行归一化,可得多尺度能量比值$P_J^n=\frac{E_J^n}{E}$,该特征集表征不同尺度节点能量在所有尺度能量上存在的概率。

$$\boldsymbol{P}=[P_J^0,P_J^1,\cdots,P_J^{2J-1}]\in\mathbf{R}^{1\times 2J} \tag{5}$$

综合以上两种特征,通过 J 层的小波包分解构造多尺度特征集 $\boldsymbol{WPTFEA}$。

$$\boldsymbol{WPTFEA}=[\boldsymbol{SC},\boldsymbol{P}^{\mathrm{T}}]\in\mathbf{R}^{(\alpha+1)2J\times 1} \tag{6}$$

2　参照化流形空间融合学习

2.1　类别参照化近邻保持嵌入算法

NPE 算法是 LLE 算法的线性近似算法,对于高维样本集 $\boldsymbol{X}=[\boldsymbol{x}_1,\boldsymbol{x}_2,\cdots,\boldsymbol{x}_N]\in\mathbf{R}^{D\times N}$,NPE 旨在寻找映射矩阵 $\boldsymbol{\alpha}=[\boldsymbol{\alpha}_1,\boldsymbol{\alpha}_2,\cdots,\boldsymbol{\alpha}_d]\in\mathbf{R}^{D\times d}$,通过投影空间变换 $\boldsymbol{Y}=\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}$,得到嵌入高维空间的低维流形 $\boldsymbol{Y}=[\boldsymbol{y}_1,\boldsymbol{y}_2,\cdots,\boldsymbol{y}_N]\in\mathbf{R}^{d\times N}$,$d\ll D$。为保持数据局部流形结构,每个样本点能以相同的权重被其对应的 k 个近邻点重构,得到 NPE 的优化目标函数。

$$\begin{aligned}J_d(\boldsymbol{\alpha})&=\mathrm{Min}\Big(\sum_{i=1}^{N}\Big\|\boldsymbol{y}_i-\sum_{j=1}^{k}w_{ij}\boldsymbol{y}_j\Big\|^2\Big)\\&=\mathrm{Min}[\boldsymbol{Y}^{\mathrm{T}}(\boldsymbol{I}-\boldsymbol{W})^{\mathrm{T}}(\boldsymbol{I}-\boldsymbol{W})\boldsymbol{Y}]\\&=\min_{\alpha}[\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}(\boldsymbol{I}-\boldsymbol{W})^{\mathrm{T}}(\boldsymbol{I}-\boldsymbol{W})\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}]\\&=\min_{\alpha}(\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{M}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha})\\&\text{s.t.}\quad\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}=\boldsymbol{I}\end{aligned} \tag{7}$$

其中,$\boldsymbol{M}=(\boldsymbol{I}-\boldsymbol{W})^{\mathrm{T}}(\boldsymbol{I}-\boldsymbol{W})$ 为满足对称半正定的局部散度矩阵,$\boldsymbol{W}=[w_{ij}]\in\mathbf{R}^{N\times N}$ 为重构系数矩阵。$\boldsymbol{W}$ 衡量邻域数据点 x_j 对 x_i 的重构权重,具有尺度转换、旋转和平移不变性。当数据点 x_j 不是 x_i 所对应的近邻点时,$w_{ij}=0$,$\sum_{j=1}^{k}w_{ij}=1$,约束条件 $\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}=\boldsymbol{I}$ 可消除随机尺度因子的影响。

由式(7)可以发现,NPE 是一种无监督流形学习方法,当异类模式之间比较相近的时候,由于没有考虑样本的类别信息,NPE 很可能将异类模式样本划分到同一局部空间进行特征投影,导致投影后的低维流形结构扭曲失真。另外,NPE 为了保证投影前后的数据局部近邻结构相似,其目标函数没有考虑数据的全局特征。针对 NPE 存在的这些问题以及有效增强异类模式之间的流形特征差异,提出一种类别参照化局部保持投影(Class-Reference Neighborhood Preserving Embedding,CRNPE)方法,该方法可根据应用场合选取监督学习或无监督学习两种模式。

2.1.1　监督学习模式

在监督学习模式下有效利用类别标签信息,在保持数据局部特征的同时使异类模式具有最大的类间散度。算法流程如下所示。

步骤 1:将高维数据集 $\boldsymbol{X}\in\mathbf{R}^{D\times N}$ 根据 c 种类别标签划分为 $\boldsymbol{X}=\boldsymbol{\pi}_1\cup\boldsymbol{\pi}_2\cup\cdots\cup\boldsymbol{\pi}_c$。

步骤 2:采用文献[17]提出的自适应邻域构造方法计算重构系数矩阵 $\boldsymbol{W}$,避免 k 近邻方法需人工设置近邻数,在监督学习模式下,依据各样本的类别标签加入监督机制强化同类样本的聚集性和异类样本的互斥性。

$$a_{ij}=\exp(-\|\boldsymbol{x}_i-\boldsymbol{x}_j\|^2/\sigma)$$

$$w_{ij}=\begin{cases}a_{ij} & \alpha_{ij}>M=\dfrac{1}{N}\displaystyle\sum_{j=1}^{N}\alpha_{ij};\boldsymbol{x}_i,\boldsymbol{x}_j\in\boldsymbol{\pi}_c\\0 & \text{其他}\end{cases} \tag{8}$$

其中:σ 为热核宽度,等于所有样本欧式距离均值的平方;重构系数 w_{ij} 由样本 $\boldsymbol{x}_i$ 与其他样本相似度均值 M_i 以及 $\boldsymbol{x}_i$ 与 $\boldsymbol{x}_j$ 的类别标签是否一致共同确定。对相同近邻域的重构系数 w_{ij} 进行归一化以满足 $\sum_{j=1}^{k}w_{ij}=1$。

步骤 3:根据参照的样本类别 $\boldsymbol{\pi}_i$,计算其对应的负散度矩阵。

$$\boldsymbol{S}_c^i=\frac{1}{N_{-,i}}\sum_{j=1}^{N_{-,i}}(\boldsymbol{x}_j-\bar{\boldsymbol{\mu}}_i)(\boldsymbol{x}_j-\bar{\boldsymbol{\mu}}_i)^{\mathrm{T}}\in\mathbf{R}^{D\times D} \tag{9}$$

式中,$\bar{\boldsymbol{\mu}}_i$ 为 $\boldsymbol{\pi}_i$ 类样本均值,$N_{-,i}$ 为除去 $\boldsymbol{\pi}_i$ 类样本剩余的其他类样本数目。

步骤 4:监督学习模式下的优化目标函数为:

$$J(\boldsymbol{\alpha})=\min\frac{\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{M}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}}{\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{S}_c^i\boldsymbol{\alpha}} \tag{10}$$

该优化目标函数能够保证在数据降维前后局部重构特征变化最小,同时对参照的样本类别 $\boldsymbol{\pi}_i$ 具有更大的类间散度,在第一层为特征信息增强性学习中可有效凸显异类样本局部差异的敏感性。式(10)的最优化问题,可通过 $J(\boldsymbol{\alpha})$ 对 $\boldsymbol{\alpha}$ 求偏导数为 0 进行求解,即

$$\frac{\mathrm{d}J(\boldsymbol{\alpha})}{\mathrm{d}\boldsymbol{\alpha}}=2(\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{S}_c^i\boldsymbol{\alpha})^{-1}\boldsymbol{X}\boldsymbol{L}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}-$$
$$2\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{L}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}(\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{S}_c^i\boldsymbol{\alpha})^{-2}\boldsymbol{S}_c^i\boldsymbol{\alpha}=0\Leftrightarrow$$
$$\boldsymbol{X}\boldsymbol{L}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}=J(\boldsymbol{W})\boldsymbol{S}_c^i\boldsymbol{\alpha} \tag{11}$$

如果 $\boldsymbol{S}_c^i$ 满足半正定，可逆，则式(11)可以通过 Lagrange 乘法转化为广义的特征值求解。

$$\boldsymbol{X}\boldsymbol{L}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}=\lambda\boldsymbol{S}_c^i\boldsymbol{\alpha} \tag{12}$$

2.1.2 无监督学习模式

在无监督学习模式下，为了达到在保持数据局部特征的同时使得异类模式具有最大的类间散度这一优化目标，需同时考虑数据的全局特征，使得位于不同的邻域中距离较远的数据点在低维空间尽可能地分开。现提出如下解决思路：建立双优化目标函数，在满足数据点与 k 个邻域数据的局部距离不变的约束下，通过最大化不同邻域数据方差来最大化地展开数据流形。算法流程如下所示。

步骤 1：依然采用自适应邻域构造方法计算重构系数矩阵 $\boldsymbol{W}$，在无监督模式下，取消式(8)中 $\boldsymbol{x}_i,\boldsymbol{x}_j\in\boldsymbol{\pi}_c$ 的限制条件。

步骤 2：建立无监督学习双优化目标函数。

$$J(\boldsymbol{\alpha})=\min\frac{\sum_{i=1}^{N}\left\|\boldsymbol{y}_i-\sum_{j=1}^{k}w_{ij}\boldsymbol{y}_j\right\|^2}{\sum_{i=1}^{N}\sum_{j=k+1}^{N}\|\boldsymbol{y}_i-\boldsymbol{y}_j\|^2}$$
$$=\min\frac{\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{M}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}}{\boldsymbol{\alpha}^{\mathrm{T}}\sum_{i=1}^{N}\sum_{j=1}^{N}(\boldsymbol{x}_i-\boldsymbol{x}_j)(\boldsymbol{x}_i-\boldsymbol{x}_j)^{\mathrm{T}}H_{ij}\boldsymbol{\alpha}}$$
$$=\min\frac{\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{M}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}}{\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{R}\boldsymbol{X}\boldsymbol{\alpha}} \tag{13}$$

当数据点 $\boldsymbol{x}_j$ 是 $\boldsymbol{x}_i$ 所对应的最近邻点时，$H_{ij}=0$，否则 $H_{ij}=1$。式(13)的最优化问题，也可通过 $J(\boldsymbol{\alpha})$ 对 $\boldsymbol{\alpha}$ 求偏导数为 0 进行求解，即

$$\frac{\mathrm{d}J(\boldsymbol{\alpha})}{\mathrm{d}\boldsymbol{\alpha}}=2(\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{R}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha})^{-1}\boldsymbol{X}\boldsymbol{M}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}-$$
$$2\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{M}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}(\boldsymbol{\alpha}^{\mathrm{T}}\boldsymbol{X}\boldsymbol{R}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha})^{-2}\boldsymbol{X}\boldsymbol{R}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}=0\Leftrightarrow$$
$$\boldsymbol{X}\boldsymbol{M}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}=J(\boldsymbol{\alpha})\boldsymbol{X}\boldsymbol{R}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha} \tag{14}$$

如果 $\boldsymbol{R}$ 可逆，则式(14)也可以通过 Lagrange 乘法转化为广义的特征值求解。

$$\boldsymbol{X}\boldsymbol{M}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha}=\lambda\boldsymbol{X}\boldsymbol{R}\boldsymbol{X}^{\mathrm{T}}\boldsymbol{\alpha} \tag{15}$$

若式(12)和式(15)中 $\boldsymbol{S}_c^i$ 和 $\boldsymbol{R}$ 不可逆，可参照文献[18]提出的正则化方法进行近似求解，选取前 $d(d\ll D)$ 个最小特征值所对应的特征向量得到投影矩阵 $\boldsymbol{W}=[\boldsymbol{w}_1,\boldsymbol{w}_2,\cdots,\boldsymbol{w}_d]\in\mathbf{R}^{D\times d}$。通过投影空间变换 $\boldsymbol{Y}=\boldsymbol{W}^{\mathrm{T}}\boldsymbol{X}$ 得到嵌入在高维空间中的低维流形 $\boldsymbol{Y}=[\boldsymbol{y}_1,\boldsymbol{y}_2,\cdots,\boldsymbol{y}_N]\in\mathbf{R}^{d\times N}$。

2.2 遥测振动信号敏感特征提取的参照化流形空间融合学习方法

针对遥测振动信号样本数少、冲击强、响应周期短等特点导致异类模式之间差异性小的问题，借鉴深度学习思想，提出采用级联两层流形学习的参照化流形空间融合学习方法。通过两层流形学习对信号多尺度特征进行提纯再学习，提高特征信息的敏感性。算法流程如图 1 所示。

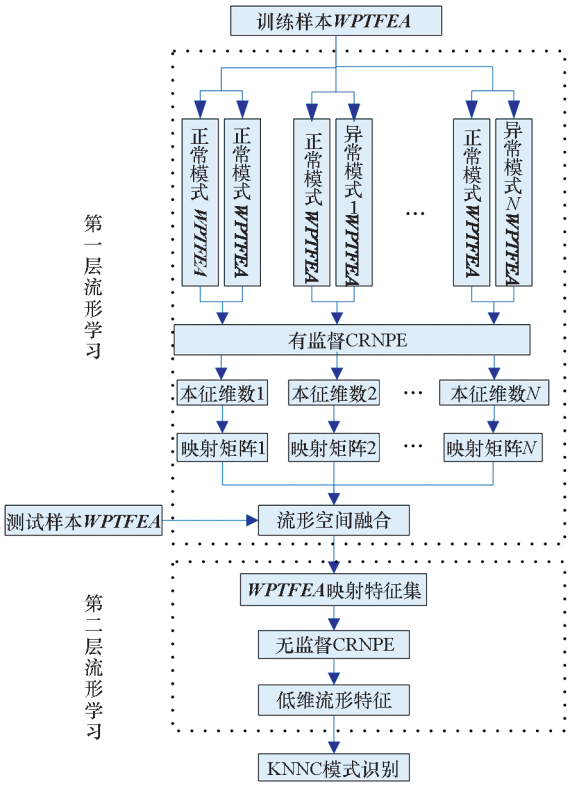


图 1 算法流程图

Fig. 1 Algorithm flowchart

图 1 中，第一层为特征信息的增强性学习，以相同的正常信号样本结合相同类型的异常样本建立专属参照化模型单元，将多分类问题转化为二分类问题。在增强正常模式与异类模式流形特征差异性的同时有效提高样本的利用率。第二层为多尺度特征拓展学习，通过对第一层学习得到的映射矩阵进行流形空间融合，实现对多尺度特征的升维拓展。通过流形再学习，对拓展后特征信息进行提纯，获取低维敏感流形特征。算法步骤如下所示。

步骤 1：对采集的遥测振动信号依据指令时刻进行特征段顺序选取，若相邻指令时刻间隔较近(前一指令响应未结束，后一指令响应即开始)，可按前一特征段最大幅值能量的 10% 进行截取，若重叠部分超过 50%，则将相邻两特征段合并处理。对所选特征段进行预处理：根据

《GJB2238A—2004》的规范进行零漂修正、趋势项去除、野值剔除等。

步骤 2:第一层特征信息的增强性学习。将所有样本同一指令时刻的特征段信号组成训练样本集,按照第 1 节的方法构建高维多尺度特征集,并按照各样本的类别信息(共有 c 类模式),创建类别标签。以相同的正常信号样本为参照构建 c 个专属参照化模型单元。

$$\boldsymbol{T}_i^{\text{train}} = [\boldsymbol{WPTFEA}_i^1, \cdots, \boldsymbol{WPTFEA}_i^{n_i}] \quad i = 1, 2, \cdots, c$$

对每个专属参照化模型单元 $\boldsymbol{T}_i$ 进行数据标准化处理 $\tilde{\boldsymbol{T}}_i^{\text{train}} = f_1(\boldsymbol{T}_i^{\text{train}})$,消除数据量纲的影响采用极大似然估计(Maximum Likelihood Estimate, MLE)方法计算各单元的本征维数,通过 CRNPE 对 $\tilde{\boldsymbol{T}}_i^{\text{train}}$ 依据其本征维数进行特征降维,得到其参照化模型单元的映射矩阵 $\boldsymbol{M}_i$。在流形空间中将各参照化模型单元的映射矩阵 $\boldsymbol{M}_i$ 进行融合,得到综合映射矩阵 $\boldsymbol{M}_{\text{layerI}} = [\boldsymbol{M}_1^{\text{T}}, \boldsymbol{M}_2^{\text{T}}, \cdots, \boldsymbol{M}_c^{\text{T}}]^{\text{T}}$。

步骤 3:第二层为多尺度特征拓展学习:采用 $\boldsymbol{M}_{\text{layerI}}$ 对测试样本集 $\boldsymbol{T}^{\text{test}}$ 进行特征拓展,凸显各异常模式与正常模式差异信息的敏感性,提高各类型样本的利用率。

$$\boldsymbol{F}^{\text{test}} = \boldsymbol{M}_{\text{layerI}} \boldsymbol{T}^{\text{test}} \tag{16}$$

对特征拓展后的高维特征集 $\boldsymbol{F}^{\text{test}}$ 再次进行数据标准化处理 $\tilde{\boldsymbol{F}}^{\text{test}} = \boldsymbol{f}_2(\boldsymbol{F}^{\text{test}})$,进行无监督 CRNPE 流形再学习,获取低维敏感流形特征 $\boldsymbol{Y}^{\text{test}}$。

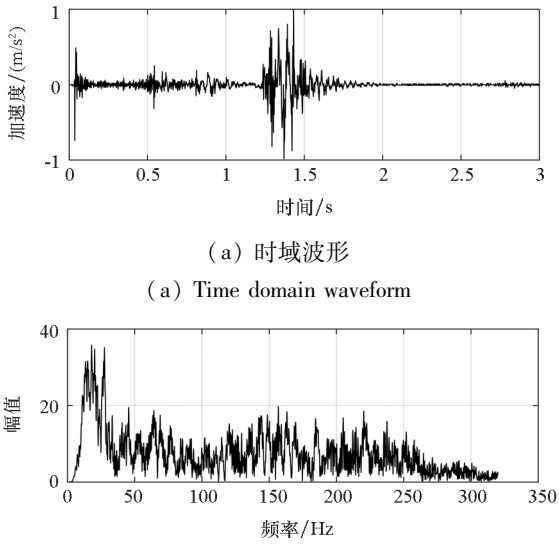
$$\boldsymbol{Y}^{\text{test}} = \boldsymbol{M}_{\text{layer2}} \tilde{\boldsymbol{F}}^{\text{test}} \tag{17}$$

式中,$\boldsymbol{M}_{\text{layer2}}$ 为第二层 CRNPE 流形学习的映射矩阵。

步骤 4:将敏感流形特征 $\boldsymbol{Y}^{\text{test}}$ 输入到 K 最近邻分类器(K-Nearest Neighbor classification, KNNC)进行信号状态模式识别,得到分类结果。

3　实测信号验证

为验证所提方法的有效性,采用某型飞行器试验任务中同一系统部位传感器采集的轴、法、横 3 个通道的遥测振动信号进行处理验证。以法向通道信号为例,选取正常信号和 3 种类型故障信号作为测试信号,其中正常信号样本 45 个,异常模式 1(过载超过限定值,致使该部位下端框出现细微裂纹或断裂)信号样本 27 个,异常模式 2(该部位肩部出现形变或细微裂纹)信号样本 29 个,异常模式 3(某故障导致在特定时间段内振动信号发生间断或限幅)信号样本 21 个。保密安全起见,信号幅值作了归一化处理,某一样本信号的时域波形如图 2 所示。



(a) 时域波形

(a) Time domain waveform

(b) 频谱

(b) Spectrum

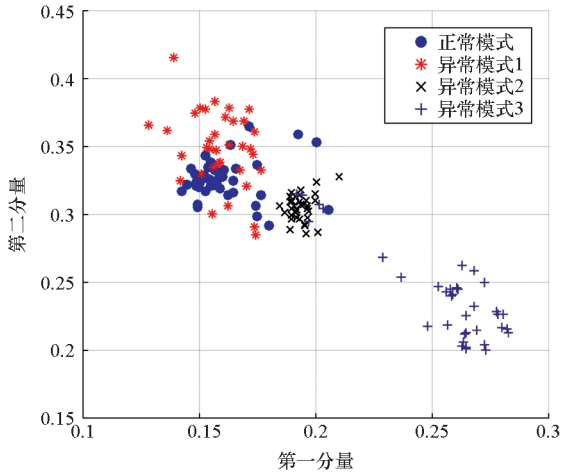
图 2　遥测振动信号及其频谱

Fig. 2　Waveform and spectrum of the telemetry vibration signal

根据信号的采样频率,3 层小波包分解即可包含所有的分析频率,以 *db*4 小波作为小波基函数,多尺度子带 *SampEn* 的子带因子 $\alpha = 3$,则每个样本可以得到其多尺度特征向量 $\boldsymbol{WPTFEA} \in \mathbf{R}^{32\times 1}$,组成训练特征集 $\boldsymbol{X}^{\text{train}} \in \mathbf{R}^{32\times 122}$。以异常模式最小样本数为依据,随机选取相同的正常信号样本作为参照样本,构建 3 个专属参照化模型单元,其中 $\boldsymbol{T}_i^{\text{train}} \in \mathbf{R}^{32\times 42}$。以各单元的本征维数为依据采用 CRNPE 对标准化处理后的单元特征集 $\tilde{\boldsymbol{T}}_i^{\text{train}}$ 进行降维,得到其参照化模型单元的映射矩阵 $\boldsymbol{M}_i$。为了对第一层特征信息的增强性学习的性能进行分析,采用各参照化模型单元的映射矩阵 $\boldsymbol{M}_i$ 对 $\boldsymbol{X}^{\text{train}}$ 进行特征映射,直观起见,这里选取映射后的前二维分量进行分析,结果如图 3 所示。

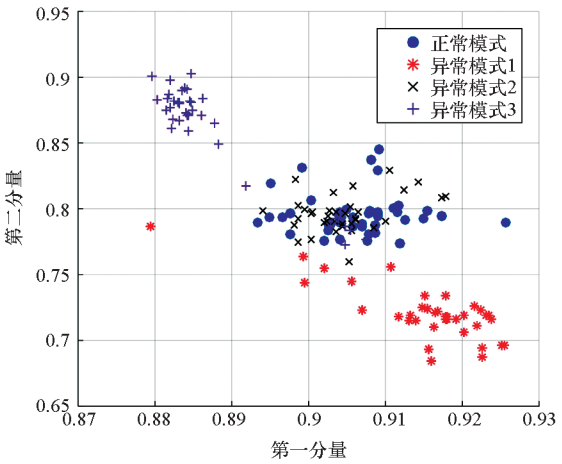
通过图 3 可以发现,由于不同模式的特征方向不同,通过第一层特征信息的增强性学习,每个专属参照化模型单元所训练出的映射矩阵只对所对应类型的样本在低位空间投影聚集,将其他模式的样本投影到更远的低维坐标上进行分离,这增加了不同属性样本之间的类间散度,即每个专属参照化模型单元只针对同属性样本具有特征增强特性,而对异类属性样本,增大了其流形特征的差异性。

由于样本数较少,将所有样本组成测试集 $\boldsymbol{X}^{\text{test}} = \boldsymbol{X}^{\text{train}} \in \mathbf{R}^{32\times 122}$,将所提方法(简写为 CRNPE + CRNPE)与主成分分析(Principal Component Analysis, PCA)、LLE 及其线性化方法 NPE 算法、



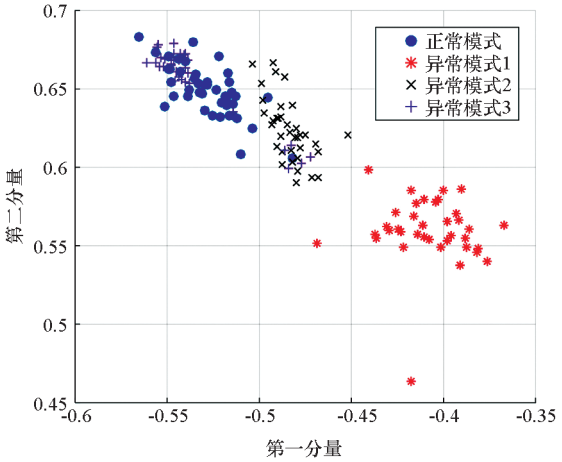
(a) 正常 - 异常模式 1 参照单元

(a) Normal-abnormal mode 1 reference unit



(b) 正常 - 异常模式 2 参照单元

(b) Normal-abnormal mode 2 reference unit



(c) 正常 - 异常模式 3 参照单元

(c) Normal-abnormal mode 3 reference unit

图 3 各专属参照化模型单元映射下 4 种模式 ***WPTFEA*** 二维聚类分布

Fig. 3 Two-dimensional clustering of four modes ***WPTFEA*** of telemetry vibration signals under the mapping of each specific reference model unit

基于无监督 NPE 的参照化流形空间融合学习(两层均采用无监督 NPE,简写为 Unsupervised NPE + NPE)和基于有监督 NPE 的参照化流形空间融合学习(第一层特征信息的增强性学习采用有监督 NPE,监督学习模式同 CRNPE 的第 2 步,简写为 Supervised NPE + NPE)的性能进行对比测试,同样选取映射后的前三维分量进行分析。同时采用类内散度 S_w、类间散度 S_b 和判别因子 $S = S_b/S_w$ 三种评估因子定量分析上述算法的聚类性能[19]。

$$\begin{cases} S_w = \sum_{j=1}^{c} \sum_{u \in c_j} (u - \mu_i)(u - \mu_j)^T \\ S_b = \sum_{j=1}^{c} n_j (\mu_j - \bar{\mu})(\mu_j - \bar{\mu})^T \end{cases} \tag{18}$$

其中:c 为模式总数,n_j 为第 j 个模式的样本数,$\mu_j = \sum_{u \in c_j} (u/n_j)$ 为第 j 个模式样本特征均值,$\bar{\mu} = \sum (\mu_j/c)$ 为所有样本特征均值。以获取的低维流形矩阵的前三维分量作为敏感特征输入到最近邻分类器中,采用测试集留一交叉检验正确识别率作为分类精度,结果如表 1 和图 4 所示。

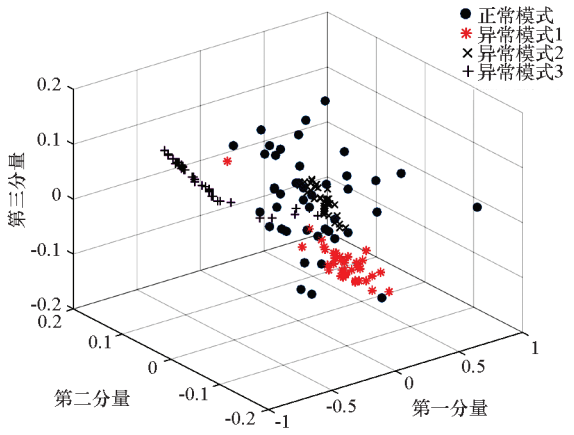
表 1 不同流形学习方法的特征聚类定量分析对比

Tab. 1 Quantitative analysis and comparison of characteristic clusters of different manifold learning methods

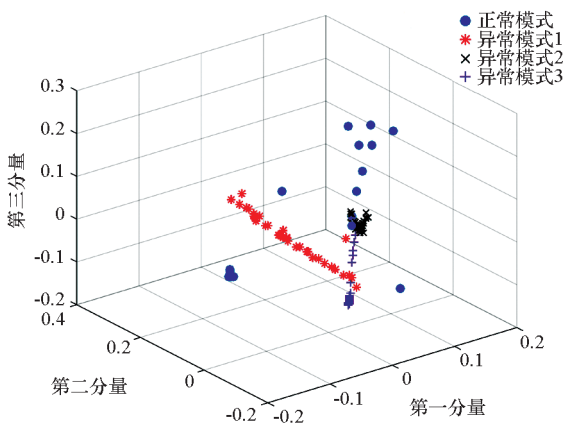
方法	S_w	S_b	S	分类精度/%
PCA	5.87	10.23	1.74	53.28
LLE	2.93	40.66	13.88	83.60
NPE	0.92	41.32	44.91	81.15
Unsupervised NPE + NPE	1.07	182.31	170.38	90.98
Supervised NPE + NPE	0.98	186.82	190.63	95.90
CRNPE + CRNPE	0.79	211.37	267.56	99.18

从图 4(a)可以看出,PCA 只考虑样本集的全局特性,忽略局部特征,导致各模式样本交织重叠在一起,难以区分,分类精度仅为 53.28%。LLE 和其线性近似算法 NPE 均为非线性降维方法,它们充分考虑测试集的局部特征,并保持数据内在的非线性结构。因此它们得到的聚类分布效果优于 PCA 方法,可将部分异类模式样本分离,分类精度有所提高,但不同模式样本之间仍存在一定程度的重叠,不利于分类器的模式识别。

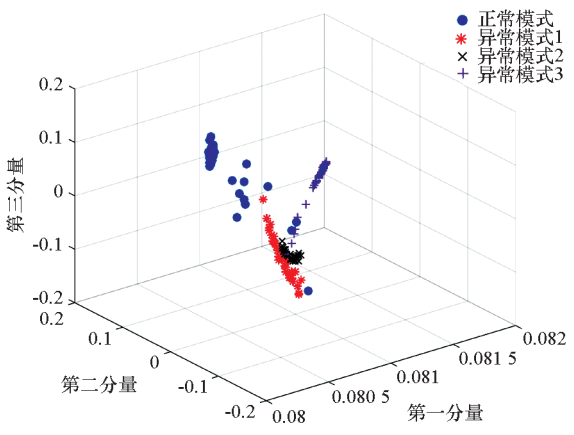
而参照化流形空间融合学习方法通过参照化模型建立各异类模式专属的特征挖掘单元,增大



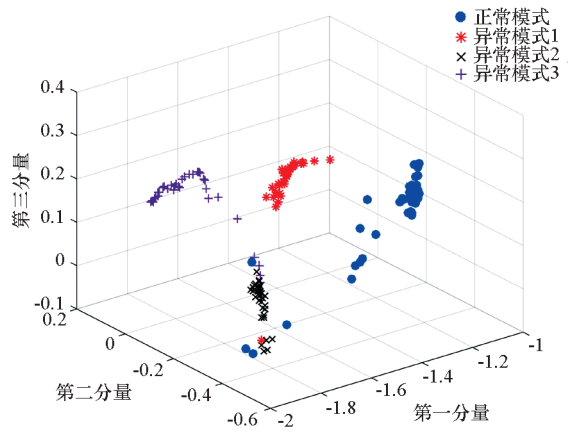
（a）PCA



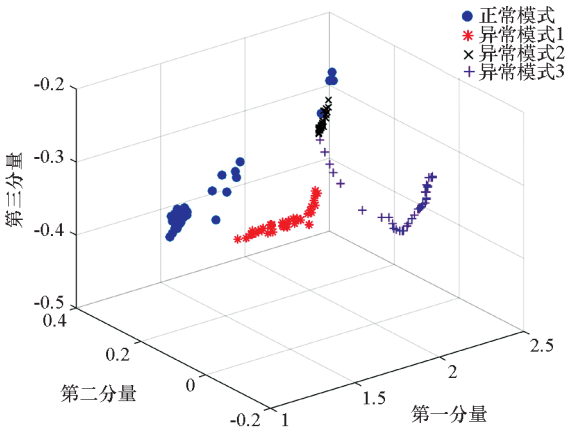
（b）LLE



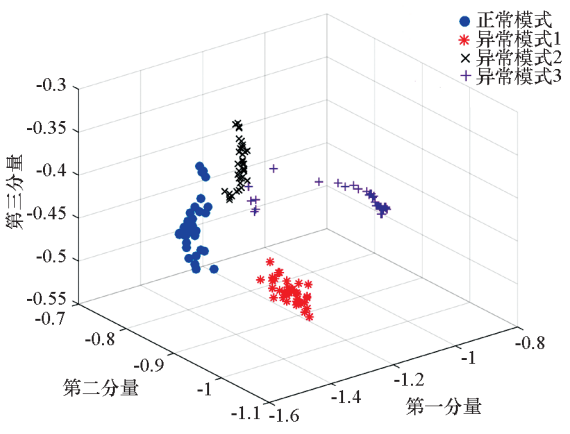
（c）NPE



（d）Unsupervised NPE + NPE



（e）Supervised NPE + NPE



（f）CRNPE + CRNPE

图 4　六种流形学习方法得到的三维流形特征聚类分布

Fig. 4　Clustering distribution of three-dimensional manifold features obtained by six manifold learning methods

异类模式同正常模式样本的特征差异，利用多个参照化模型单元的特征融合映射矩阵，可以实现对多尺度特征集的信息扩展，获取更高维的特征信息，为第二层流形再学习提取更为敏感低维流形特征提供便利。从图 4（d）~（f）可以看出，在聚类分布图中，每种模式具有较为清晰的聚类边界，不同模式较单层学习更易被区分，分类精度均达到了 90%。这说明参照化流形空间融合学习方法可有效地增大异类模式之间的差异性以及同类模式之间的聚集性，但通过图 4（d）和图 4（e）的对比可以发现，无监督 NPE + NPE 由于没有利用样本的类别信息，在确定近邻空间时很可能将异类模式样本划分到同一局部空间进行特征投影，导致特征投影后部分正常模式样本错误地被

划分到异常模式的聚类空间中,这将严重影响后续模式识别的精度。有监督 NPE + NPE 在第一层特征信息的增强性学习采用监督学习模式,充分利用样本的类别信息,避免了无监督 NPE + NPE 错误特征投影问题,使得各模式具有独立的聚集边界,分类精度有所提高,达到了 95.90%。但 NPE 为了保证投影前后的数据局部近邻结构相似,其目标函数没有考虑数据的全局特征,各模式之间,特别是异常模式 2 和异常模式 3 之间,没有形成较大的类间散度和较小的类内散度,而良好的模式识别效果需同时考虑各模式之间的类间散度和类内散度,即不仅要有较大的类间散度,还应具有较小的类内散度。

针对上述问题,CRNPE 在保持数据局部特征的同时使得异类模式具有更大的类间散度,可以增大不同模式之间的区分度。无监督 CRNPE 同时考虑数据的局部和全局特征,从图 4(f)和表 1 可以看出,CRNPE + CRNPE 参照化流形空间融合学习方法提取的流形特征可以同时获得最大的类间散度、最小的类内散度、最大的判别因子以及最高的分类精度 99.18%,即该方法可以有效增加异类模式之间的差异性以及同类模式之间的聚集性。因此,CRNPE + CRNPE 学习方法在增强特征信息、挖掘系统状态敏感特征等方面优于上述其他方法。

4 结论

提出一种基于参照化流形空间融合学习的遥测振动信号敏感特征提取与异常检测方法,通过建立专属参照化模型单元,采用级联流形学习的模式实现对信号多尺度特征信息的多层挖掘再学习,有效提高了特征信息的敏感性。经实测信号应用验证,所提方法可有效提高遥测振动信号异常模式识别精度。总结可得到以下几点结论。

1)提出 CRNPE 算法,在监督模式下采用新的优化目标函数能够保证在数据降维前后局部重构特征变化最小,同时对参照的样本类别 $\boldsymbol{\pi}_i$ 具有更大的类间散度;在无监督模式下,同时考虑数据的局部和全局特征,采用双优化目标函数,在满足数据点与 k 个邻域数据的局部距离不变的约束下,通过最大化不同邻域数据方差来最大化地展开数据流形;

2)实测信号实验结果表明:新方法可以有效增加异类模式之间的差异性以及同类模式之间的聚集性,在增强特征信息、挖掘系统状态敏感特征等方面优于 PCA、LLE、NPE 和基于 NPE 的参照化流形空间融合学习等流形学习方法。

3)CRNPE 为线性化流行学习方法,可以获得高维敏感特征子集转换为低维空间的显式映射,使得新样本可以迅速准确地映射到低维空间中。因此,基于 CRNPE 参照化流形空间融合学习特征方法可很方便地推广到其他故障检测领域。

参考文献(References)

[1] Belkin M, Niyogi P. Laplacian eigenmaps for dimensionality reduction and data representation[J]. Neural Computation, 2003, 15(6): 1373 – 1396.

[2] Roweis S T, Saul L K. Nonlinear dimensionality reduction by locally linear embedding[J]. Science, 2000, 290(5500): 2323 – 2326.

[3] Zhang Z Y, Zha H Y. Principal manifolds and nonlinear dimension reduction via local tangent space alignment[J]. SIAM Journal on Scientific Computing, 2003, 26(1): 313 – 338.

[4] Seung H S, Lee D D. The manifold ways of perception[J]. Science, 2000, 290(5500): 2268 – 2269.

[5] Yu J B. Bearing performance degradation assessment using locality preserving projections[J]. Expert Systems with Applications, 2011, 38(6): 7440 – 7450.

[6] He X F, Cai D, Yan S C, et al. Neighborhood preserving embedding[C]//Proceedings of the 10th IEEE International Conference on Computer Vision, 2005: 1208 – 1213.

[7] Zhang T H, Yang J, Zhao D L, et al. Linear local tangent space alignment and application to face recognition[J]. Neurocomputing, 2007, 70(7/8/9): 1547 – 1553.

[8] Lunga D, Prasad S, Crawford M M, et al. Manifold-learning-based feature extraction for classification of hyperspectral data: a review of advances in manifold learning[J]. IEEE Signal Processing Magazine, 2014, 31(1): 55 – 66.

[9] Ge Z, Kruger U, Lamont L, et al. Fault detection in non-Gaussian vibration systems using dynamic statistical-based approaches[J]. Mechanical Systems and Signal Processing, 2010, 24(8): 2972 – 2984.

[10] 王广斌, 李龙, 罗军, 等. 基于流形子带特征映射的转子复合故障特征提取方法[J]. 振动与冲击, 2017, 36(16): 56 – 62.
WANG Guangbin, LI Long, LUO Jun, et al. Rotor compound fault feature extraction based on a manifold sub-band feature mapping method[J]. Journal of Vibration and Shock, 2017, 36(16): 56 – 62. (in Chinese)

[11] 王广斌, 杜谋军, 韩清凯, 等. 基于多尺度子带样本熵和 LPP 的轴承故障诊断方法[J]. 振动与冲击, 2016, 35(20): 71 – 76.
WANG Guangbin, DU Moujun, HAN Qingkai, et al. A bearing fault diagnosis method based on multi-scale sub-band sample entropy and LPP[J]. Journal of Vibration and Shock, 2016, 35(20): 71 – 76. (in Chinese)

[12] Miao A M, Ge Z Q, Song Z H, et al. Time neighborhood preserving embedding model and its application for fault detection[J]. Industrial & Engineering Chemistry Research, 2013, 52(38): 13717 - 13729.

[13] Wang Y, Xu G H, Liang L, et al. Detection of weak transient signals based on wavelet packet transform and manifold learning for rolling element bearing fault diagnosis[J]. Mechanical Systems and Signal Processing, 2015, 54/55: 259 - 276.

[14] Chen R, Chen S, Yang L, et al. Looseness diagnosis method for connecting bolt of fan foundation based on sensitive mixed-domain features of excitation-response and manifold learning[J]. Neurocomputing, 2017, 219: 376 - 388.

[15] Miao A M, Song Z H, Ge Z Q, et al. Nonlinear fault detection based on locally linear embedding[J]. Journal of Control Theory and Applications, 2013, 11(4): 615 - 622.

[16] Ding X X, He Q B, Luo N W. A fusion feature and its improvement based on locality preserving projections for rolling element bearing fault classification[J]. Journal of Sound and Vibration, 2015, 335: 367 - 383.

[17] Yang B, Chen S C. Sample-dependent graph construction with application to dimensionality reduction [J]. Neurocomputing, 2010, 74(5): 301 - 314.

[18] Tian Q, Fainman Y, Lee S H. Comparison of statistical pattern-recognition algorithms for hybrid processing. Ⅱ. Eigenvector-based algorithm [J]. Journal of the Optical Society of America A: Optics, Image Science, and Vision, 1988, 5(10): 1670 - 1682.

[19] Jin X H, Zhao M B, Chow T W S, et al. Motor bearing fault diagnosis using trace ratio linear discriminant analysis[J]. IEEE Transactions on Industrial Electronics, 2014, 61(5): 2441 - 2451.